

2 Estado del Arte

Antes de abordar el estudio y propuesta de un método para generar series sintéticas de radiación solar es condición necesaria realizar un amplio estudio de la situación actual y antecedentes respecto a los métodos ya existentes sobre la generación de dichas series. Por lo tanto, en este capítulo, se hará una descripción del estado del arte respecto a los métodos existentes para la generación de series sintéticas de radiación solar. Asimismo, puesto que el método que se propone en esta tesis para la generación de secuencias de radiación solar se basa en un nuevo enfoque que emplea redes neuronales artificiales, también se realizará una descripción de dicho paradigma de computación. Por lo tanto, se ha considerado interesante dividir este capítulo en dos secciones. En la primera, se resumirá la situación actual de las técnicas empleadas para la generación de series artificiales de radiación solar basadas en los métodos clásicos de análisis de series temporales. La segunda sección se centrará en describir el estado actual de las técnicas de tratamiento de información basadas en el uso de redes neuronales artificiales. Asimismo, se comentarán algunos métodos para la generación de series solares que no utilizan las técnicas clásicas, sino los nuevos enfoques a través del uso de redes neuronales.

2.1 Evolución de los métodos clásicos para la generación de secuencias solares

Como ya se mencionó en el capítulo de introducción, cuando el diseñador de sistemas solares (tanto fotovoltaicos como térmicos) va a realizar una instalación, uno de los ingredientes de partida esenciales que necesita es el conocimiento de la radiación solar del lugar. Aunque los datos de radiación solar suelen estar ya disponibles en muchas localidades, existen todavía muchos lugares donde no lo están. Además, según el uso que se precise de estos datos, puede ocurrir que aunque la localidad sí disponga de datos de radiación solar, éstos sean insuficientes o no estén en la escala temporal adecuada.

Con el fin de disponer de largas secuencias de radiación solar tanto a escala diaria como horaria, diferentes investigadores han propuesto una gran variedad de métodos para la generación de series artificiales solares.

En todos esos métodos, la idea que subyace en el fondo, se puede resumir en que se parte de un estudio estadístico exhaustivo de los registros históricos de la localidad o localidades de las que se dispongan datos solares, para posteriormente proponer un modelo matemático de generación solar. En ese estudio estadístico de los datos se han de incluir al menos los dos tipos de características siguientes:

- a) *Características independientes del tiempo* de la radiación solar como son las medias (tanto mensuales como anuales), varianzas o desviaciones estándar, etc.
- b) *Características dependientes del tiempo o secuenciales* de la radiación solar: principalmente las funciones de autocorrelación parciales y totales. (Todas estas características serán descritas más detalladamente en otro capítulo.)

Una vez conocidos esos parámetros, el siguiente paso es la propuesta de un modelo matemático que genere series de radiación sintéticas que sean equivalentes a las series reales, en el sentido de que los parámetros estadísticos antes citados deben ser similares (cuanto más próximos mejor) a los valores de las series reales, dentro de determinados márgenes de fiabilidad.

Se empezará haciendo un repaso a los métodos de generación de series a escala diaria y posteriormente a los de escala horaria.

Uno de los trabajos pioneros en el campo de series diarias fue debido a Klein [1]. Este investigador hizo uso del hecho de que la mayor parte de las variaciones estacionales de la radiación global diaria eran debidas a variaciones en la radiación extraterrestre o extraatmosférica (la que incide sobre las capas altas de la Tierra, sin haber llegado a atravesar la atmósfera), y estas variaciones estacionales pueden ser eliminadas usando el índice de claridad K_T (cociente entre la radiación global y la radiación extraterrestre) como variable. De este modo, la variable a modelar no fue la radiación global propiamente sino el índice de claridad. Sin embargo, muchos otros investigadores empezaron estudiando la propia radiación global. Así, otro de los primeros trabajos fue realizado por Brinkworth [2] utilizando un modelo autoregresivo con media móvil (ARMA: AutoRegressive Moving Average) aplicado directamente sobre los datos de radiación global diaria. Paasen [3] modeló las secuencias de radiación diarias en Holanda, usando una variable de radiación modificada. Exell [4] y Vergara-Domínguez et al. [5] hicieron uso de una nueva variable denominada radiación de cielo

claro, que es similar al índice de claridad. Sin embargo, ninguno de estos autores incorporó en su estudio el análisis de la distribución de los datos obtenidos por medio de la función de distribución. En este sentido, Amato et al. [6] incluyeron la función de distribución de las series de radiación global diaria pero, sin embargo, el modelo propuesto era sólo aplicable a la localidad en estudio, es decir, no era de aplicación universal.

Aunque la función de distribución de la radiación global dependerá localmente del lugar de donde proceda esa radiación, Liu y Jordan [7] demostraron que para el caso de las funciones de distribución del índice de claridad diario, éstas son universales. Además, estas funciones son no gaussianas, dependientes del índice de claridad mensual y por tanto variables mensualmente. Un trabajo que ya incluía las funciones de distribución universales de Liu y Jordan fue realizado por Dagelman [8] quien proponía un método para generar los índices de claridad diarios de forma aleatoria a partir de las curvas de distribución de Liu y Jordan.

También son importantes los trabajos de Boileau [9], basados en desarrollos en serie de Fourier y los de Bartoli et al. [10] también centrados en series de Fourier y procesos de Markov. Sin embargo los más extendidos son los propuestos por Graham y Hollands [11] basados en técnicas de inversión gaussiana y los de Aguiar y Collares-Pereira [12] que hacen uso de Matrices de Transición de Markov. Estos dos últimos trabajos son actualmente los considerados mejores en este campo, y se suelen usar como base para generar secuencias artificiales de radiación solar con gran rigor. En el caso de Graham y Hollands, el estudio fue realizado con localidades canadienses de climas diferentes, y en el caso de Aguiar las localidades utilizadas fueron de varios países, desde Portugal a Macao (China).

Respecto a los métodos de generación en escala horaria, uno de los trabajos pioneros basado en procesos ARMA fue debido a Goh y Tan [13] para datos de Singapur. Mustacchi et al. [14], estudiando alrededor de una veintena de localidades italianas, emplearon Matrices de Transición de Markov para simular los procesos estocásticos implícitos en las series reales de radiación solar horaria. Un método basado en técnicas espectrales fue presentado por Balouktsis y Tsalides [15] para datos de Atenas. Los investigadores españoles Llanos Mora y Mariano Sidrach [16] presentan un modelo basado en procesos ARMA multiplicativos, utilizando datos de localidades

españolas, mientras que Palomo [17], también para localidades españolas, emplea matrices de transición de Markov.

Pero, una vez más, los métodos usados como paradigma en este campo vuelven a ser los propuestos por Graham y Hollands [18] y por Aguiar y Collares-Pereira [19]. El método presentado por Graham y Hollands hace uso de procesos ARMA e inversión gaussiana, siendo prácticamente una continuación del trabajo que presentaron para la generación de series diarias. Sin embargo, el trabajo de Aguiar y Collares-Pereira es bastante diferente al que propusieron para series diarias, ya que no hacen uso de matrices de Markov, sino que en este caso empiezan haciendo un estudio muy exhaustivo de los datos de los que disponen, descubriendo ciertas propiedades que tratan de implementar en su nuevo método. Este nuevo método es denominado modelo gaussiano autoregresivo dependiente del tiempo (“TAG: Time dependent Autoregressive Gaussian model”), y los resultados que produce se ajustan muy satisfactoriamente a los valores reales de radiación solar horaria.

2.2.- Estado del arte en el campo de Redes Neuronales Artificiales

Como ya se ha mencionado anteriormente, puesto que el método que se propone en esta tesis se basa en el uso de un tipo de red neuronal artificial llamado perceptrón multicapa, se hace a continuación un breve repaso de este paradigma de tratamiento de la información, empezando por la propia definición de red neuronal artificial, incluyendo después un repaso histórico a su evolución, algunas aplicaciones de las mismas, etc.

2.2.1.- Definición y descripción de una RNA

Una Red Neuronal Artificial (RNA) es un sistema de procesamiento de información [20] que tiene ciertas características de funcionamiento en común con las redes neuronales biológicas. Las RNAs se han desarrollado como generalizaciones de modelos matemáticos del conocimiento humano o de la biología neuronal, basados en las siguientes suposiciones:

- 1) El procesado de la información ocurre en muchos elementos simples llamados neuronas.
- 2) Las señales pasan entre las neuronas a través de enlaces que las unen.

- 3) Cada conexión entre neuronas lleva asociado un peso, el cual, en una red neuronal típica, lo que hace es multiplicar la señal transmitida.
- 4) Cada neurona aplica una función de activación (generalmente no lineal, como más adelante se describirá) a su entrada con el objetivo de determinar su señal de salida.

Una red neuronal se caracteriza por estos tres elementos o características:

- 1) La topología de conexiones entre neuronas, lo que recibe el nombre de *arquitectura* de la red.
- 2) El método de determinación de los pesos sobre las conexiones, denominado *algoritmo de entrenamiento* o de *aprendizaje*.
- 3) La *función de activación* que tengan sus neuronas.

Para comprender un poco mejor por qué estos modelos matemáticos para procesamiento de la información reciben el nombre de redes neuronales, se hará un breve repaso sobre el funcionamiento de la red neuronal real de un sistema biológico y posteriormente se analizará la estructura de una RNA, comparándola con la anterior [21].

2.2.2.- Modelo biológico. Simplificación.

La maquinaria del sistema nervioso puede comprenderse a varios niveles, que van desde las propiedades de las células individuales hasta las macrocaracterísticas de encéfalo entero.

A gran escala, una de las divisiones más generales del sistema nervioso es la separación en *sistema nervioso central*, que hace referencia a la médula espinal y el encéfalo (parte del sistema nervioso alojada dentro de la cavidad craneal), y *sistema nervioso periférico*, que incluye todas las partes del sistema nervioso fuera de las estructuras óseas que forman el cráneo y la columna vertebral, entre las cuales se encuentran las ramificaciones nerviosas que transmiten información a los distintos órganos.

El encéfalo, masa gelatinosa de aproximadamente 1.400 gramos, de forma plegada y contorsionada, básicamente está dividido en dos hemisferios cerebrales claramente visibles. Cortado de forma horizontal o transversal se observan dos tonalidades que ponen de manifiesto su estructura celular. Una tonalidad oscura, denominada sustancia gris, denota áreas próximas a la superficie ricas en cuerpos de

células nerviosas. Otra tonalidad clara, denominada sustancia blanca, forma áreas compuestas de las ramificaciones de estas células, generalmente axones, que sirven de vías de comunicación.

Estas células nerviosas, llamadas *neuronas*, son las unidades básicas del sistema nervioso, junto con otras células de soporte. Están separadas estructural, metabólica y funcionalmente, y se observa en ellas una gran variedad de tamaños y formas. Forman redes entretejidas muy elaboradas, cuyas funciones varían en diferentes regiones del encéfalo. Estas diferencias de formas y tamaños reflejan la forma en que las neuronas procesan la información. Debe tenerse en cuenta que más que simples relevos que transmiten la información recibida, las neuronas típicas recogen señales de varias fuentes, las cuales integran y transforman, codificándolas en complejas señales de salida que distribuyen a un gran número de otras células.

Aunque esta diversidad estructural complica la tarea de modelización, existen simplificaciones que se pueden usar para comprender y explicar las propiedades estructurales fundamentales de estas células nerviosas.

La mayoría de los tipos de neuronas tienen tres partes estructurales diferenciadas, relacionadas con las propiedades funcionales de las mismas: el *cuerpo celular*, las *dendritas* y el *axón*. De forma esquemática, se puede decir que el cuerpo celular es el centro de síntesis de la célula, donde procesa las señales que en forma de impulsos le llegan de otras células, generando a su vez un nuevo impulso si se cumplen ciertas condiciones. Del cuerpo celular emana una fibra principal, el axón, y varias ramas fibrosas, las dendritas. El axón actúa como canal transmisor de los impulsos generados por la célula, y frecuentemente se ramifica tanto en su punto de partida, como en su extremo. Conecta con las células de destino a través de las dendritas de éstas, que actúan como canales receptores de información. Esta conexión se realiza por medio de uniones especiales denominadas *sinapsis*. La transmisión de un lado a otro de estas uniones es de naturaleza química (neurotransmisores) aportada por el axón y recibida por las dendritas. Esta eficiencia sináptica es la que resulta modificada cuando se dice que el cerebro aprende. Puede decirse que las sinapsis, combinadas con el proceso de información de la neurona, forman el mecanismo básico de la memoria.

Esta visión de la estructura de la neurona puede parecer en exceso simplificada e incluso parcial, sin embargo basta para entender la base biológica de las redes

neuronales artificiales, al menos en lo que respecta a los modelos comúnmente estudiados. El proceso de información en las neuronas puede exponerse también de forma simplificada.

Las neuronas en estado de inactividad presentan en su interior un potencial de reposo o potencial de membrana de aproximadamente -70 mv, es decir, el interior es eléctricamente negativo respecto al exterior. Si se aplica un estímulo despolarizador (reducción del potencial de la membrana) la respuesta de ésta consiste en algunos pequeños cambios despolarizadores con alguna distorsión. Sin embargo cuando el estímulo despolarizador alcanza el nivel de $10-15$ mv se provoca una respuesta breve y rápida (0.5 a 2 mseg de hasta 50 mv) conocida como *potencial de acción* o *impulso nervioso*, es decir, la intensidad del estímulo ha sido suficiente para excitarlo. El hecho de aumentar aún más la estimulación despolarizadora no implica un aumento del potencial de acción. Esto es conocido como la *ley de todo o nada del impulso nervioso*. Éste es propagado a través del axón, a una velocidad que oscila entre 5 m/seg y 120 m/seg dependiendo del diámetro del axón, en forma de reacción en cadena, manteniéndose una magnitud uniforme a medida que avanza. Su llegada a la hendidura sináptica provoca la excitación de fenómenos eléctricos al otro lado de la sinapsis denominados *potenciales postsinápticos*.

Aunque las neuronas propagan un solo tipo de señal, los potenciales postsinápticos locales pueden mostrar polaridades opuestas. Esto significa que una neurona recibe potenciales excitatorios e inhibitorios procedentes de diversas sinapsis. Por lo general la neurona combina el efecto de estos potenciales en forma de sumas y restas para excitar el potencial de todo o nada, desencadenando un impulso nervioso sólo si la combinación de estos potenciales supera el umbral.

Existen otras características importantes del proceso de información a tener en cuenta para comprender algunos conceptos en RNA que se citan a continuación.

Queda evidenciado por medio de la hendidura sináptica que las neuronas son unidades independientes. En éstas, la transmisión va desde los terminales presinápticos, hasta las células postsinápticas, pero no en dirección contraria. Por otra parte el axón también conduce el impulso normalmente en una sola dirección.

Se ha de tener en cuenta además, que los potenciales postsinápticos producidos por la acción de sustancias químicas transmisoras en la sinapsis tras la llegada a ésta de

un impulso nervioso presináptico, se difunden pasivamente sobre la neurona desde sus puntos de origen en las dendritas y en el cuerpo celular, de modo que va disminuyendo su efecto al avanzar. La neurona suma los potenciales postsinápticos del mismo signo y resta los inhibitorios de los excitatorios. Esta suma de potenciales en el cuerpo celular se denomina *sumación espacial*.

La sumación también puede tener lugar entre efectos postsinápticos no simultáneos, puesto que éstos actúan unos cuantos milisegundos. Cuanto más cerca estén en el tiempo, mayor será el solapamiento y más completa la sumación. Esta sumación es conocida como *sumación temporal*. Incluso impulsos sucesivos que lleguen al mismo terminal pueden producir efectos postsinápticos que se sumen.

2.2.3.- Redes Neuronales Artificiales

Según la estructura descrita anteriormente se han ideado modelos de neuronas bastante sencillos pero altamente interconectados, formando redes que trabajan paralela y asincrónamente. No obstante no se debe olvidar que un rasgo típico de la modelización es la extracción de características importantes.

Simplificando, se puede decir que la función básica de una neurona es sumar sus entradas y producir una salida si la suma es mayor que un umbral determinado. El tipo (excitatorio o inhibitorio) y la efectividad de estas entradas, es función de la cantidad de señal recibida en las sinapsis, así como el tipo de éstas. La conexión de varias neuronas forma lo que comúnmente se denomina una red de neuronas.

En una red neuronal artificial, la unidad básica, análoga a la neurona biológica se denomina comúnmente *elemento de proceso (EP)*.

En la actualidad, distintos modelos de redes utilizan también distintos modelos de elementos de proceso; sin embargo, se puede establecer un marco general que los describa.

Básicamente, un elemento de proceso en un momento dado tiene un *valor de activación* propio $a_i(t)$, el cual se pasa a través de una función $f[a_i(t)]$ para producir un *valor de salida* $s_i(t)$.

En cada conexión de entrada existe un número denominado *peso* o *fuerza* de la conexión w_{ij} , que determina el efecto cuantitativo de unas unidades sobre otras, y que corresponde a las sinapsis biológicas. Estas entradas ponderadas, por regla general, se

combinan mediante la adición, obteniéndose la *entrada neta* al elemento de proceso e_i , que junto con el valor actual de activación $a_i(t)$, y mediante una función $a_i(t) = F_i[a_i(t-1), e_i(t)]$, servirá para determinar el nuevo valor de activación de la unidad. (Véase la figura 2.1).




Figura 2.1 Modelo genérico de neurona artificial

El conjunto de los valores de activación de los elementos de proceso de una red, indica lo que ésta representa en un momento dado. Estos valores de activación pueden ser continuos, tomando valores reales cualesquiera o valores dentro de un intervalo cerrado; también pueden ser discretos, tomando valores binarios generalmente.

Tanto la función de salida $f_i()$ como la función de activación $F_i()$, pueden tomar distintas formas como, por ejemplo, la función identidad, funciones estocásticas, o muy a menudo las denominas funciones sigmoidales que se describirán más adelante.

El patrón de conexiones W es donde reside la información modificable de una red compuesta de elementos de proceso interconectados, y mediante este patrón se determinará su respuesta ante una entrada concreta. Se define generalmente mediante una matriz de pesos, en la que la entrada w_{ij} representa la intensidad y sentido de la conexión del elemento de proceso EP_j al EP_i . Si w_{ij} es positivo representará una conexión excitatoria y si es negativo una conexión inhibitoria. Su valor absoluto representará la fuerza de la conexión.

Particularizando, se puede decir que el modelo de elemento de proceso más sencillo es el utilizado en los sistemas simplemente lineales. En estos sistemas de proceso, la función de salida $f_i()$, es una función identidad, de tal forma que el valor de

salida se corresponde con el valor de activación de la unidad, $s_i(t) = a_i(t)$. El nuevo valor de activación es igual a la entrada neta de la unidad, $a_i(t) = e_i(t)$, siendo éste un número real sin restricción.

Sin embargo, el modelo de elemento de proceso más común es el modelo de *umbral lineal*. En éste, el valor de activación generalmente toma los valores 0 ó 1, siendo 1 si la entrada neta $e_i(t)$ es mayor que algún valor umbral θ_i y 0 en otro caso. La función de salida, $f_i()$, es la función de identidad, de modo que $s_i(t) = a_i(t)$.

Matemáticamente es posible formular este modelo umbral considerando sus entradas como un vector $(a_1, a_2, \dots, a_n)$ con un vector de pesos asociados $(w_1, w_2, \dots, w_n)$ y calculando la entrada neta de la neurona como $\sum a_i \cdot w_i$, la cual es comparada con el valor umbral, θ , para obtener el nuevo estado de activación. Por último cabe mencionar que existe otro conjunto de funciones importantes que pertenecen a la familia de las denominadas sigmoidales. Por ejemplo, un tipo de función sigmoidal, muy utilizada es la siguiente:

$$f(x) = 1 / (1 + e^{-x}).$$

Los elementos de proceso descritos, por sí solos no son demasiado interesantes; sin embargo, lo que sí resulta realmente interesante es la funcionalidad que resulta de la conexión entre varios de éstos formando redes.

Una red neuronal artificial consiste en varios elementos de proceso conectados de alguna forma, generalmente organizados en grupos denominados *capas*.

En toda red neuronal existen dos capas típicas, que tienen conexión con el exterior; éstas son la *capa de entrada*, a través de la cual los datos son presentados a la red, y la *capa de salida*, la cual muestra la respuesta de la red a una entrada dada. El resto de las capas existentes entre estas dos se denominan *capas ocultas*.

Las RNAs, al igual que las redes de neuronas biológicas, almacenan la información en los pesos asociados a las conexiones entre elementos de proceso. Podría decirse que una red diseñada para un fin específico, consta de un número determinado de elementos de proceso conectados en una estructura concreta y adecuada a tal fin, de unos pesos generalmente fijos en las conexiones entre estos elementos de proceso, y de una dinámica de funcionamiento que permita a la red obtener la salida deseada a una entrada dada.

Esto hace que se pueda estudiar las características principales de una RNA atendiendo a su topología (estructura de la red), su ley de aprendizaje (determinación de los pesos adecuados) y a su dinámica de funcionamiento, además de otras características.

Respecto a la topología de las RNA, la forma simplificada de una red no contiene conexiones hacia atrás (“feedback”) de unas capas hacia otras, conexiones dentro de la misma capa, ni de un elemento de proceso a sí mismo. Estas redes son llamadas comúnmente *redes alimentadas hacia adelante* o *redes feed-forward*. En este caso, la información pasa de la capa de entrada a través de las capas ocultas hasta la capa de salida de una forma sencilla, usando la suma y la función de activación de la red en particular. A pesar de que su flujo de información es simple, estas redes son interesantes a causa de la no-linealidad en sus transformaciones.

En otras redes, se usa una cierta cantidad de retroalimentación para dar a la red un cierto carácter temporal, o dicho de otra forma, hacer que sea sensible al tiempo. Si existe retroalimentación, la información reverberará alrededor de la red a través de las capas, o dentro de ellas, hasta que se alcance algún criterio de convergencia, momento en el que la información se pasa a la salida.

Actualmente, en distintos modelos de redes coexisten distintos tipos de conexiones llegando en ocasiones a una interconexión total.

Una característica importante de las RNAs es la forma en que almacenan información. La memoria de estas redes es distribuida. Los pesos de las conexiones son las unidades de memoria de la red, y los valores de dichos pesos representan su estado actual de conocimiento. Una unidad de información, representada por un par entrada / salida deseada, es distribuida a través de muchas unidades de memoria en la red y comparte éstas con muchas otras unidades de conocimiento almacenadas en la misma.

El proceso para almacenar la información en los pesos de las conexiones viene dado por lo que comúnmente se conoce como *aprendizaje*. Al contrario de los sistemas expertos donde el conocimiento se da explícitamente por medio de reglas, las RNAs generan su propio conocimiento aprendiendo de ejemplos que le son mostrados. El aprendizaje se consigue a través de reglas que adaptan o cambian los pesos de las conexiones de la red en respuesta a los ejemplos de entrada dados y, opcionalmente, a la salida deseada para esas entradas.

Si la salida deseada es suministrada a la red por un entrenador, se dice que el *aprendizaje es supervisado*. En este caso, para cada estímulo de entrada, se le presenta a la red un estímulo de salida deseado, y ésta se configura a sí misma gradualmente para almacenar la correspondencia entrada / salida deseada.

Por el contrario, si a la red no se le muestra la salida deseada, el aprendizaje se denomina *aprendizaje no supervisado*. En este caso, solamente los estímulos de entrada son mostrados a la red la cual se organiza a sí misma internamente de tal forma que cada elemento de proceso oculto responde muy activamente o muy débilmente a un grupo de estímulos de entrada. Este grupo de estímulos se representa mediante conjuntos en el espacio de entrada, que corresponden a distintos conceptos del mundo real.

Existe un tercer tipo de aprendizaje denominado *aprendizaje por refuerzo*, en el cual un entrenador externo proporciona información parcial a la red, indicando únicamente si su respuesta a una entrada es buena o mala.

Cualquiera que sea el aprendizaje usado, una característica esencial de la red es la *regla de aprendizaje*, la cual indica cómo adaptar los pesos de las conexiones para aprender un ejemplo dado. Por ejemplo, para el modelo de RNA que se utilizará en este proyecto esa regla de aprendizaje (que será explicada y detallada posteriormente) se traduce en el llamado algoritmo de retropropagación (*backpropagation*).

2.2.4.- Breve historia de las redes neuronales artificiales

En la mitad de los años 50, Frank Rosenblatt [22] construyó un modelo computacional para la retina, al que llamó Perceptrón. Este trabajo estuvo inspirado por los trabajos de McCulloch y Pitts [23], y Donald O. Hebb [24]. En 1.949 Hebb describió un método por el que las neuronas podían aprender: cuando la entrada desde la sinapsis a la neurona y la salida de ésta eran ambas activas, entonces se reforzaba la fuerza sináptica de la conexión. Para entonces McCulloch (neurofisiólogo) y Pitts (matemático) ya habían publicado en 1.943 [23] un artículo donde exponían la creación de un modelo abstracto de neurona, en el que la probabilidad de que una neurona se activase, dependía de la señal de entrada a ésta y de la sinapsis de conexión. Describieron de esta forma la actividad de la neurona como un álgebra de Boole

multiestado. Un caso especial de este álgebra (biestado) fue generalizado más tarde por Von Neumann en lo que fue la base de los computadores digitales.

En 1951 Minsky y Edmons construyeron una máquina capaz de aprender, compuesta de tubos, motores y otros dispositivos mecánicos. Esta máquina basada en las ideas de McCulloch y Pitts, podía aprender lo suficiente como para mover un dispositivo, lo cual fue un gran avance en su tiempo.

Después de esa experiencia Minsky dio un giro, centrando su interés en la construcción de programas que modelaran los principios de la mente y resolvieran problemas, más que en la construcción de modelos sobre los mecanismos del sistema nervioso a bajo nivel.

Organizada por Minsky, McCarthy, Rochester y Shannon, y bajo el patrocinio de la fundación Rockefeller, en 1956 se celebró la primera conferencia sobre inteligencia artificial.

Esta conferencia inspiró una actividad que se desarrolló en dos frentes; por una parte el desarrollo de programas que pudiesen realizar tareas descritas como inteligentes, desde la visión del cerebro como una caja negra; por otro lado el desarrollo de máquinas que usaran modelos de los mecanismos del cerebro, para llegar a tener un cierto grado de inteligencia.

Rochester, de IBM, presentó un modelo de red neuronal que había construido. Usando varios cientos de neuronas simuladas e interconectadas, Rochester construyó un sistema para explorar como respondería una red a estímulos de su entorno. Los resultados de este modelo fueron series de datos numéricos generados por la red, los cuales Rochester no sabía aún como interpretar. Esta es considerada por muchos autores como la primera simulación conocida de red neuronal.

En este ambiente, Rosenblatt desarrolló su concepto de Perceptrón. Era un sistema de clasificación de patrones que podía interpretar patrones tanto abstractos como geométricos. El primer perceptrón era capaz de algún aprendizaje y sus operaciones solamente se degradaban después de dañar significativamente el sistema; además poseía una gran plasticidad, pudiendo ser entrenado sin errores después de que algunas células habían sido destruidas. En definitiva, el perceptrón era capaz de realizar generalizaciones limitadas y clasificar patrones a pesar de ruidos en la entrada.

El perceptrón fue primeramente aplicado al reconocimiento óptico de patrones. Una malla de 400 fotocélulas, que correspondían a las neuronas de más alto nivel de la retina, recibía los estímulos ópticos primarios. Estas fotocélulas eran conectadas a una unidad de asociación que combinaba los impulsos eléctricos procedentes de las fotocélulas. Las conexiones entre las fotocélulas y el asociador eran establecidas al azar. Si la entrada procedente de las células excedía cierto umbral, la unidad de asociación producía una salida.

Por otro lado, encabezados por Minsky, otro grupo de investigadores basaba sus esfuerzos en el empleo de la lógica deductiva para la resolución de problemas. Tenían como objetivo desarrollar programas que pudiesen aprender estos principios y entonces aplicarlos para resolver los problemas. Algunos aseguran que hubo una fuerte rivalidad entre los dos grupos en aquellos años.

A principio de los años 60, Hoff, estudiante de la universidad de Stanford, bajo la tutela de Widrow, desarrolló un modelo llamado Adaline, probando que éste era capaz de clasificar un espacio de entrada en dos regiones linealmente separables.

A finales de los 60 Minsky y Papert [25], publicaron un libro sobre el perceptrón, en el cual demostraron la aplicación del teorema de la separación lineal en el perceptrón, y concluían que éste no era capaz de ejecutar operaciones sencillas como la función lógica O-exclusiva (XOR), lo cual limitaba su interés. Sin embargo, por otra parte, puntualizaron que una red de un perceptrón con varias capas podía resolver el problema de la XOR, pero no se conocía un mecanismo que pudiese entrenar la red para configurar los pesos correspondientes cuando la salida de la misma era incorrecta; esto fue conocido como el problema de la asignación de créditos.

La incapacidad de un perceptrón con una sola capa para realizar tareas interesantes, y el problema de la asignación de créditos en el perceptrón multicapa, llevaron a concluir a Minsky y a Papert que las investigaciones sobre éstos tenían escaso valor.

Estas conclusiones provocaron que el interés de los investigadores de todo el mundo por el campo de las redes neuronales se desvaneciera repentinamente.

Sin embargo, Rosenblatt, continuó sus estudios sobre el sistema nervioso y más concretamente sobre el sistema visual con la esperanza de encontrar una respuesta a los problemas aducidos por Minsky y Papert. Pero sus estudios se vieron truncados por un

accidente de barco que le causó la muerte, dos años después de la publicación del libro sobre el perceptrón.

A pesar de este suceso y las críticas realizadas por Minsky y Papert, algunos investigadores continuaron su trabajo en este campo; entre ellos se encontraba Anderson, que focalizó su trabajo en el desarrollo de un modelo llamado asociador lineal, basado en los modelos de almacenamiento y recuperación de la memoria [26,27]. El asociador lineal es un modelo de asociación distribuida basado en los principios de Hebb sobre las conexiones entre neuronas, y su reforzamiento cada vez que eran activadas. Anderson desarrolló además una extensión del asociador lineal, el modelo BSB (Brain State in a Box).

A finales de los sesenta ya se apuntaba como solución a las limitaciones del perceptrón introducir capas ocultas, pero el problema residía en que si bien se disponía de un algoritmo de aprendizaje para el perceptrón simple (el denominado algoritmo del perceptrón), no se disponía de ningún procedimiento que permitiese obtener automáticamente los pesos en una multicapa, con neuronas ocultas (problema de “asignación de crédito”). Este problema fue resuelto no mucho más tarde por Paul Werbos [28]. Es precisamente este investigador quien desarrolló una teoría importante para la implementación de un algoritmo eficiente para entrenamiento de redes neuronales.

Kohonen en la Universidad de Helsinki, realizó un trabajo fundamental en el aprendizaje competitivo y las memorias adaptativas desde principio de los 70 [29]. Fue responsable de la descripción y análisis de una gran cantidad de reglas de adaptación local, reglas en las que los pesos eran modificados únicamente de forma dependiente de los valores anteriores de los mismos, y del estado post y presináptico. Otra contribución de Kohonen fue el principio de aprendizaje competitivo, en el que los elementos de proceso compiten para responder a estímulos de entrada y el vencedor se autoadapta para responder más activamente a esos estímulos. Este aprendizaje es no supervisado.

Otro investigador que también continuó sus investigaciones en la computación neuronal, a pesar del trabajo de Minsky y Papert, fue Grossberg [30]. Grossberg estaba especialmente interesado en usar datos procedentes de la neurobiología para construir modelos computacionales. Empleó mucho tiempo desarrollando mecanismos neuronales inspirado en la percepción y la memoria. Traslado las reglas de asociación

de los modelos sinápticos a ecuaciones explícitas. La mayoría de sus reglas formales y postulados derivaron de sus estudios fisiológicos.

Grossberg ha contribuido a enriquecer las investigaciones sobre el diseño y la construcción de modelos neuronales. En su sistema las unidades básicas pueden tomar un valor de activación real comprendido entre un máximo y un mínimo. La función de salida queda establecida como una función sigmoide. Este tipo de redes ha sido empleado para el desarrollo de su Teoría de la Resonancia Adaptativa (TAR).

En 1982 Hopfield [31] presentó un trabajo en la Academia Nacional de Ciencias estadounidense. Este fue el primer trabajo en computación neuronal presentado a esta distinguida comunidad científica desde 1960. La alta consideración que tenía de Hopfield la comunidad científica, mezclada con el carisma y el entusiasmo de éste, legitimaron el nuevo interés por la computación neuronal. Su trabajo describía un sistema que se ha dado en llamar el Modelo de Hopfield. Usando investigaciones basadas en sistemas olfativos, Hopfield presentó un sistema constituido por elementos de proceso totalmente interconectados que buscaba un estado de mínima energía. De hecho el mecanismo de respuesta y la función de energía de esta red era un caso especial de la clase general de redes considerada por Grossberg. El entusiasmo de Hopfield y la claridad de su presentación fueron muy bien recibidos y se produjo de nuevo interés por parte de los científicos en el fascinante campo de las redes neuronales.

Por último cabe mencionar los estudios de Rumelhart. Este investigador trabajó junto a McClelland, y estaban interesados en la aplicación de las redes neuronales para la comprensión de funciones mentales [32]. Formaron uno de los grupos de investigación más importantes de los últimos años llamado PDP (Parallel Distributed Processing).

2.2.5.- Usos de las redes neuronales artificiales

Actualmente las redes neuronales han encontrado aplicación en multitud de campos de la ciencia y la ingeniería que van desde el tratamiento de señales hasta los negocios. Se puede afirmar que las redes neuronales son una buena alternativa a gran número de métodos que se aplican en numerosos campos. En la mayoría de los casos, incluso para problemas que se han resuelto por otros medios y gracias a diferentes teorías, las redes neuronales han encontrado a su vez, otras formas de resolución más eficientes.

Con la idea de hacer un breve repaso de las principales aplicaciones en las que se han empleado las RNAs se describen en los próximos apartados diferentes campos en los dichas redes se han utilizado.

Tratamiento de señal

En el campo del tratamiento de señal las RNAs han sido aplicadas con gran éxito. Como ejemplo específico se describe a continuación una aplicación en concreto que es el tratamiento de señales sonar. Las señales de sonar son energía acústica transmitida a través del agua. Hay ciertas características que marcan la dificultad de construcción de un sistema de tratamiento de señales sonar. La primera es el ruido con el que se suelen recibir dichas señales, en las que se llegan a alcanzar relaciones señal/ruido de -15 dB (ruido 32 veces más potente que la señal). Otro problema es la diferencia de camino que puede recorrer la señal debido a las diferentes salinidades del agua, profundidad, temperatura, etc. Esto provoca grandes interferencias en la señal. Por último, para aumentar la complejidad del problema, los sistemas de tratamiento de sonar deben manejar un amplio ancho de banda.

Los sistemas de tratamiento de señales sonar suelen constar de cuatro procesos secuenciales: eliminación del ruido, extracción de características, detección y clasificación. Todos estos procesos han sido tratados, bien con distintos tipos de redes neuronales para cada proceso independientemente, o bien una sola red que realiza varios de esos procesos simultáneamente como, por ejemplo, eliminar el ruido y extraer las características.

Las redes empleadas han sido de diferentes tipos. Así para la cancelación de ruido se han creado los llamados filtros neuronales formados por redes neuronales del tipo ADALINE [33]. En cuanto a la clasificación de la señal recibida encontramos redes neuronales probabilísticas para la clasificación de objetos en naves de superficie o submarinos, memorias asociativas para la detección y seguimiento de submarinos, dos redes neuronales combinadas para determinar la distancia y profundidad de los objetos, redes bajo perceptrón multicapa para discriminación de rocas/minas, etc.

Compresión de datos

El principal objetivo de las técnicas de compresión de datos y de reducción de la dimensión es el de disminuir el tamaño de la representación de los datos con la mínima pérdida de información. Este proceso ofrece grandes ventajas en cuanto a

almacenamiento, transmisión y procesamiento de la información se refiere, ya que mediante la compresión se produce un ahorro de recursos importante.

Una técnica bien establecida de análisis y reducción de la dimensionalidad de datos es el análisis de componentes principales (PCA: Principal Component Analysis. Duda 1.973 [34]). Esta técnica proyecta los datos de entrada en un subespacio lineal con mínima pérdida de información. La magnitud de los autovalores de la matriz de covarianza de la muestra proporciona una estimación de la mínima dimensión del subespacio al que los datos pueden ser proyectados, así como la información perdida en esta operación. La representación reducida se obtiene multiplicando los datos por los autovectores correspondientes a los autovalores seleccionados. Esta transformación es óptima desde el punto de vista de la energía contenida por el error.

Dentro de las técnicas de compresión de datos mediante redes neuronales se puede hacer mención especial de las técnicas de compresión de imágenes. Este campo encuentra su principal motivación en el gran tamaño que, en general, poseen las imágenes digitalizadas. También en este caso la aplicación de RNAs es de gran utilidad y aplicabilidad.

Medicina

En el campo de la medicina las RNA también han encontrado aplicación. Un ejemplo concreto es el diagnóstico de infarto de miocardio. Esta enfermedad es de difícil diagnóstico. Prueba de ello es el porcentaje de acierto en los diagnósticos, que es de un 88 %, y el de falsas alarmas que es de un 29 %. Con técnicas clásicas como son la regresión logística, el análisis discriminante o cualquier otra técnica de clasificación tan sólo se ha llegado a mejorar el porcentaje de falsas alarmas rebajándolo hasta un 26 %. En 1.990 Baxt [35] propuso un modelo de RNA para resolver el problema. Los datos utilizados provenían del historial médico de 356 pacientes con dolor en el pecho. Los resultados obtenidos sobre el conjunto del test realizado fueron de un 92 % de acierto y de un 4 % de falsas alarmas.

Reconocimiento del Habla

Este es uno de los campos en los que las redes neuronales están jugando un papel más importante. Existen multitud de trabajos en los que las RNAs se han aplicado con éxito para el reconocimiento del habla. De entre todos estos trabajos se destacan a continuación los siguientes: en Huang [36] se combina un mapa de características

autoorganizado con un perceptrón multicapa para reconocer palabras aisladas. Waibel [37] aplica la técnica de redes neuronales con retardos temporales para el reconocimiento de algunos fonemas.

Aplicaciones económicas y empresariales

Sin duda el campo de aplicaciones económicas que ha recibido mayor interés es el financiero. La predicción financiera mediante RNA es abordada entre otros por White [38], quien utiliza una red *feed-forward* con un solo nivel intermedio, entrenada sobre 500 observaciones del precio diario de las acciones de IBM. En este caso los resultados son similares a otras técnicas de análisis financiero.

Otro problema es la selección de activos financieros. Este problema exige una ingente cantidad de recursos. Para este caso se han empleado redes borrosas que aprenden de forma supervisada.

La calificación del nivel de riesgo en las emisiones de bonos también ha sido tratada con RNA. En este caso los resultados obtenidos por las RNAs han sido superiores a los tradicionales, y comparables a los obtenidos por un calificador experto. Por último, existen diversas aplicaciones en las que se están incluyendo redes neuronales, como son la construcción de sistemas de información empresarial, los problemas de decisión multicriterio, las aplicaciones comerciales en compra-venta, etc.

Sistemas energéticos. Radiación solar

Las RNAs también han sido aplicadas con éxito en el campo de los sistemas energéticos y la radiación solar. Se han utilizado para modelar sistemas térmicos de vapor [39] o la predicción de medias mensuales de producción energética en dichos sistemas [40]. Asimismo se han empleado en sistemas de calor, ventilación y aire acondicionado. Por ejemplo Kalogirou [41] empleó RNAs en el cálculo de cargas calóricas de edificios, Kreider y Wang [42] las utilizaron RNAs para predecir el uso energético en edificios comerciales, Curtiss et al. [43] para la optimización del consumo energético a escala comercial o Kah et al. [44] para el sistema de aire acondicionado de un autobús. Otros ejemplos son los trabajos de Muller y Keller [45] en procesos de combustión en plantas incineradoras o Milanic y Karba [46] para el control predictivo de una planta térmica. Respecto a la predicción de series temporales de radiación, son interesantes los trabajos de Negnevitsky y Le [47] para determinar la irradiancia a escala horaria, Al-Alawi y Al-Hinai [48] proponen una red neuronal para calcular la

radiación global usando como parámetros de entrada diferentes variables meteorológicas como la presión atmosférica, la humedad relativa, la velocidad del viento, etc. Kemoku et al. [49] utilizan una red neuronal con varias etapas de cálculo para obtener secuencias diarias de radiación, suponiendo conocidas también algunas de las variables atmosféricas anteriormente mencionadas. Y para finalizar, merece la pena destacar los trabajos de Sfetsos y Coonick [50] o Mohandes [51, 52] también en el terreno de series solares.

Por último, procede citar otros muchos campos donde tienen gran utilidad las RNAs, como son el control de cualquier tipo de planta industrial o sistema dinámico, el reconocimiento de patrones, la producción de discursos, la identificación de estrellas, etc.

Referencias

- [1] S.A. Klein and W.A. Beckman, *TRNSYS- A transient simulation program*. ASHRAE Transactions **82**. 623. 1976.
- [2] B.J. Brinkworth. *Autocorrelation and stochastic modelling of insolation sequences*. Solar Energy. Vol. **19**. 1977.
- [3] A.H.C. van Paasen. *Indoor climate, outdoor climate and energy consumption*. Ph. D. Thesis. Delft University of Technology. Delft The Netherlands. 1981.
- [4] R.H.B. Exell. *A mathematical model for solar radiation in Southeast Asia (Thailand)*. Solar Energy **26**. 165-168. 1981.
- [5] L.Vergara-Domínguez et al. *Automatic modelling simulation of daily global solar radiation series*. Solar Energy **35(6)**. 483-489. 1985.
- [6] U. Amato et al. *Markov processes and Fourier analysis as a tool to describe and simulate daily solar irradiance*. Solar Energy **37**. 179-194. 1986.
- [7] B. Liu and R. Jordan. *The interrelationship and characteristics distribution of direct, diffuse and total solar radiation*. Solar Energy **4**. 1-19. 1960.
- [8] L. O. Dagelman. *A weather simulation model for building energy analysis*. ASHRAE Trans. Symposium on weather data. Seattle. WA. Annual Meeting. 453-447. 1976.
- [9] Bolieau E. *Use of simple statistical models in solar meteorology*. Solar Energy **30**. 333. 1983.
- [10] B. Bartoli et al. *Autocorrelation of daily global solar radiation*. Il nuovo cimento **40**. 1983.
- [11] V. A. Graham, K. G. T. Hollands and T. E. Unny. *A Time Series Model for Kt with Application to Global Synthetic Weather Generation*. Solar Energy, Vol. **40**, No. 3, pp. 269-279. 1988.
- [12] R. Aguiar, M. Collares-Pereira, J.P. Conde. *Simple procedure for generating sequences of daily radiation values using a library of Markov transition matrices*. Solar Energy Vol. **40** pp. 269-279. 1988.
- [13] T.Goh, K. Tan. *Stochastic modelling and forecasting of solar radiation data*. Solar Energy **19**. 1977.
- [14] C. Mustacchi, V. Cena and M. Rocchi. *Stochastic simulation of hourly global radiation sequences*. Solar. Energy **23**. 1979.

- [15] A. Balouktsis and Ph. Tsalides. *Stochastic simulation model of hourly total solar radiation*. Solar Energy **37**. 1986
- [16] Ll. Mora and M. Sidrach-de-Cardona. *Multiplicative ARMA models to generate hourly series of global irradiation*. Solar Energy Vol. **63**. pp. 283-291. 1998.
- [17] E. Palomo. *Hourly solar radiation time series as first-order Markov chains*. In Proceedings of the ISES Solar World Congress. Kobe (Japan). 1989.
- [18] V. A. Graham and K. G. T. Hollands. *A Method to Generate Synthetic Hourly Solar Radiation Globally*. Solar Energy, Vol. **44**, No. 6, pp. 333-341. 1990.
- [19] R. Aguiar and M. Collares-Pereira. *TAG: A Time-Dependent, Autorregressive, Gaussian Model for Generating Synthetic Hourly Radiation*. Solar Energy, Vol. **49**, No. 3, pp. 167-174. 1992.
- [20] S. Haykin. *Neural Networks. A Comprehensive Foundation*. Macmillan Publishing Company, 1994.
- [21] Olmeda I. y Barba-Romero, S. *Redes neuronales artificiales. Fundamentos y aplicaciones*. Servicio de Publicaciones de la Universidad de Alcalá. 1993.
- [22] Rosenblatt R. *Principles of Neurodynamis*. Spartan Books, New York. 1959.
- [23] McCulloch WS., & Pitts W. *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics. Vol. **5**. pp 115-133. 1943.
- [24] Hebb D.O. *The organisation of behaviour*. John Wiley & Sons. New York. 1949.
- [25] Minsky M & Papert S. *Perceptrons: an introduction to computacional geometry*. The MIT Press. Cambridge, MA. 1969.
- [26] Anderson J.A. *Two models for memory organisation using interacting traces*. Mathematical Biosciences, vol **26**. pp. 175-185. 1970.
- [27] Anderson J.A. *A theory for the recognition of items from short memorised list*. Psychological Review. Vol **80**. pp. 137-160. 1973.
- [28] P. Werbos. *Beyond Regression: New Tools for Predicting and Analysis in the Behavioural Sciences*, Ph. D. thesis, Harvard University. 1974.
- [29] Kohonen T. *Associative memory: a system theoretical approach*. Springer Verlag, New York, 1977.
- [30] Grossberg S. *Adaptive pattern classification and universal recording. Part I Parallel development and coding of neural feature detectors*. Biological Cybernetics. vol **23** pp 12-134. 1976.

- [31] Hopfield JJ. *Neural networks and physical systems with emergent collective computational abilities*. Proc. of the National Academy of Science. USA vol **79**. pp. 2554-2558. 1982.
- [32] Rumelhart, D. Hinton G. & Williams R. *Learning internal representations by error propagation*. Parallel distributed processing: Explorations in the microstructure of cognition. vol. **1**. Foundations. The MIT Press. Cambridge. Rumelhart and McClelland (eds.). 1986.
- [33] Widrow B. et al. *Adaptive noise cancelling: principles and applications*. Proc. of the IEEE vol **63** pp. 1692-1716. 1975.
- [34] Duda R. & Hart P. *Pattern classification and scene analysis*. John Wiley & Sons. 1973.
- [35] Baxt W.G. *Use of an artificial neural network for data analysis in clinical decision making: the diagnosis of acute coronary occlusion*. Neural Computation, vol **4**. pp. 480-489.
- [36] Huang Z & Kuh A. *A combined self-organising feature map and multilayer perceptron for isolated word recognition*. IEEE Trans. on signal processing. Vol **40**. pp 2651-2657.
- [37] Waibel A et al. *Phoneme recognition using time delay neural networks*. IEEE Trans Acoust. Speech Signal Processing. Vol **37**. pp. 328-339. 1989.
- [38] White H. *Economic prediction using neural networks. the case of IBM daily stock returns*. Proc. of the IEEE International Joint Conference on Neural Networks. San Diego CA. 1988.
- [39] Kalogirou SA, Panteliou S, Dentsoras A. *Modelling of solar domestic water heating systems using artificial neural networks*. Solar Energy **65**(6):335–42. 1996.
- [40] Kalogirou SA, Panteliou S, Dentsoras A. *Artificial neural networks used for the performance prediction of a thermosyphon solar water heater*. Renewable Energy **18**(1) : 87–99. 1999.
- [41] Kalogirou SA. *Forced circulation solar domestic water heating systems long-term performance prediction using artificial neural networks*. Applied Energy **66**(1): 63–74. 2000.
- [42] Kreider JF., Wang XA. *Artificial neural network demonstration for automated generation of energy use predictors for commercial buildings*. In: Hgarberl JS, Nelson

- RM, Culp CC, editors. The use of artificial intelligence in building systems. ASHRAE, p.193-198. 1995.
- [43] Curtiss PS, Brandemuehl MJ., Kreider JF. *Energy management in central HVAC plants using neural networks*. In: Hgarberl JS, Nelson RM, Culp CC, editors. The use of artificial intelligence in building systems. ASHRAE, p.199-216. 1995.
- [44] Kah AH, San QY, Guan SC, Kiat WC, Koh YC. *Smart air conditioning system using multilayer perceptron neural network with a modular approach*. In Proc of the IEEE Int Conf ICNN'95, Perth, Western Australia, Vol. 5 pp. 2314-2319. 1995.
- [45] Muller B, Keller H. *Neural networks for combustion process modelling*. In Proc of the Int Conf EANN'96 London, UK. p. 87-90. 1996.
- [46] Milanic & Karba. *Reinforcement learning neural networks and PI control applied to heating coil*. In Proc of the Int EANN'96 London, UK. p. 151-154. 1996.
- [47] Negnevitsky M, Le TL. *Artificial neural networks application for current rating of overhead lines*. In: IEEE Transactions on Neural Networks, 418–22. 1995.
- [48] Alawi SM, Hinai HA. *An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation*. Renewable Energy **14** (1-4):199–204. 1998.
- [49] Kemmoku Y, Orita S., Nakagawa S. and Skakibara T. *Daily insolation forecasting using a multistage neural network*. Solar Energy Vol **66**. N° 3 p. 193-199. 1999.
- [50] Sfetsos A. and Coonick H. *Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques*. Solar Energy Vol **68**. N° 2 p. 169-178.
- [51] Mohandes M, Balchonaim A., Kassas Rehman S, Halawani TO. *Estimation of global solar radiation using artificial neural networks*. Renewable Energy **14** (1-4):179–84. 1998.
- [52] Mohandes M, Balchonaim A., Kassas Rehman S, Halawani TO. *Use of radial basis functions for estimating monthly mean daily solar radiation*. 2000. Solar Energy Vol. **68**. N° 2 p. 161-168. 2000.