



**ESTUDIO DE LA RADIACIÓN NETA EN ZONAS SEMIÁRIDAS  
UTILIZANDO MODELOS LINEALES Y NEURONALES Y LA SINERGIA  
ENTRE GERB Y SEVIRI**

**Facultad de Física**  
**Departamento de Física de la Tierra y Termodinámica**



VNIVERSITATIS VALÈNCIAE

**ESTUDIO DE LA RADIACIÓN NETA EN ZONAS SEMIÁRIDAS  
UTILIZANDO MODELOS LINEALES Y NEURONALES Y LA SINERGIA  
ENTRE GERB Y SEVIRI**

**Memoria presentada por:**  
**ANTONIO GERALDO FERREIRA**  
**para optar al grado de Doctor en Física**

Ernesto López Baeza, Profesor Titular del Departamento de Física de la Tierra y Termodinámica de la Facultat de Física de la Universitat de València, y Emilio Soria Olivas, Profesor Titular del Departamento de Ingeniería Electrónica de la Escuela de Ingeniería de la Universitat de València,

CERTIFICAN: Que la presente Memoria titulada “*Estudio de la radiación neta en zonas semiáridas utilizando modelos lineales y neuronales y la sinergia entre GERB y SEVIRI*”, ha sido realizada bajo nuestra dirección en el Departamento de Física de la Tierra y Termodinámica de esta Facultad, por D. Antonio Geraldo Ferreira, y constituye su Tesis Doctoral para optar al grado de Doctor en Física.

Y para que así conste, en cumplimiento de la legislación vigente firmamos el presente certificado en Burjassot, a 30 de agosto de 2012.

  
Fdo.: Ernesto López Baeza

  
Fdo.: Emilio Soria Olivas

*A vida não é argumento – Armamos para nós um mundo, em que podemos viver – ao admitirmos, corpos, linhas, superfícies, causas e efeitos, movimento e repouso, forma e conteúdo: sem esses artigos de fé ninguém toleraria agora viver! Mas com isso ainda não são nada de demonstrado. A vida não é argumento; entre as condições da vida poderia estar o erro.*

*Nietzsche*

***Dedico***

*A Valencia, al sol, Alice y Gabriel, que, así como el sol, traen luz e alegría a mi vida.*

## Agradecimientos

De entre las personas que colaboraron directa o indirectamente para la ejecución y finalización de esta Tesis Doctoral, deseo agradecer:

En primer lugar a mis directores, Dr. Ernesto López Baeza y Dr. Emilio Soria Olivas, por la orientación, estímulo, amistad y apoyo a lo largo del camino. Ellos no midieron esfuerzos para que este proyecto llegase a su término. Ernesto, trabajador incansable y un gran divulgador de los temas relativos a los satélites, me abrió muchas puertas en el mundo de la teledetección y Emilio, también una máquina para trabajar, siempre comportándose como un verdadero *"Master Jedi"*. A ellos mi respeto, admiración y que la fuerza esté con ellos.

A Soledad Gandía Gomar, Directora del Departamento de Física de la Tierra y Termodinámica, durante el periodo que estuve en Valencia, por su amable acogida en el Departamento para la realización de mis estudios de doctorado. De modo cariñoso a María Pilar Utrillas Esteban e Isabel Ruiz Baselga, quienes siempre facilitaron todas las gestiones, ayudándome prontamente con la documentación necesaria.

A todos los profesores del Departamento de Física de la Tierra y Termodinámica, personas fascinantes, que han propiciado, además de la formación, un ambiente acogedor, de amistad y de estímulo durante mi estancia en Valencia. De modo especial al Dr. Joaquín Meliá Miralles, un profesor muy didáctico que, a pesar de no estar involucrado directamente en mi proyecto, siempre fue un buen consejero; muchas gracias por su interés, apoyo y por las conversaciones siempre muy agradables que tuvimos en su despacho.

A Alice, la persona más maravillosa y el corazón más puro que yo he conocido jamás, por acompañarme en esa jornada por la tierra de El Cid, Valencia, donde trabajamos juntos con nuestro hijo, Gabriel, las batallas del día a día, durante nuestros cursos de doctorado, y por auxiliarme en mi crecimiento individual como nadie jamás había hecho.

Agradezco también a Gabriel que por haber convivido conmigo y Alice nuestro día a día de doctorandos, acabó por interesarse por la ciencia y, además de ser un excelente estudiante, ya demuestra un espíritu investigador. Él, a pesar de ser un niño, llegó en Valencia con 8 años, también trabó sus batallas diarias para vencer sus miedos, adaptarse al idioma y a otra cultura que no es la suya. Hoy es una persona segura de sí mismo, y sabe que puede conquistar lo que quiera. Su estancia en España fomentó su espíritu de superación.

A los profesores de la carrera en Física de la UNESP de Rio Claro, Brasil, Alzira C.M. Stein-Barana, Dario Antonio Donatti, Benedito Renê Fischer, Deisy Piedade Munhoz, Edson José Vasques, Jorge Roberto Pimentel, José Roberto Campanha, Ligya de Moura Walmsley, Makoto Yoshida, Maria Cecília V. S. Carneiro, Roberto Hessel, Roberto Naves Domingos y Tadashi Yokoyama, que de una manera u otra dejaron su marca en mi vida, y me enseñaron y ayudaron a dar los primeros pasos para seguir en el mundo de la ciencia investigadora. A todos mi eterno respeto y admiración.

A mis compañeros del curso de doctorado y del día a día de la Universidad, y en Valencia, Alex, Almudena Monsoriu, Amparo, Ana, Aurelio, Carlos, Carol, Cecilia, Cristina, Diego, Javio, Juan Manuel, Manolo, Maria Mira, Sandra, Sara y Victor, por el incentivo, amistad y porque me hicieron sentir en casa, a pesar de estar en tierras lejanas. Agradezco de modo muy especial a Almudena Velázquez, la siempre AIG, por todos los trabajos que hicimos juntos; eres una fuera de serie. Mejores y más increíbles amigos yo no podría encontrar.

A Enrique y Amparo, de la Secretaría del Departamento de Física de la Tierra y Termodinámica, por la simpatía y eficiencia fuera de lo común, que siempre estaban disponibles para ayudar con una sonrisa en la cara.

Por fin, agradezco a mis padres, José Ferreira y Maria Aparecida, por el apoyo incondicional siempre que lo necesito, y mis hermanos, Elizabete, Fátima, Francisco Israel (*in memoriam*) y José Luiz que, a pesar de veros a todos muy poco, pues vivo lejos de ellos ya hace mucho tiempo (desde la carrera), los tendré siempre en mi corazón.

La realización de la presente Tesis Doctoral ha sido posible gracias a Francisco de Assis de Souza Filho y Eduardo Sávio Martins Passos, respectivamente, ex y actual Presidente de FUNCEME, por haberme liberado de mi trabajo para cursar el doctorado, y al programa Alβan (Programa de becas de alto nivel de la Unión Europea para América Latina), que me ha concedido la beca no. E05D058998BR. A las gestoras de la beca, Carla Ribero, Elimary Silva y Mónica Guedes mis sinceros agradecimientos. También agradezco a la Consellería de Medio Ambiente, Agua, Urbanismo y Vivienda de la Generalitat Valenciana (Dirección General para el Cambio Climático) por la concesión de la Beca de Colaboració (BC09-9) en el marco del Convenio “Estrategia Valenciana ante el Cambio Climático” y al Programa Nacional de Investigación sobre Espacio por aceptarme como miembro de los Proyectos MIDAS-4, MIDAS-5 y MIDAS-6 (Ernesto López Baeza, Investigador Principal).

## INDICE

LISTA DE FIGURAS .....	IV
LISTA DE TABELAS .....	XV
LISTA DE ACRÓNIMOS .....	XVIII

## CAPÍTULO

### **1**

#### **INTRODUCCIÓN Y OBJETIVOS**

1.1 - Introducción .....	27
1.2 - Objetivos .....	36

## CAPÍTULO

### **2**

#### **ÁREA DE ESTUDIO Y CAMPAÑAS DE CAMPO**

2.1 - Introducción .....	39
2.2 - Descripción y caracterización del área de estudio .....	39
2.2.1 - Área de la Valencia Anchor Station .....	39
2.2.2 - Orografía y usos del suelo .....	40
2.2.3 - Clima .....	42
2.3 - Campañas Experimentales .....	44
2.3.1 - IV Campaña SCALES .....	44
2.3.2 - Campaña FESEBAV-2007 .....	45
2.4 - Metodología de adquisición de los datos .....	46

## CAPÍTULO

### **3**

#### **MODELIZACIÓN DE LA RADIACIÓN NETA Y DEL FLUJO DE CALOR EN EL SUELO**

3.1 - Introducción .....	50
--------------------------	----

3.2 - El flujo de calor en el suelo .....	50
3.2.1 – Datos utilizados para estimar el flujo de calor en superficie .....	53
3.2.1.1 - Estudio estadístico y análisis de las series temporales .....	53
3.2.1.2 - Estimación del flujo de calor en superficie a partir de la radiación neta .....	65
3.3 - Modelos de estimación de la radiación neta en superficie .....	68
3.3.1 - Análisis mediante modelos neuronales .....	69
3.3.1.1 - El Modelo Perceptrón Multicapa (MLP) de Redes Neuronales .....	69
3.3.1.2 - Mapas Autoorganizados .....	73
3.3.1.3 - SOM en el análisis de la radiación neta .....	75
3.3.1.4 - Datos utilizados en el desarrollo del modelo propuesto .....	79
3.3.1.5 - Uso del Perceptrón Multicapa para la modelización de la radiación neta .....	80
3.4 - Uso de modelos lineales para la modelización de la radiación neta .....	85
3.5 - Comparación del modelo neuronal con los modelos lineales .....	89
3.6 - Estimación de la radiación neta a partir de parámetros meteorológicos .....	91
3.6.1 - Datos utilizados .....	91
3.6.2 - Modelo propuesto y resultados obtenidos .....	91
3.6.3 - Análisis de sensibilidad del modelo neuronal propuesto .....	95

## C A P Í T U L O

# 4

### SINERGIA ENTRE GERB Y SEVIRI PARA LA ESTIMACIÓN DE LA RADIACIÓN NETA

4.1 - Introducción .....	98
4.2 - Estimación de la temperatura de la superficie con SEVIRI .....	100
4.3 - Radiación neta en el techo de la atmósfera con GERB .....	106
4.4 - Estimación de la radiación neta en superficie a partir de GERB utilizando redes neuronales .....	109
4.4.1 - Datos utilizados en las fases de entrenamiento y validación del MLP .....	109
4.4.2 - Aplicación del Modelo MLP .....	111
4.4.3 - Estimación de la radiación neta en superficie a partir de GERB utilizando modelos lineales: Resultados y discusiones .....	113

**CONCLUSIONES Y TRABAJOS FUTUROS**

5.1 - Principales conclusiones técnicas extraídas del trabajo .....	130
5.2 - Extensiones para trabajos futuros .....	133
Bibliografía .....	134
Apéndice I - Descripción de los sensores SEVIRI y GERB .....	144
Apéndice II – Artículo “Characterization and Modelization of Surface Net Radiation Through Neural Networks” .....	156
Apéndice III – Artículo “Estimating net radiation at surface using artificial neural networks: a new approach” .....	175
Apéndice IV – Artículo “Modelling net radiation at surface using “in situ” netpyrradiometer measurements with artificial neural networks” .....	193

## LISTA DE FIGURAS

1.1 - Balance anual medio global de energía de la Tierra – Unidades: $Wm^{-2}$ Fuente: Trenberth <i>et al</i> (2008) .....	29
1.2 - (a) Diagrama esquemático de los flujos implicados en el balance de radiación de un sitio “ideal” (adaptado de Oke, 1987, p. 26), (b) balance de radiación observado en la <i>Valencia Anchor Station</i> (latitud 39° 34’ 15”N and longitud 1° 17’ 18” W – Plana de Utiel-Requena, España) bajo condiciones de cielo despejado el 7 de julio 2007 .....	30
1.3 - (a) radiómetro neto utilizado para medir el flujo de radiación neta en superficie, (b) <i>CNR1 Net radiometer</i> que tiene 2 piranómetros – sensor de la izquierda en (b) – utilizado para medir la radiación solar (incidente y reflejada) y 2 pirgeómetros – sensor de la derecha en (b) – utilizado para medir radiación de onda larga incidente desde el cielo y la emitida por la superficie .....	32
2.1 - a) Imagen del satélite <i>TERRA/MODIS</i> correspondiente al día 13 de febrero de 2009 con la localización geográfica de la <i>VAS</i> , y el área cercana donde se montaron los experimentos de campo de 2006 y 2007; (b) Imagen <i>Landsat-5</i> en falso color de la Plana de Utiel-Requena (01 de agosto de 2006) con la localización de la <i>VAS</i> y de la estación micrometeorológica móvil utilizada en la campaña de campo de 2007 (latitud 39°31’23” N y longitud 1°17’22” W); c) Fotografía aérea de la zona de la <i>VAS</i> adquirida en Junio de 2006 (Fuente: <i>Ground Data Processing &amp; Production of the High Resolution Biophysical Maps</i> – Ref.: EOLAB_09R01, Issue: 1.1 de 05/03/2009.); d) detalle de la <i>VAS</i> (latitud 39°34’15” N , longitud 1°17’18” W) .....	40
2.2 - Elevación del terreno de los alrededores de la <i>VAS</i> .....	41
2.3 - Usos y clasificación del suelo. Leyenda: 1-agua; 2-pinos; 3-baja	

	densidad de pinos y matorral; 4-matorral; 5-cultivos de regadío; 6-viñedos; 7-baja densidad de viñedos; 8-muy baja densidad de viñedos; 9-cultivos a base de hierbas; 10-suelo desnudo; 11- áreas urbanas. Imagen <i>LANDSAT 5</i> de 8 de julio de 2003, sobre el área de estudio ( <i>Valencia Anchor Station</i> – 50 km x 50 km). Fuente: Universidad Politécnica de Catalunya .....	41
2.4 -	Diagrama de las precipitaciones pluviométricas (media mensual y porcentaje de la media climatológica (1971 – 2006) anual) registradas en la estación meteorológica de la Agencia Estatal de Meteorología (AEMET) en Caudete de las Fuentes (latitud 39°52'28''N y longitud 1°31'71''W). La estación meteorológica se encuentra situada a una distancia relativa de la VAS de 5,95 km .....	42
2.5 -	Médis climatológica mensual (1970 – 2007) de las temperaturas del aire a 2 m de altura (mínima, media y máxima) registradas en la estación meteorológica de AEMET en Caudete de las Fuentes (latitud 39°52'28''N y longitud 1°31'71''W). La estación meteorológica se encuentra situada a una distancia relativa de la VAS de 5,95 km .....	43
2.6 -	IV Campaña SCALES de adquisición de datos en Caudete de Las Fuentes (31/07 - 06/08/2006). (a) y (b) estación móvil montada en zona de viñas (latitud 39°57'51" N, longitud 1°25'01" W); (c) estación móvil montada en zona de matorral (latitud 39°56'96"N, longitud 1°29'25"W). .....	44
2.7 -	Experimento FESEBAV-2007: (a) ortofoto con la localización del sitio experimental FESEBAV-2007, (b) vista aérea del cultivo de viñas donde estaba localizada la estación móvil (latitud 39°31'23''N, longitud 1°17'22''W), (c) y (d) detalles de la estación micrometeorológica móvil instalada en medio de las viñas y (e) detalle de los dataloggers Campbell CR1000 utilizados en el experimento FESEBAV-2007, para recogida de datos. ....	45

2.8 -	Valencia Anchor Station: (a) mástil principal de la VAS (latitud 39°34'15" N , longitud 1°17'18" W) donde están instalados los sensores para medir parámetros meteorológicos; (b) esquema de los sensores de la VAS; (c) y (d) mástil secundario donde están montados los sensores para medir parámetros de radiación .....	47
3.1 -	Serie temporal de la temperatura en superficie ( $\approx 1$ cm), a 5 cm, 7,5 cm, 10 cm 15 cm y 25 cm de profundidad en el suelo. Periodo: 31/07 a 05/09/2006 .....	54
3.2 -	Serie temporal de la temperatura en superficie ( $\approx 1$ cm), a 5 cm, 7,5 cm, 10 cm 15 cm y 25 cm de profundidad en el suelo. Periodo: 19/06 a 18/09/2007 .....	54
3.3 -	Serie temporal de la temperatura en superficie y en el suelo a las profundidades de 5 , 7,5, 10, 15 y 25 cm. (a) 19 a 30/07/2007; (c) 01 a 31/07/2007; (e) 01/ a 31/08/2007; (g) 01 a 18/09/2007 y (b)22 y 23/06/2007; (d) 11 y 12/07/2007; (f) 02 y 03/08/2007 y (h) 15 y 16/09/2007. Las figuras de la derecha muestran el detalle de las figuras de la izquierda, para dos días consecutivos tomados como muestra del periodo respectivo .....	55
3.4 -	Capacidad calorífica volumétrica, estimada por la ecuación (3.3) y humedad del suelo. (a): Periodo: 31 de julio a 5 de Septiembre de 2006; (b): Periodo: 19 de junio a 18 de Septiembre de 2007 .....	57
3.5 -	Serie temporal del flujo de calor en el suelo en superficie (G); a 7,5 cm (G 7,5cm); y a 12,5 cm (G 12,5cm) de profundidad. Periodo: 31 de julio a 5 de septiembre de 2006 .....	58
3.6 -	Serie temporal del flujo de calor en el suelo (G) en superficie, a 7,5 cm y a 12,5 cm de profundidad. Periodo: (a) 19 a 31/06/2007; (b) 1 a	

	31/07/2007; (c) 01 a 31/08/2007 y (d) 01 a 18/09/2007 .....	59
3.7 -	Serie temporal de radiación neta y flujo de calor en el suelo. Periodo: 31 de julio a 5 de septiembre de 2006 .....	61
3.8 -	Serie temporal de radiación neta y flujo de calor en el suelo. Periodo: (a) 19 a 31/06/2007; (b) 1 a 31/07/2007; (c) 01 a 31/08/2007 y (d) 01 a 18/09/2007 .....	62
3.9 -	Relación entre $R_n$ y $G$ para las viñas para los días 07/07/2007 (a) y 18/09/2007 (b). En ambos casos se dan condiciones de cielo despejado	64
3.10 -	Diagramas de dispersión de $R_n$ frente a $G$ y recta de regresión indicada en rojo. A) año 2006 y b) año 2007. Los datos de $R_n$ se obtuvieron sobre los cultivos de viña mencionados en el ítem 2.3 del Capítulo 2 y los valores $G$ se estimaron mediante la Ecuación 3.5 .....	65
3.11 -	Variación diurna de los flujos de $R_n$ y $G$ sobre el cultivo de viñas: (a), (c), (e) y (g). Valores observados de $G$ y estimados a partir del modelo $G =$ $0,1683 R_n - 19,7153$ : (b), (d), (f) y (h). Días nubosos: (a), (b), (c) y (d). Días con cielo despejado: (e), (f), (g) y (h) .....	66
3.12 -	Esquema de una neurona artificial .....	69
3.13 -	Funciones sigmoide y tangente hiperbólica .....	70
3.14 -	Esquema de un perceptrón multicapa. Las líneas discontinuas muestran realimentaciones en el modelo; en este análisis no se usan este tipo de conexiones .....	71
3.15 -	Arquitectura del SOM .....	73

3.16 -	(a) agrupamientos establecidos en el <i>SOM</i> , y (b) representación del número de patrones asignados a cada neurona del <i>SOM</i> .....	76
3.17 -	Mapa de componentes mostrando las posibles relaciones entre las variables meteorológicas medidas " <i>in situ</i> ". Periodo: 19 de junio a 18 de Septiembre de 2007. Datos recogidos por la estación móvil instalada entre viñas (latitud 39°31'23" N, longitud 1°17'22"W y altitud de 796 m). La definición de los acrónimos utilizados está en la Tabla 3.6 .....	77
3.18 -	Mapa de componentes mostrando las variables meteorológicas medidas " <i>in situ</i> " que se utilizan en el desarrollo del <i>ANN</i> . Periodo: 19 de junio a 18 de Septiembre de 2007. Datos recogidos por la estación móvil instalada entre viñas (latitud 39°31'23" N, longitud 1°17'22"W y altitud de 796 m). La definición de los acrónimos utilizados está en la Tabla 3.6 .....	80
3.19 -	$R_n$ estimada utilizando <i>ANN</i> y $R_n$ medida en el campo para: (a) y (c) cielo despejado (días: 01/09/2007 y 15/08/2007) y (b) y (d) cielo con nubosidad (días: 23/08/2007 y 12/07/2007) .....	83
3.20 -	Diagramas de dispersión de la radiación neta (observada versus estimada por el modelo <i>ANN</i> . (a) por la noche ( $R_{n-}$ ), (b) durante el día ( $R_{n+}$ ) y (c) ciclo diurno ( $R_{n\pm}$ ) .....	84
3.21 -	Variación promediada de $R_n$ y $R_s^\downarrow$ sobre el viñedo en los periodos: (a) junio (19-31); (b) julio; (c) agosto y (d) septiembre (1-18) del año 2007 ..	85
3.22 -	Radiación neta observada y estimada para diferentes condiciones de nubosidad. (a) y (c): días despejados (23/08/2007 y 12/07/2007); y (b) y (d): días nubosos (01/09/2007 y 15/08/2007). Los modelos lineales utilizados para estimar $R_n$ fueron: (a) y (b): $R_{n1} = 0.657R_s^\downarrow - 54.273$ ; y (c) y	

(d): $R_{n2} = 0.791(1-\alpha)R_s^\downarrow - 54.161$ .....	87
3.23 - Diagrama de dispersión de la radiación neta (observada frente estimada) (a) $R_{n1}$ y (b). $R_{n2}$ para $R_{n+}$ (periodo diurno) .....	88
3.24 - Representación de $R_n$ estimada por el MLP frente a los valores medidos <i>in situ</i> y regresión lineal para ambos conjuntos de datos .....	93
3.25 - Representación de los valores medidos <i>in situ</i> de $R_n$ y predicción del modelo neuronal para días con cielo despejado: (a) 02/07/2007 y (c) 15/08/2007; y días nublados: (b) 21/05/2007 y (d) 26/06/2007 .....	94
3.26 - Representación de la importancia de las entradas para el modelo neuronal. (a) FESEBAV-2007 y (b) VAS-2007 y 2008. El orden de las entradas es: mes, día, hora, velocidad del viento (Vel. Viento), temperatura del aire (Temp. Aire), presión atmosférica (P. Atmosf.) y humedad relativa del aire (H. Rel.) .....	96
4.1 - Comparación entre las medidas de LST obtenidas durante la campaña de campo <i>IV Campaña SCALES 2006</i> sobre (a) matorral y (b) viñas y las estimaciones a partir de <i>SEVIRI</i> . En la leyenda: Est. Met = Estación Meteorológica .....	101
4.2 - $G/R_n$ sobre viñas y matorral estimados a partir de la Ecuación 4.2 utilizando la temperatura de la superficie estimada con <i>SEVIRI</i> y las medidas de las estaciones meteorológicas durante la Campaña <i>SCALES 2006</i> : (a) día 31/07/2006, (b) día 01/08/2006, (c) día 02/08/2006, (d) día 03/08/2006, (e) día 04/08/2006, (f) día 04/08/2006, y (g) día 05/08/2006. En la leyenda de las figuras Est. Met. = Estación Meteorológica .....	103
4.3 - $G/R_n$ generado a partir de las imágenes del sensor <i>SEVIRI</i> de	

	Meteosat para el día 31/07/2007: (a) 00:00 UTC; (b) 05:00 UTC, (c) 09:00 UTC, (d) 13:00 UTC, (e) 19:00 UTC, (f) 21:00 UTC .....	105
4.4 -	Desarrollo temporal de las series de datos de radiación. Fuente: Adaptado de Smith <i>et al.</i> , 2004 .....	107
4.5 -	Imagen <i>LANDSAT 5</i> de 8 de julio de 2003 con los 4 <i>footprints</i> de alta resolución de <i>GERB</i> sobre el área de estudio (Valencia Anchor Station – 50 x 50 km <sup>2</sup> ). Los usos y clasificación del suelo de esta área se mostraron en la Figura 2.3 del Capítulo 2 .....	110
4.6 -	Ciclo diurno de la radiación neta medida en la VAS en dos días diferentes: 22 de julio de 2007 – día nuboso y 02 de agosto de 2007 – día despejado .....	113
4.7 -	Índices de error para los conjuntos de datos de entrenamiento (entr) / validación (valid) del <i>MLP</i> y <i>MLR</i> para las viñas, vuelo desnudo y matorral, considerando condiciones de cielo con nubosidad variable, nuboso y despejado. Todos los valores están en unidades de W m <sup>-2</sup> .....	116
4.8 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie (W m <sup>-2</sup> ), y la salida de la red (W m <sup>-2</sup> ), para cielo con nubosidad variable. Modelo utilizado: <i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>viñas</i> .....	118
4.9 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie (W m <sup>-2</sup> ), y la salida de la red (W m <sup>-2</sup> ), para cielo nuboso. Modelo utilizado: <i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>viñas</i> .....	118
4.10 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie (W m <sup>-2</sup> ), y la salida de la red (W m <sup>-2</sup> ), para cielo despejado. Modelo utilizado:	

	<i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>viñas</i> .....	118
4.11 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo con nubosidad variable. Modelo utilizado: <i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>suelo desnudo</i> .....	119
4.12 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo nuboso. Modelo utilizado: <i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>suelo desnudo</i> .....	119
4.13 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo despejado. Modelo utilizado: <i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>suelo desnudo</i> .....	119
4.14 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo con nubosidad variable. Modelo utilizado: <i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>matorral</i> .....	119
4.15 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo nuboso. Modelo utilizado: <i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>matorral</i> .....	120
4.16 -	Comparación entre la señal deseada, el valor de $R_n$ en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo despejado. Modelo utilizado: <i>MLP</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>matorral</i> .....	120

- 4.17 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo con nubosidad variable. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) Conjunto de validación. Tipo de Superficie: *viñas* ..... 120
- 4.18 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo nuboso. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) Conjunto de validación. Tipo de Superficie: *viñas* ..... 120
- 4.19 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo despejado. Modelo utilizado: *MLR*. (a) conjunto de Entrenamiento y (b) conjunto de Validación. Tipo de Superficie: *viñas* ..... 121
- 4.20 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo con nubosidad variable. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) Conjunto de validación. Tipo de Superficie: *suelo desnudo* ..... 121
- 4.21 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo nuboso. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: *suelo desnudo* ..... 121
- 4.22 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo despejado. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: *suelo desnudo* ..... 121
- 4.23 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo con nubosidad variable.

Modelo utilizado: <i>MLR</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>matorral</i> .....	122
4.24 - Comparación entre la señal deseada, el valor de $R_n$ en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo nuboso. Modelo utilizado: <i>MLR</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>matorral</i> .....	122
4.25 - Comparación entre la señal deseada, el valor de $R_n$ en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para cielo despejado. Modelo utilizado: <i>MLR</i> . (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de Superficie: <i>matorral</i> .....	122
4.26 - Índices de error para los conjuntos de datos de entrenamiento (entr) / validación (valid) del <i>MLR</i> y <i>MLR1</i> para viñas, suelo desnudo y <i>matorral</i> , considerando condiciones de cielo con nubosidad variable, nuboso y despejado. Todos los valores están en $W m^{-2}$ .....	124
4.27 - $R_n$ observada y estimada por <i>MLR1</i> sobre suelo desnudo para el mes de julio de 2007 .....	125
4.28 - $R_n$ observada y estimada por <i>MLR</i> sobre viñas para el mes de julio de 2007 .....	126
4.29 - $R_n$ observada y estimada por <i>MLP</i> sobre viñas para el mes de julio de 2007 .....	126
4.30 - $R_n$ estimada por <i>MLR</i> y <i>MLP</i> sobre viñas para los días 11, 12, 13 y 14 de julio de 2007 .....	127
4.31 - $R_n$ estimada por <i>MLR</i> y <i>MLP</i> sobre viñas para los días 8, 9, 10, 11 y 12 de julio de 2007 .....	127

4.32 - Comparación <i>MLR</i> x <i>MLP</i> para días despejados: 26, 27, 28 de julio de 2007 .....	128
4.33 - $R_n$ observada x estimada por <i>MLR</i> sobre suelo desnudo para el mes de julio de 2007 .....	128
4.34 - $R_n$ observada x estimada por <i>MLP</i> sobre viñas para el mes de julio de 2007 .....	129

## LISTA DE TABLAS

2.1 -	Sensores utilizados para el estudio del balance de energía en superficie durante los experimentos de campo de 2006 y 2007, parámetros medidos y disposición de los sensores .....	47
2.2 -	Relación de parámetros medidos en la VAS y disposición de los sensores .....	48
3.1 -	Estadísticos descriptivos para las series temporales de la temperatura ( $^{\circ}$ C) en superficie y en a diferentes profundidades .....	56
3.2 -	Estadísticos descriptivos para las series temporales de la capacidad calorífica volumétrica $C_V$ [ $J\ m^{-3}\ K^{-1}$ ] y de la humedad del suelo ( $\theta_w$ ) [ $m^3\ m^{-3}$ ] medidos a 7,5 cm de profundidad .....	56
3.3 -	Estadísticos descriptivos para las series temporales del flujo de calor en el suelo ( $W\ m^{-2}$ ) entre viñas a diferentes profundidades .....	60
3.4 -	Estadísticos descriptivos para la serie temporal de la radiación neta en superficie ( $W\ m^{-2}$ ) .....	63
3.5 -	Modelos lineales obtenidos para $G$ y resultados estadísticos de la comparación entre $G$ estimado a partir de la Ecuación (3.5) y mediante el modelo. RMSE, MAE y se expresan en $W\ m^{-2}$ .....	66
3.6 -	Parámetros meteorológicos y del suelo recogidos durante el experimento <i>FESEBAV-2007</i> y utilizados para entrenar el <i>SOM</i> .....	75
3.7 -	Resultados estadísticos para $R_n$ utilizando la red neuronal artificial (entrenamiento/validación) .....	82
3.8 -	Modelos de regresión lineal obtenidos para $R_n$ y resultados estadísticos	

de la comparación entre los valores observados y estimados de $R_n$ . Los resultados estadísticos para las fases de desarrollo y validación están separadas por / .....	86
3.9 - Errores de ajuste para días específicos con diferentes condiciones de nubosidad .....	87
3.10 - Regresión lineal de los diagramas de dispersión (a = pendiente y b = sesgo del modelo) de $R_n$ ( $W\ m^{-2}$ ) medida frente a $R_n$ estimada usando modelos lineales (ML) y modelos neuronales (ANN). Indica el promedio de los valores medidos “in situ” de $R_n$ .....	90
3.11 - Estadísticos para los conjuntos de datos meteorológicos analizados .....	92
3.12 - Valores de los errores de las fases de entrenamiento y validación del modelo neuronal .....	93
3.13 - Valores de los errores para días nubosos y para días despejados .....	95
4.1 - Estadísticos de la comparación entre la LST de <i>SEVIRI</i> y de las medidas en campo .....	102
4.2 - Valores estadísticos de los parámetros físicos utilizados como datos de entrada ( <i>SWF</i> , <i>LWF</i> ) y salida ( $R_n$ ) en el modelo <i>MLP</i> . Los números de patrones utilizados para el conjunto de datos denominados cielo con nubosidad variable, cielo nuboso y cielo despejado, fueron, sobre suelo desnudo, 6399, 4245 y 2154 respectivamente .....	111
4.3 - Valores estadísticos de los parámetros físicos utilizados como datos de entrada ( <i>SWF</i> , <i>LWF</i> ) y salida ( $R_n$ ) en el modelo <i>MLP</i> . Los números de patrones utilizados para el conjunto de datos denominados cielo con nubosidad variable, cielo nuboso y cielo despejado, fueron, sobre las	

viñas, 5735, 3862 y 1873 respectivamente .....	112
4.4 - Valores estadísticos de los parámetros físicos utilizados como datos de entrada ( $SWF$ , $LWF$ ) y salida ( $R_n$ ) en el modelo $MLP$ . Los números de patrones utilizados para el conjunto de datos denominados cielo con nubosidad variable, cielo nuboso y cielo despejado, fueron, sobre matorral, 472, 288 y 184 respectivamente .....	112
4.5 - Modelos multivariantes de regresión lineal obtenidos para viñas, suelo desnudo y matorral, considerando valores para $SWF > 0$ para condiciones de cielo con nubosidad variable, nuboso y despejado, con sus respectivos $R^2$ y $N$ (números de patrones utilizados).....	114
4.6 - Modelos multivariantes de regresión lineal obtenidos para viñas, suelo desnudo y matorral, considerando valores para $SWF \geq 0$ para condiciones de cielo con nubosidad variable, nuboso y despejado, con sus respectivos $R^2$ y $N$ (número de patrones utilizados) .....	114
4.7 - Índices de error para los conjuntos de datos de entrenamiento / validación del $MLP$ y $MLR$ para las viñas, suelo desnudo y matorral, considerando condiciones de cielo con nubosidad variable, nuboso y despejado .....	115
4.8 - Índices de error para los datos $MODIS$ considerando diferentes condiciones del cielo.....	117
4.9 - Ajuste lineal del tipo $y = ax + b$ , para los conjuntos de entrenamiento y validación de los modelos $MLP$ y $MLR$ .....	123

## LISTA DE ACRÓNIMOS

ANN	Modelo neuronal artificial
CERES	Clouds and the Earth's Radiant Energy System
DCP	Data Collection Platforms
ERB	Earth Radiation Budget
ERBE	Earth Radiation Budget Experiment
ESA	European Space Agency
EUMETSAT	European Organisation for the Exploitation of Meteorological Satellites
FESEBAV	Field Experiment on Surface Energy Balance Aspects in the Valencia Anchor Station area
<i>G</i>	flujo geotérmico o flujo de calor en el suelo
GERB	Geostationary Earth Radiation Budget
GOES	Geostationary Operational Environmental Satellite
<i>H</i>	flujo de calor sensible
HRIT	High Rate Information Transmission
LRIT	Low Rate Information Transmission
MAE	Error medio absoluto
ME	Error medio
ML	Modelo lineal
MLP	Perceptrón Multicapa
MLR	Modelo multivariante de regresión lineal
MSG	Meteosat Second Generation
MODIS	Moderate Resolution Imaging Spectroradiometer
RMSE	Raíz cuadrada del error cuadrático medio
RNA	Redes Neuronales Artificiales
ScaRaB	Scanner for Radiation Budget
SEVIRI	Spinning Enhanced Visible and Infrared Image
SOM	Self-Organizing Map
TOA	Techo de la Atmósfera
UTM	Universal Transverse Mercator
VAS	Valencia Anchor Station
VISSR	Visible and Infrared Spin Scan Radiometer

$R^2$	coeficiente de determinación
$\alpha$	Albedo de la superficie
$c_s$	calor específico
$C_V$	Capacidad calorífica volumétrica
$\varepsilon$	Emisividad
$\varepsilon_{sup}$	Emisividad de la superficie
$\varepsilon_{atm}$	Emisividad de la atmósfera
$\kappa$	difusividad térmica
$\rho_s$	Densidad del suelo
$\sigma$	Constante de Stefan-Boltzmann
$\lambda E$	Flujo de calor latente
$\theta_m$	Fracción volumétrica de material mineral
$\theta_o$	Fracción volumétrica de materia orgánica
$\theta_w$	Fracción volumétrica de agua
$R_l^\downarrow$	Radiación emitida por la atmósfera (onda larga)
$R_l^\uparrow$	Radiación emitida por la superficie (onda larga)
$R_n$	Radiación neta en superficie
$R_s^\downarrow$	Radiación solar incidente (onda corta) en la superficie
$R_s^\uparrow$	Radiación solar reflejada por la superficie (onda corta)



## INTRODUCCIÓN Y OBJETIVOS

### 1.1 Introducción

Las regiones áridas o semiáridas se caracterizan por una distribución irregular de los recursos hídricos, lo que muchas veces constituye una limitación para el desarrollo de una determinada región. La variabilidad hidrológica de estas regiones se debe a la mala distribución espacial y temporal de la lluvia, a la topografía heterogénea y a los cambios de origen antropogénicos que muchas veces conducen a procesos de degradación y de desertificación.

Como en estas regiones la evapotranspiración ( $ET$ ) explica una parte significativa de la pérdida de agua hacia la atmósfera, el estudio y modelización de la radiación neta en superficie ( $R_n$ ), es de suma importancia, una vez que las estimaciones o mediciones de  $R_n$  se utilizan, por ejemplo, para el cálculo de la  $ET$  que, a su vez, se usa para optimizar la calidad y el rendimiento de los cultivos, la planificación de los recursos hídricos y previsiones climáticas (Bennie *et al.*, 2008; Ji *et al.*, 2009; Li *et al.*, 2009; Trezza, 2006). Por esta razón, el flujo de  $R_n$  es la principal variable de entrada en algunos de los principales métodos clásicamente utilizados para medir la  $ET$ , tales como el método de *Priestley-Taylor*, *Penman-Monteith*, método de *Bowen*, *eddy correlation* y balance hídrico del suelo.

La dinámica atmosférica, el cálculo de la evaporación y la estimación de los balances de energía y de agua en la superficie requieren una información adecuada sobre el flujo radiativo neto ya que, el conocimiento de  $R_n$  proporciona una información importante sobre la energía disponible en la superficie (Jegede, 1997). Así pues,  $R_n$ , se distribuye en diferentes procesos: físicos: calentamiento del aire ( $H$ ) y del

suelo ( $G$ ), bio-físicos: transpiración + evaporación o evapotranspiración ( $E$ ), bio-químicos: fotosíntesis ( $F$ ). Por tanto, el balance de energía en superficie viene dado por

$$R_n = H + \lambda E + G + F \quad (1)$$

donde  $H$  es el término que representa el flujo de calor sensible,  $\lambda E$  producto entre el calor latente de vaporización ( $\lambda$ ) y  $E$ , representa el flujo de calor latente,  $G$  es el flujo geotérmico que representa el término de conducción de calor en el suelo y  $F$  la energía que se emplea en la fotosíntesis.

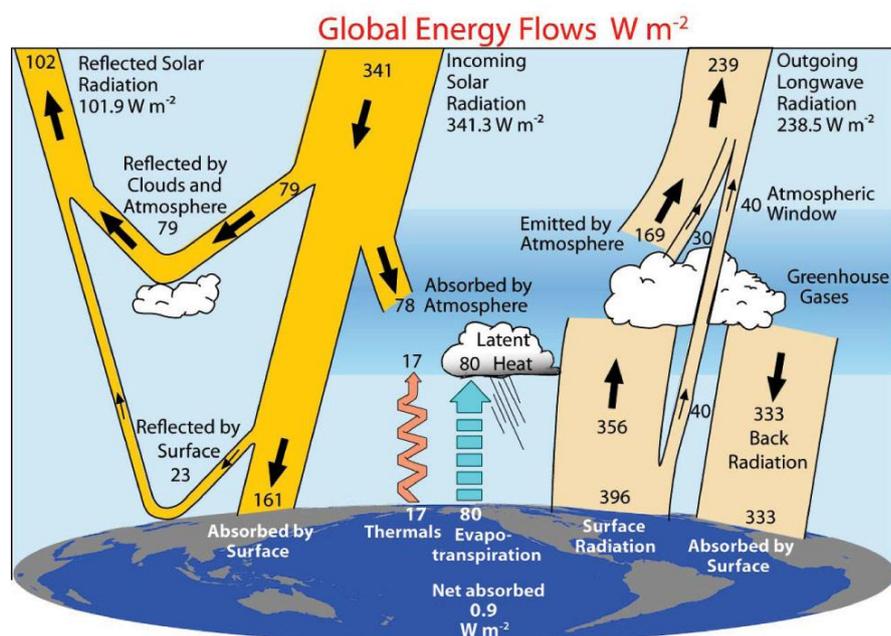
Considerando que el aprovechamiento energético en la fotosíntesis según Lemon, (1963), raramente excede de un 2 a un 5% de  $R_n$ , y que la evaporación y la transpiración (evapotranspiración) ocurren simultáneamente y son indistinguibles, la ecuación de balance de energía en superficie, Ecuación (1), puede aproximarse como:

$$R_n = H + \lambda E + G \quad (2)$$

o sea, el balance de radiación se reparte entre los tres principales procesos; calentamiento del aire, calentamiento del suelo y evapotranspiración. La partición exacta del exceso o déficit de radiación entre ( $H$ ,  $E$  y  $G$ ) viene gobernada por la naturaleza de la superficie y por la capacidad relativa del suelo y de la atmósfera para transportar calor (Oke, 1987). Pero, el flujo neto de radiación no es solamente la entrada básica para el balance de energía en la superficie, sino también el resultado final del balance de radiación, pues la radiación solar interceptada por la Tierra será, o bien absorbida y utilizada en procesos impulsados por la energía, como los citados anteriormente, o bien devueltos al espacio mediante procesos de dispersión o de reflexión.

El balance de energía más reciente obtenido mediante datos de teledetección para el sistema Tierra-Atmósfera se muestra en la Figura 1, donde se puede observar la interacción de la energía de onda corta (solar) y de onda larga (térmica), a través de dicho sistema, y verificar como, efectivamente, se trata de un balance anual medio global de energía tanto en el techo de la atmósfera como en superficie, así como para

la radiación atmosférica. El análisis detallado de los diferentes flujos puede encontrarse en Trenberth *et al.* (2008).



**Figura 1.1** - Balance anual medio global de energía de la Tierra – Unidades:  $W m^{-2}$   
**Fuente:** Trenberth *et al.* (2008)

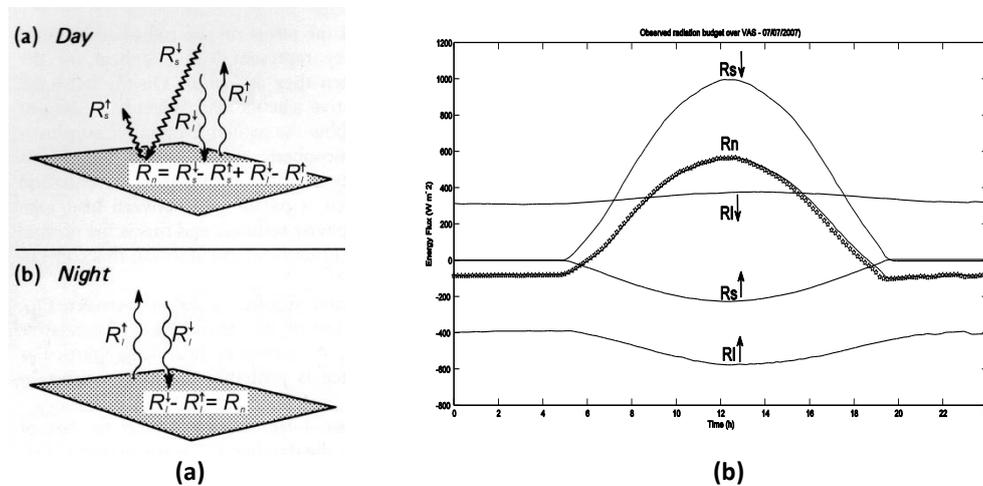
Así que, otra manera de calcular  $R_n$  es considerar las entradas y salidas de la radiación de onda corta y onda larga pues, de acuerdo con Jegede (1997), Arya (1988), y Oke (1987), el flujo de radiación neta en superficie es el resultado del balance entre las entradas y salidas de radiación de onda corta ( $R_s$ ) y onda larga en la superficie ( $R_l$ ), o sea:

$$R_n = R_s^\downarrow - R_s^\uparrow + R_l^\downarrow - R_l^\uparrow \quad (3)$$

donde  $R_s^\downarrow$  es la radiación solar incidente (onda corta) en la superficie,  $R_s^\uparrow$  es la radiación solar reflejada por la superficie (onda corta),  $R_l^\downarrow$  es la radiación emitida por la atmósfera (onda larga) y  $R_l^\uparrow$  es la radiación emitida por la superficie (onda larga). Las flechas hacia abajo y hacia arriba indican la radiación entrante y saliente sobre la superficie, respectivamente. La energía hacia la superficie se considera positiva y la energía saliente de la superficie se considera negativa.

En la Figura 2b, a título de ilustración, se presentan los flujos de radiación observados sobre la *Valencia Anchor Station* (VAS) el día 7 de julio de 2007, donde se

observa, por ejemplo, que la radiación de onda larga hacia arriba y hacia abajo casi se cancelan (Ferreira *et al*, 2011a).



**Figura 1.2 - (a)** Diagrama esquemático de los flujos implicados en el balance de radiación de un sitio “ideal” (adaptado de Oke, 1987, p. 26), **(b)** balance de radiación observado en la *Valencia Anchor Station* (latitud 39° 34' 15"N y longitud 1° 17' 18"W – Plana de Utiel-Requena, España) bajo condiciones de cielo despejado el 7 de julio 2007. **Fuente:** Ferreira *et al*, 2011a.

También se observa en la Figura 2b que la evolución de  $R_l^\uparrow$  presenta una ligera modulación, que refleja el cambio en la temperatura de la superficie de la tierra, pues ésta se calienta y se enfría en respuesta a las variaciones en la radiación solar. Según Wallace y Hobbs (2006), la radiación solar incidente en la superficie de la Tierra viene modulada por la rotación de la Tierra, originando un ciclo diario de la radiación solar incidente sobre cada punto de la superficie. A causa de su pequeña capacidad calorífica, las superficies terrestres responden casi instantáneamente, por lo que  $R_l^\uparrow$  está virtualmente en fase con el flujo de  $R_s^\downarrow$ . Sin embargo,  $R_l^\downarrow$  depende de la temperatura del aire, que alcanza su máximo por la tarde antes del ocaso del Sol y su mínimo inmediatamente después de la salida del Sol.

Puesto que  $R_s^\uparrow$  depende de la cantidad de radiación incidente,  $R_s^\downarrow$ , y del albedo de la superficie,  $\alpha$ , que depende a su vez de las características radiativas de la superficie, se tiene que:

$$R_s^\uparrow = \alpha R_s^\downarrow \tag{4}$$

Por tanto, la Ecuación (3) puede reescribirse como

$$R_n = (1 - \alpha) R_s^\downarrow + (R_l^\downarrow - R_l^\uparrow) \tag{5}$$

La emisión de radiación de onda larga  $R_l^\uparrow$  de la superficie terrestre se calcula por la Ley de Stefan-Boltzmann

$$R_l^\uparrow = \varepsilon_{sup} \sigma T_{sup}^4 \quad (6)$$

$$R_l^\downarrow = \varepsilon_{atm} \sigma T_{atm}^4 \quad (7)$$

donde  $\varepsilon$  es la emisividad de la superficie ( $\varepsilon_{sup}$ ) o de la atmósfera ( $\varepsilon_{atm}$ );  $\sigma$  es la constante de Stefan-Boltzmann ( $\sigma = 5,67 \times 10^{-8} \text{ W m}^{-2} \text{ K}^{-4}$ ), y T es la temperatura absoluta de la superficie expresada en kelvin (K).

Por tanto, la Ecuación (5) puede reescribirse como

$$R_n = (1 - \alpha)R_s^\downarrow + \sigma (\varepsilon_{atm} T_{atm}^4 - \varepsilon_{sup} T_{sup}^4) \quad (8)$$

La Ecuación (8) muestra que  $R_n$  es el resultado del balance de radiación en superficie y constituye un parámetro fundamental que regula el clima de las capas más bajas de la atmósfera. También se puede ver, a través de la Ecuación (8), que  $R_n$  depende críticamente de la estructura y composición de la atmósfera, de la presencia de nubes, además de características de la superficie tales como el albedo, la emisividad, la temperatura, la humedad y las propiedades térmicas del suelo subyacente.

Para los estudios de balance de energía en superficie, la determinación más precisa posible de  $R_n$  es muy importante, porque su magnitud está directamente relacionada con el resto de los flujos de calor y de radiación, como se puede ver en las Ecuaciones (2) y (8). Pero, a pesar de su importancia,  $R_n$  no se mide habitualmente y hay pocos datos históricos disponibles en la mayoría de las estaciones meteorológicas estándar (Sentelhas y Gillespie, 2008).

El flujo de  $R_n$  se mide con radiómetros netos (Figura 3a) o con sensores de radiación que miden sus componentes por separado – radiación de onda corta incidente y reflejada y radiación de onda larga incidente y emitida (Figura 3b), sólo en

muy pocas estaciones climatológicas alrededor del mundo, o por científicos en campañas de campo específicamente diseñadas con esta finalidad. También hay que considerar los cuidados requeridos en el campo para el mantenimiento de estos sensores además del problema de proporcionar una superficie de referencia (Monteith y Unsworth, 1973; Irmak *et al.*, 2003).



**Figura 1.3 - (a)** radiómetro neto utilizado para medir el flujo de radiación neta en superficie, **(b)** CNR1 Net radiometer que tiene 2 piranómetros – sensor de la izquierda en (b) – utilizado para medir la radiación solar (incidente y reflejada) y 2 pirgeómetros – sensor de la derecha en (b) – utilizado para medir radiación de onda larga incidente desde el cielo y la emitida por la superficie. **Fuente:** (a) <http://www.gruma.ufsm.br/lumet/equipamentos.php> y (b) <http://www.campbellsci.co.uk>.

Una serie de estudios han puesto gran esfuerzo en la determinación precisa de  $R_n$  para un lugar determinado, teniendo en cuenta su cobertura vegetal y usos del suelo, a partir de datos meteorológicos, como la temperatura de la superficie del suelo y del aire, la fracción de cobertura de nubes, la humedad relativa del aire, la radiación emitida por la atmósfera y la radiación solar incidente, dando origen a varios modelos que se han propuesto o evaluado (de Jong *et al.*, 1980; Jegede, 1997; Amarakoon y Chen, 1999; Iziomon *et al.*, 2000; Irmak *et al.*, 2003; Jegede *et al.*, 2006; Carrasco y Ortega-Farías, 2008; Kjaersgaard *et al.*, 2007; Sentelhas y Gillespie, 2008; Wang y Liang, 2009).

Estos modelos, unos basados en ecuaciones empíricas y usando coeficientes de la bibliografía, u otros desarrollados a la luz de los principios físicos del balance de radiación en superficie, difieren entre sí en función de la complejidad de los datos meteorológicos requeridos (Sentelhas y Gillespie, 2008). Sin embargo, mirando más detenidamente, la mayoría de las ecuaciones utilizadas para calcular la radiación neta en superficie en una escala temporal horaria, diaria (cubriendo el ciclo diurno) o a más

largo plazo (de meses a años), necesitan como parámetro de entrada la radiación solar incidente – un parámetro que también no se mide habitualmente en la mayoría de las estaciones meteorológicas.

Aquí, por tanto, se encuentra la primera aportación de esta tesis, el desarrollo, por primera vez, de un modelo para la estimación de  $R_n$ , utilizando redes neuronales, cuyos datos de entrada son parámetros meteorológicos convencionales: velocidad del viento, presión atmosférica en superficie, temperatura del aire y humedad relativa del aire. Estos parámetros se miden rutinariamente en las estaciones meteorológicas alrededor del globo. Por tanto, el modelo propuesto, tiene una ventaja práctica en la estimación de  $R_n$  en comparación con otros modelos físicos, empíricos o semi-empíricos, una vez que la mayoría de estos modelos requieren, como datos de entrada, otros parámetros geofísicos, tales como los ya mencionados. Pero, en general, estos parámetros, así como la radiación solar, no se miden de forma rutinaria en las estaciones meteorológicas convencionales, y estimaciones realizadas para ellos pueden conducir a errores cada vez mayores en la estimación de  $R_n$  (Ferreira *et al.* 2011b).

Otro aspecto a considerar, es que en las regiones semi-áridas o áridas, de modo especial, se requiere, además de la estimación de  $R_n$ , la estimación del flujo de calor en el suelo ( $G$ ), término significativo de la ecuación de balance de energía en superficie (Ecuación 2) en estas regiones. Pero  $G$  suele despreciarse en los estudios de balance de energía en la superficie de la Tierra. Muchas veces este término se considera nulo, o se parametriza usando datos meteorológicos (por ejemplo, como un porcentaje fijo de  $R_n$ ), o se mide con placas de flujo de calor (fluxímetros).

Según Davies (1967) y Kustas *et al.* (1990), en regiones semi-áridas o con vegetación escasa, una gran parte de la superficie del suelo queda expuesta a la radiación solar, especialmente alrededor del medio día, cuando una gran parte de la energía puede conducirse hacia el suelo. Hay que destacar también que, según Verhoef (2004), la mayoría de los métodos actuales destinados a determinar  $G$  sólo pueden proporcionar valores *in situ* que son válidos para zonas inferiores a 1 m<sup>2</sup>. La

cuestión entonces es: ¿cómo extrapolar las medidas de  $R_n$  y  $G$  de la escala local a la escala regional o global?

La respuesta puede estar en la naturaleza espacial y temporal de los datos de teledetección, pues con el avance de la tecnología espacial y los recientes progresos en los sistemas sensores y en las técnicas de teledetección es posible, actualmente, la obtención, con alta resolución espacial y temporal de muchos de los parámetros utilizados para estimar los componentes del balance de energía en superficie (Price, 1982; Sellers, 1990; Schmetz, 1991; Watts, 2000; y Abdelghania, 2008). Por tanto, el marco de este trabajo está fuertemente motivado por la posibilidad de utilizar la tecnología espacial combinada con medidas *in situ* para estudiar y modelizar la radiación neta en superficie.

En la década de los 80 surgen las primeras aproximaciones alternativas para estimar directamente la radiación neta en superficie a partir de las observaciones hechas por satélites en el Techo de la Atmósfera (*TOA*). Pinker y Corio (1984) utilizando datos de  $R_n$  y radiación de onda larga saliente, medidos en el *TOA* por el satélite *NOAA-5*, demostraron que éstas estaban correlacionadas con la radiación neta en superficie.

Posteriormente, Pinker *et al.* (1985 y 1988) utilizando datos horarios de radiación neta medidos *in situ* por el *Canadian Climate Center of the Atmospheric Environmental Service* e imágenes *GOES-E (Geostationary Operational Environmental Satellite)*, utilizando el sensor *Visible and Infrared Spin Scan Radiometer (VISSR)*, con pixel de 8 km x 8 km de resolución, también encontraron que la media diaria de la radiación neta planetaria está altamente correlacionada con la media diaria de la radiación neta en superficie.

Hay que destacar que a lo largo de las últimas décadas se han desarrollado misiones espaciales dirigidas al estudio del balance de radiación del sistema Tierra-Atmósfera tales como *ERB (Earth Radiation Budget)* a bordo de *NIMBUS-6* y *-7*, *ERBE (Earth Radiation Budget Experiment)* a bordo de *NOAA-9* y *-10*, *ScaRaB (Scanner for Radiation Budget)* 1 y 2, respectivamente a bordo de los satélites *Meteor-3/7* y *Resurs-*

01/4, CERES (*Clouds and the Earth's Radiant Energy System*) a bordo de TRMM, Terra y Aqua de NASA y GERB (*Geostationary Earth Radiation Budget*) de EUMETSAT. Pero, todas estas misiones, excepto GERB, son satélites de órbita polar donde la observación sobre una misma zona sólo se realiza dos veces al día. Sin embargo, GERB es el primer instrumento diseñado exclusivamente para estimar el balance de radiación de la Tierra desde un satélite en órbita geoestacionaria.

Aquí se encuentra una segunda aportación de esta tesis, donde, utilizando, por primera vez, datos de  $R_n$  medidos *in situ* y la sinergia entre los sensores GERB y SEVIRI (*Spinning Enhanced Visible and Infrared Imager*), ambos a bordo del satélite MSG (*Meteosat Second Generation*), se han desarrollado modelos lineales y neuronales que permiten estimar el ciclo diurno completo de  $R_n$  a partir de los datos GERB en el TOA. Nótese que los satélites MSG, proporcionan medidas cada 15 minutos, representando así un enorme avance en la adquisición de datos de la superficie terrestre y de su atmósfera.

El sensor SEVIRI tiene 12 canales espectrales y una resolución espacial de 3 km en el nadir para todos los canales espectrales excepto el de alta resolución del visible cuya resolución es de 1 km. SEVIRI permite la obtención, entre otros parámetros, de la temperatura y el albedo de la superficie, de las características de la vegetación y su evolución a lo largo del periodo fenológico, de características de los diferentes tipos de nubes, etc. El estudio de la relación  $G/R_n$ , a escala local y regional (ver capítulo 4) basado en la metodología propuesta por Santanello y Friedl (2003), utiliza la temperatura obtenida del sensor SEVIRI.

El sensor GERB fue diseñado específicamente para estudiar el balance de la radiación de la Tierra haciendo medidas muy precisas de los flujos radiativos de onda corta y de onda larga de este balance en el TOA. Su resolución nominal en el nadir es de 45 km x 40 km y su muestreo temporal también es de 15 minutos. En el apéndice I se presenta un resumen de las características técnicas de los sensores GERB y SEVIRI.

La sinergia entre *GERB* y *SEVIRI*, es decir, la combinación entre los datos *GERB* en banda ancha (bien calibrados), con los datos de *SEVIRI* en bandas estrechas (con una mayor resolución espacial), permite una mejora significativa de la resolución espacial de los flujos radiativos obtenidos por *GERB* en el *TOA*. Así que, el producto de alta resolución de *GERB* posee una resolución nominal en el nadir, alrededor del Ecuador terrestre, de 9 km x 9 km (3 x 3, pixeles de *SEVIRI*) y una resolución espacial del orden de 12 km x 15 km en nuestra área de estudio, debido a las condiciones de latitud y longitud (latitud 39°34'15"N y longitud 1°17'18" W – Plana de Utiel-Requena).

La sinergia entre los sensores *GERB* y *SEVIRI* es, por tanto, el núcleo fundamental sobre el que se pretende basar el presente trabajo para estudiar, con alta resolución espacial y temporal, la dinámica de la radiación neta en superficie,  $R_n$ , y mostrar su potencial para la obtención del resto de los flujos del balance de energía.

Como  $R_n$  es una medida de la energía radiativa disponible en la superficie y es la fuerza motriz en muchos procesos físicos y biofísicos requeridos por los sistemas suelo-vegetación-atmósfera, para alcanzar los objetivos propuestos y descritos a seguir, su estudio se realiza sobre diferentes superficies; suelo desnudo, matorral y viñas y en diferentes condiciones considerando días con cielo despejado, días nubosos y días con nubosidad variable. La sinergia entre los sensores *GERB* y *SEVIRI* a bordo de los satélites *MSG* puede, juntamente con medidas *in situ*, ayudar en esta tarea, cubriendo completamente el ciclo diario gracias a su alta resolución temporal.

### 1.2 Objetivos

Este proyecto tiene como objetivo principal el estudio de la dinámica de la radiación neta en regiones semiáridas utilizando modelos lineales y neuronales y la sinergia entre los sensores *GERB* y *SEVIRI*, así que los objetivos propuestos para esta tesis se han concentrado específicamente en:

- realizar campañas de campo en la zona de la *Valencia Anchor Station (VAS)*, para recoger datos agro-meteorológicos *in situ*, fundamentalmente  $R_n$  sobre suelo desnudo, viñas y matorral,
- estimar el flujo de calor en el suelo en superficie a partir de los valores medidos *in situ* a diferentes profundidades y verificar su correlación con  $R_n$ ,
- modelizar y estimar  $R_n$  a partir de datos meteorológicos medidos rutinariamente en estaciones meteorológicas convencionales o automáticas (velocidad del viento, temperatura del aire, presión atmosférica y humedad relativa del aire), utilizando modelos neuronales artificiales,
- modelizar y estimar  $R_n$  a partir de la sinergia entre los sensores *GERB* y *SEVIRI* a bordo del satélite *METEOSAT*, utilizando modelos lineales multivariantes y modelos neuronales.

Así que, para cumplir los objetivos propuestos esta tesis está organizada como sigue:

En el capítulo 2 se encuentra una descripción detallada del área de estudio y de las campañas de campo realizadas para adquirir los datos necesarios para el estudio de  $R_n$  considerando diferentes tipos de cobertura vegetal, o sea, matorral y viñas, además de suelo desnudo.

El capítulo 3 trata de la modelización de  $R_n$  y de la estimación del flujo de calor en suelo ( $G$ ) a partir de  $R_n$ . Los modelos utilizados para seleccionar los datos de entrada para el modelo neuronal propuesto para estimar  $R_n$ , se describen en detalle, así como la metodología utilizada para estimar el flujo de calor en superficie y a partir de  $R_n$ .

El estudio de la relación  $G/R_n$ , utilizando datos de la temperatura en superficie, obtenidos del sensor *SEVIRI*, y la modelización y estimación de  $R_n$  utilizando modelos lineales multivariantes y modelos neuronales, que utilizan como datos de entrada los datos de alta resolución temporal y espacial de los flujos radiativos en el *TOA*, obtenidos a partir de la sinergia entre los sensores *GERB* y *SEVIRI*, se presenta en el capítulo 4.

En el apéndice I se encuentra una descripción detallada de los sensores *SEVIRI* y *GERB*. Los artículos “Ferreira *et al.*, 2010, *Characterization and Modelization of Surface Net Radiation Through Neural Networks*”, publicado en el libro “*Soft Computing Methods for Practical Environment Solutions Techniques and Studies* – editor IGI Global), capítulo 16:260-277; “Ferreira *et al.*, 2011, *Estimating net radiation at surface using artificial neural networks: a new approach*”, publicado en la revista *Theoretical and Applied Climatology*, 106(1):263-279; y “Ferreira *et al.*, 2011, *Modelling net radiation at surface using “in situ” netpyrradiometer measurements with artificial neural networks*”, publicado en la revista *Expert Systems with Applications*; 38(11):4190-4195, se encuentran en los apéndices II, III y IV respectivamente.

## ÁREA DE ESTUDIO Y CAMPAÑAS DE CAMPO

### 2.1 Introducción

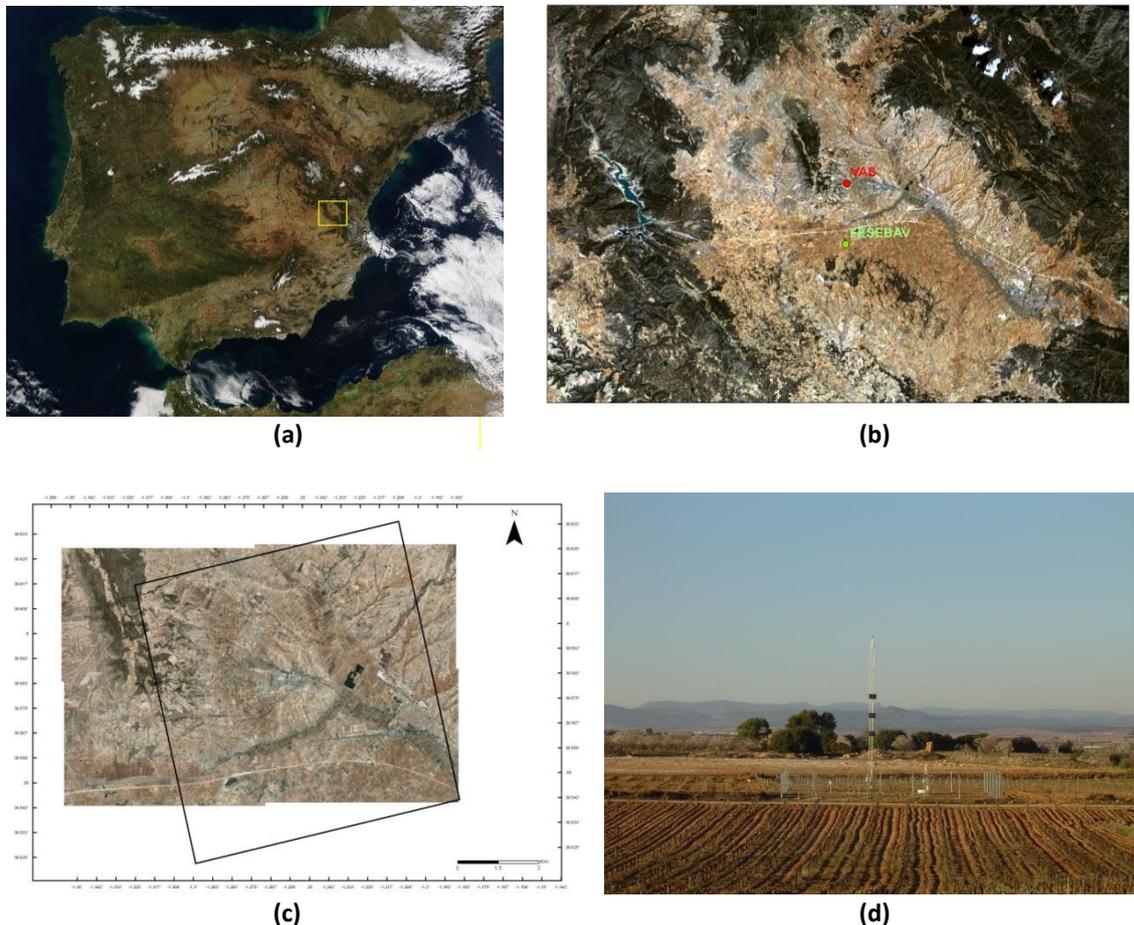
El estudio del balance de energía requiere la realización de campañas de medidas con instrumentos específicos tanto a nivel del suelo (en superficie y en profundidad), en alturas que pueden variar de 2 a 30 m (estaciones meteorológicas) o desde el espacio, con sensores a bordo de satélites geoestacionarios o de órbita polar. En este apartado se presenta la metodología utilizada para realizar la adquisición de los datos necesarios para el estudio del balance de energía en superficie y su modelización, considerando los diferentes tipos de cobertura vegetal sobre los que se recogieron datos, o sea, matorral y viñas, además de suelo desnudo. Los datos utilizados para el desarrollo del tema central de este trabajo se recogieron en dos campañas de campo realizadas en 2006 y 2007, y que se describen en este capítulo.

### 2.2 Descripción y caracterización del área de estudio

#### 2.2.1 Área de la *Valencia Anchor Station*

La *Valencia Anchor Station* (VAS), estación meteorológica de referencia para validación de datos y productos de teledetección, está situada cerca de la localidad de Caudete de las Fuentes, en el altiplano de Utiel-Requena, a 80 km hacia el oeste de Valencia y representa un área bastante homogénea de 50 km x 50 km, dedicada fundamentalmente al cultivo de viñas. La localización de la estación viene dada por la latitud 39°34'15" N y la longitud 1°17'18" W, lo que corresponde a 647141 y 4381706 en coordenadas *Universal Transverse Mercator* (UTM), estando situada a una altura de 813 m sobre el nivel del mar. En la Figura 2.1a se muestra una imagen del satélite

TERRA/MODIS (*Moderate Resolution Imaging Spectroradiometer*) correspondiente al día 13 de febrero de 2009, en la que se encuentra señalada la posición de la VAS dentro de la Península Ibérica. En esta área se desarrollaron los experimentos de campo de los años 2006 y 2007 y que se comentan a continuación.



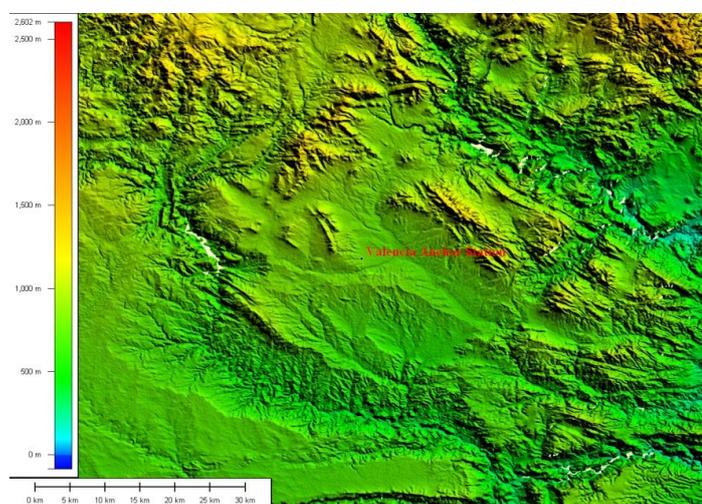
**Figura 2.1** - (a) Imagen del satélite *TERRA/MODIS* correspondiente al día 13 de febrero de 2009 con la localización geográfica de la VAS, y el área cercana donde se montaron los experimentos de campo de 2006 y 2007; (b) Imagen *Landsat-5* en falso color de la Plana de Utiel-Requena (01 de agosto de 2006) con la localización de la VAS y de la estación micrometeorológica móvil utilizada en la campaña de campo de 2007 (latitud  $39^{\circ}31'23''$  N y longitud  $1^{\circ}17'22''$  W); (c) Fotografía aérea de la zona de la VAS adquirida en junio de 2006 (Fuente: *Ground Data Processing & Production of the High Resolution Biophysical Maps* – Ref.: EOLAB\_09R01, Issue: 1.1 de 05/03/2009.); (d) detalle de la VAS (latitud  $39^{\circ}34'15''$  N , longitud  $1^{\circ}17'18''$  W).

## 2.2.2 Orografía y usos del suelo

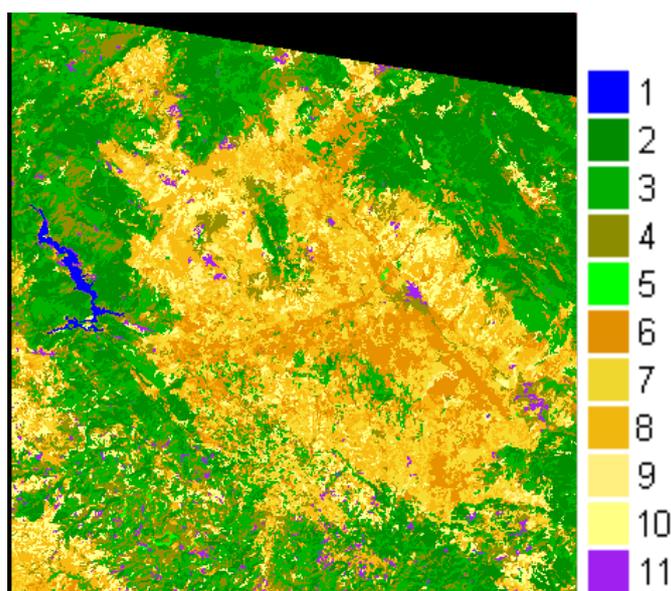
Los alrededores de la VAS poseen una orografía muy suave ya que, en general, el relieve es llano (con pendientes inferiores al 2%), aunque hay zonas en las que la

orografía pasa a ser de tipo ondulado, con pendientes comprendidas entre el 8 y el 15 % (el modelo digital de elevación del terreno aparece en la Figura 2.2).

En la zona considerada, la cual posee una extensión aproximada de 25 km × 25 km, la mayor parte del suelo se dedica al cultivo de la viña (alrededor de un 75% de la superficie total), siendo los usos del suelo del resto de la zona dedicados, principalmente, a cultivos de secano (almendros y olivos). En menor medida, también es posible encontrar pinos y matorrales, de acuerdo con el mapa de usos del suelo mostrado en la Figura 2.3.



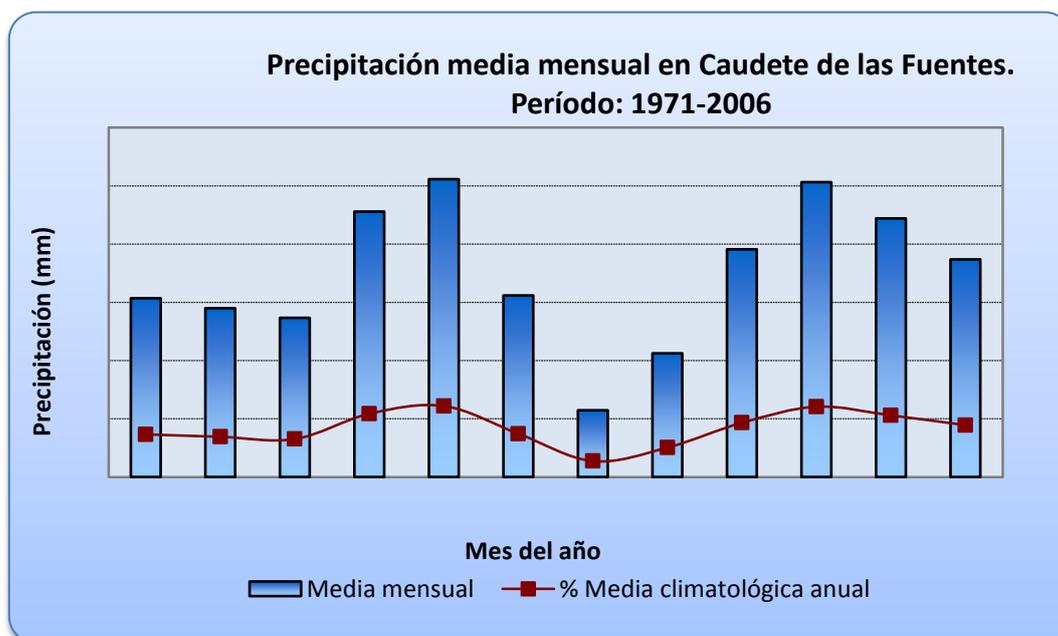
**Figura 2.2** – Elevación del terreno de los alrededores de la VAS.



**Figura 2.3** - Usos y clasificación del suelo. Leyenda: 1-agua; 2-pinos; 3-baja densidad de pinos y matorral; 4-matorral; 5-cultivos de regadío; 6-viñedos; 7-baja densidad de viñedos; 8-muy baja densidad de viñedos; 9-cultivos a base de hierbas; 10-suelo desnudo; 11-áreas urbanas. Imagen LANDSAT 5 de 8 de julio de 2003, sobre el área de estudio (Valencia Anchor Station - 50 km x 50 km). **Fuente:** Universidad Politécnica de Catalunya.

### 2.2.3 Clima

Según el Atlas Climático de la Comunidad Valenciana (Pérez, 1994), Utiel-Requena pertenece a la zona climática del sector central occidental. Este clima se caracteriza por un volumen pluviométrico anual de aproximadamente 450 mm, como promedio, repartido regularmente a lo largo de todo el año, salvo el periodo seco estival, que comprende julio y agosto. La Figura 2.4 ilustra la climatología de la precipitación (media mensual) de la estación localizada en Caudete de las Fuentes, representativa de la región de Utiel-Requena y del área de estudio.

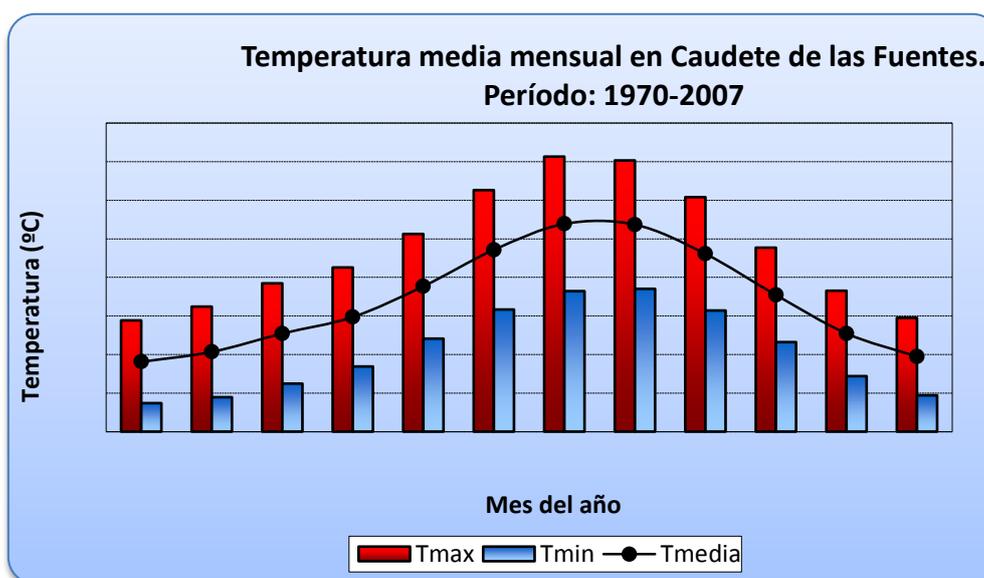


**Figura 2.4** - Diagrama de las precipitaciones pluviométricas (media mensual y porcentaje de la media climatológica (1971 - 2006) anual) registradas en la estación meteorológica de la Agencia Estatal de Meteorología (AEMET) en Caudete de las Fuentes (latitud 39°52'28''N y longitud 1°31'71''W). La estación meteorológica se encuentra situada a una distancia relativa de la VAS de 5,95 km.

El volumen pluviométrico promedio anual (1971-2006) registrado en esta estación es aproximadamente 419 mm. En el primer trimestre del año las lluvias registradas en cada mes tienen como media climatológica aproximadamente 30 mm. Los meses de abril y mayo se caracterizan por una media climatológica de lluvia entre 45,6 mm y 51,1 mm respectivamente, siendo mayo el mes más lluvioso. En junio ya se

observa un descenso en las lluvias y los meses de julio y agosto son los meses climatológicamente menos lluviosos con 11,5 mm y 21,2 mm respectivamente, caracterizando el período estival de esta área por el establecimiento de una marcada estabilidad atmosférica gracias al dominio de situaciones de tipo anticiclónico. En el cuatrimestre septiembre, octubre, noviembre y diciembre, la media climatológica se queda entre los 37,4 mm y 50,6 mm, destacando el mes de octubre como el más lluvioso de los cuatro.

En la Figura 2.5, se observa la media mensual climatológica de las temperaturas mínimas, media y máximas del período comprendido entre 1970 y 2007. La temperatura media del aire oscila entre 9,4 °C, (enero) y 30,6 °C (julio). Las temperaturas mínima/(máxima) oscilan entre -1,3 °C/(4,1 °C) en enero y 13,5 °C/(21,9 °C) en julio, respectivamente, caracterizando el mes de enero como el más frío del año y el de julio como el más cálido.

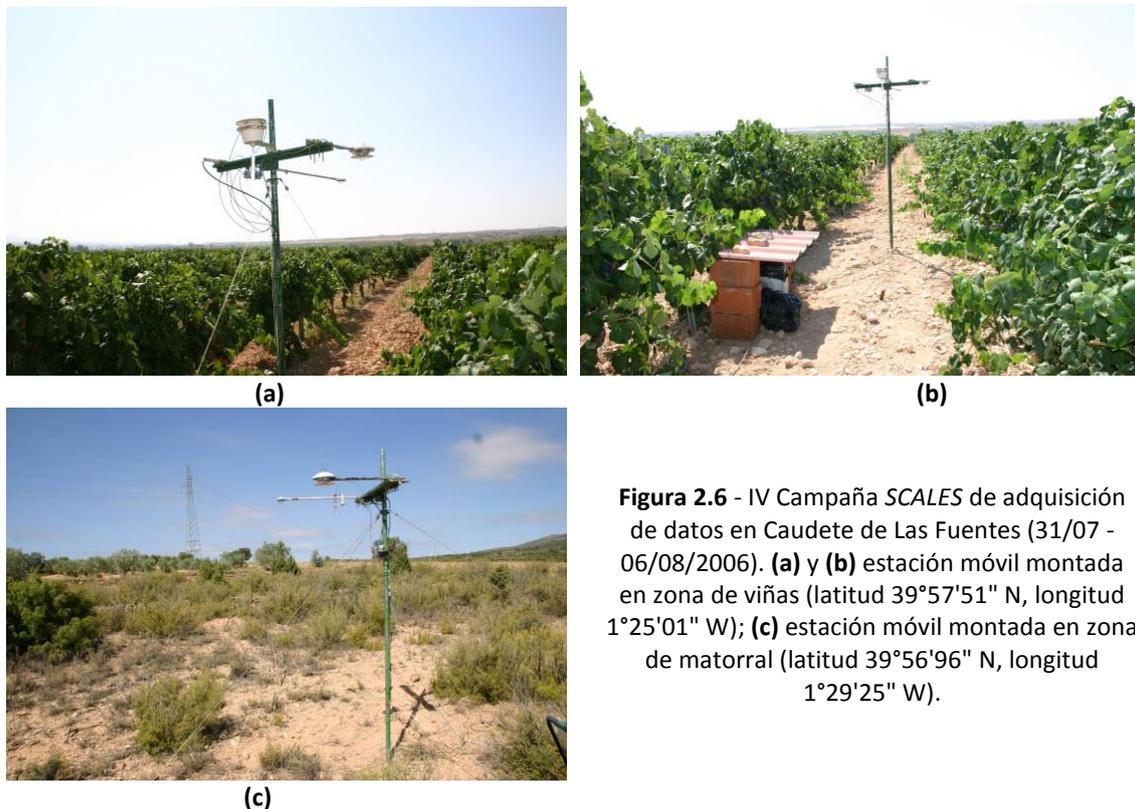


**Figura 2.5** - Média climatológica mensual (1970 - 2007) de las temperaturas del aire a 2 m de altura (mínima, media y máxima) registradas en la estación meteorológica de AEMET en Caudete de las Fuentes (latitud 39°52'28''N y longitud 1°31'71''W). La estación meteorológica se encuentra situada a una distancia relativa de la VAS de 5,95 km.

## 2.3 Campañas Experimentales

### 2.3.1 IV Campaña SCALES

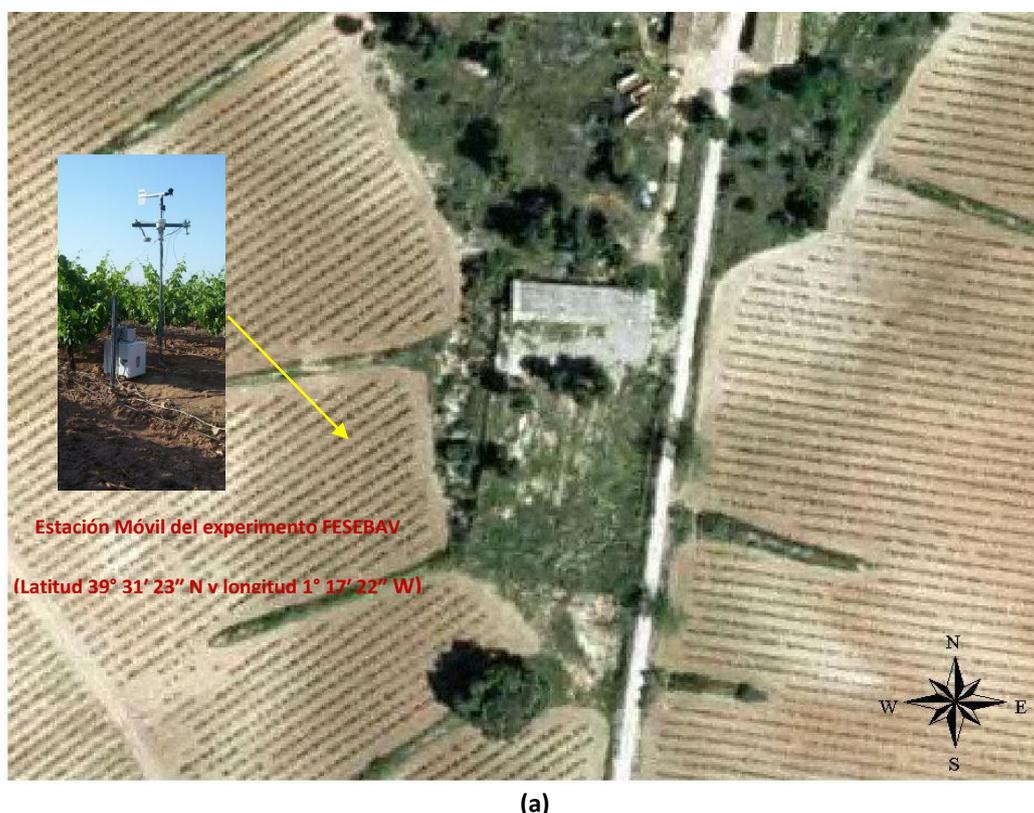
La campaña de campo de 2006 denominada *IV Campaña SCALES* (Área de Calibración/Validación para Experimentos de Campo en Gran Escala con *SEVIRI/GERB*) transcurrió entre el 31 de julio y el 7 de agosto de 2006, y su objetivo fundamental era la validación de radiancias y flujos de *GERB* (*Geostationary Earth Radiation Budget*) y *CERES* (*Clouds and the Earth's Radiant Energy System*), así como a la obtención de flujos de alta resolución con *SEVIRI* (*Spinning Enhanced Visible and Infrared imagen*). La campaña se desarrolló en Caudete de Las Fuentes y consistió en una primera fase en el montaje e instalación de dos estaciones micrometeorológicas móviles, una en viñas (Figura 2.6a) y otra en matorral (Figura 2.6b). La segunda fase consistió en la recogida de datos relativos a las siguientes variables: temperatura del aire a 2m de altura, radiación neta, radiación solar incidente y reflejada a 2 m de altura, temperatura del suelo en superficie y a diferentes profundidades (5 cm, 10 cm, 15 cm y 25 cm), flujo de calor en el suelo en dos niveles (7,5 cm y 12,5 cm), humedad relativa del aire a 2 m de altura y humedad del suelo a 5 cm de profundidad.



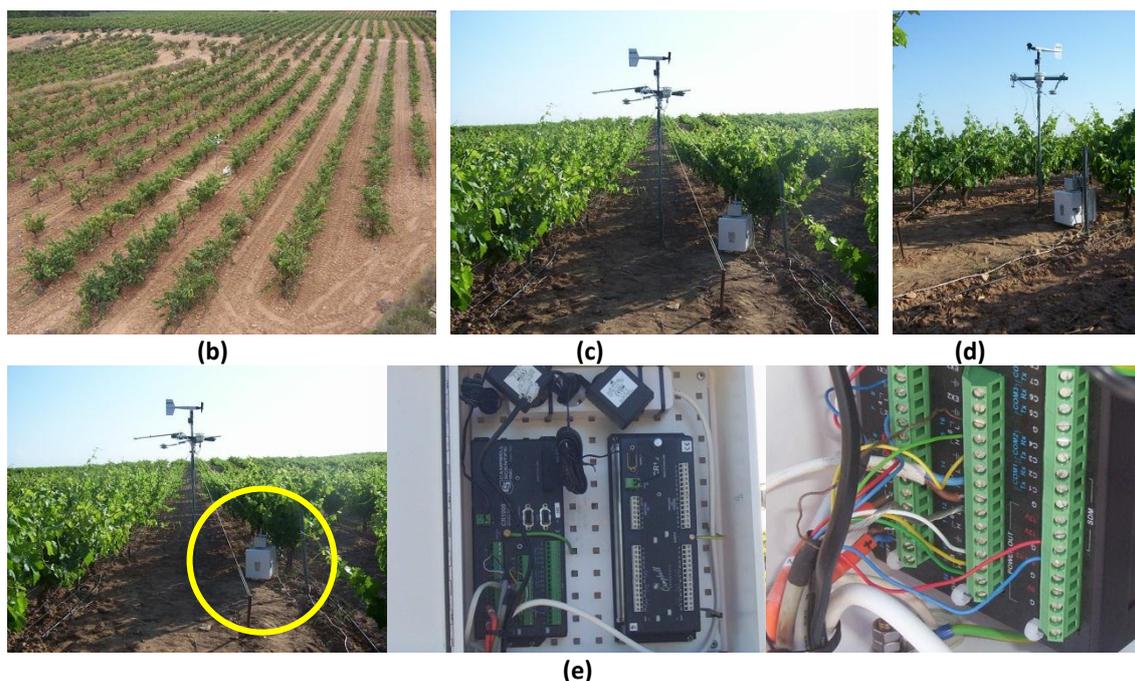
**Figura 2.6** - IV Campaña SCALES de adquisición de datos en Caudete de Las Fuentes (31/07 - 06/08/2006). **(a)** y **(b)** estación móvil montada en zona de viñas (latitud 39°57'51" N, longitud 1°25'01" W); **(c)** estación móvil montada en zona de matorral (latitud 39°56'96" N, longitud 1°29'25" W).

### 2.3.2 Campaña FESEBAV 2007

El experimento denominado *FESEBAV-2007 (Field Experiment on Surface Energy Balance Aspects in the Valencia Anchor Station area)* tuvo como objetivo principal la adquisición de datos *in situ* con la finalidad de establecer el balance de energía en superficie a partir de datos de los sensores *SEVIRI/GERB*, a bordo del satélite *MSG (Meteosat Second Generation)*, haciendo un seguimiento de las viñas durante la mayor parte de su ciclo fenológico. El experimento de campo se llevó a cabo entre los meses de mayo y septiembre de 2007 e incluía medidas de los siguientes parámetros: temperatura del aire a 2 m de altura, temperatura de la superficie del suelo y a profundidades de 5 cm, 10 cm, 15 cm y 25 cm, flujos de calor en el suelo a 7,5 cm y 12,5 cm, flujos de radiación (incidente, reflejada y neta) a 2 m de altura, dirección y velocidad del viento a 2,10 m de altura, humedad del suelo a 5 cm y 35 cm de profundidad y humedad relativa del aire a 2 m de altura. La localización del experimento *FESEBAV-2007*, y detalles de la estación micrometeorológica, situada en zona de viñas, se muestran en la Figura 2.7.



**Figura 2.7** - Experimento *FESEBAV-2007*: (a) ortofoto con la localización del sitio experimental *FESEBAV-2007*.



**Figura 2.7 (continuación)** - Experimento FESEBAV-2007: **(b)** vista aérea del cultivo de viñas donde estaba localizada la estación móvil (latitud 39°31'23" N, longitud 1°17'22" W), **(c)** y **(d)** detalles de la estación micrometeorológica móvil instalada en medio de las viñas, y **(e)** detalle de los dataloggers *Campbell CR1000* utilizados en el experimento FESEBAV-2007, para recogida de datos.

## 2.4 Metodología de adquisición de los datos

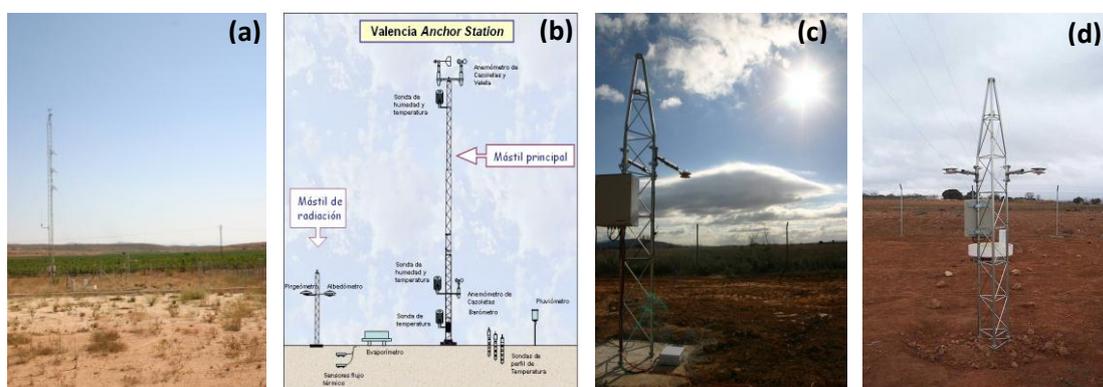
En la campaña de 2006, los datos de los sensores instalados en la estación micrometeorológica móvil (viñas y matorral) fueron recogidos cada segundo y promediados cada 10 min, utilizándose un *datalogger Li-Cor 1000*. En la campaña de campo de 2007 los datos también se recogieron a través de sensores instalados en una estación micrometeorológica móvil colocada entre las viñas. Los sensores fueron conectados a un *datalogger Campbell CR1000* programado para adquirir medidas cada segundo y almacenar los datos promediados cada diez minutos. Los sensores utilizados para medir los parámetros mencionados anteriormente y su disposición en el sitio experimental se encuentran en la Tabla 2.1.

**Tabla 2.1** - Sensores utilizados para el estudio del balance de energía en superficie durante los experimentos de campo de 2006 y 2007, parámetros medidos y disposición de los sensores.

Parámetros	Instrumentos	Resolución	Rango	Modelo
Flujo de radiación neta a 2m	Net Pyrradiometer (♣)	$\pm 25 \mu\text{V/W m}^{-2}$	0,3 - 60 $\mu\text{m}$	CN1-R
Flujo de radiación solar (incidente y reflejada) a 2m	Albedometer (♦)	$\pm 5 \%$	0 - 1500 $\text{W m}^{-2}$	CM 14
Flujo de calor en el suelo a -7,5 y -12,5 cm	Heat Flux Plate (♣)	$\pm 21 \mu\text{V/W m}^{-2}$		RIMCO HP3
Temperatura del aire a 2 m	Sonda de Temperatura (♠)	$\pm 0,15 \text{ }^\circ\text{C}$	-20 - 80 $^\circ\text{C}$	PT 100/3
Temperatura del suelo (-1 cm, -5 cm; -10 cm; -15 cm y -25 cm)	Sonda de Temperatura (♠)	$\pm 0,15 \text{ }^\circ\text{C}$	-20 - 80 $^\circ\text{C}$	PT 100/3
Humedad relativa del aire a 2m	HMP45C (♠)	$\pm 3 \%$	0,8 - 100 %	HMP45C
Dirección y del viento a 2,10 m	Veleta (♠)	$\pm 3 \text{ }^\circ$	0 - 360 $^\circ$	RM Young 05103
Velocidad del viento a 2,10 m	Anemómetro (♠)	$\pm 0,3 \text{ m s}^{-1}$	0 - 60 $\text{m s}^{-1}$	RM Young 05103
Contenido de agua en el suelo a -5 y -35 cm horizontal	ThetaProbe (♥)	$\pm 0,01 \text{ mm}^3 \text{ mm}^{-3}$		ML2x

Fabricante y localización: (♣) Middleton & Co. Pty.Ltd, Australia; (♦) Kipp & Zonen, Netherland; (♠) Campbell Scientific Ltd., USA y (♥) Delta-T Devices Ltd, USA.

Como la VAS (Figura 2.8) es una estación de referencia, se recogieron datos continuamente durante las dos campañas de campo ya citadas, principalmente datos de radiación de onda corta (incidente y reflejada) y onda larga (incidente y emitida por la superficie). Los sensores instalados en la VAS están conectados a un *datalogger* *Meteorodata de Geonica* que también recoge datos cada segundo, haciendo promedios cada diez minutos. Los sensores y parámetros medidos en la VAS se encuentran listados en la Tabla 2.2.



**Figura 2.8** - Valencia Anchor Station: (a) mástil principal de la VAS (latitud 39°34'15" N , longitud 1°17'18" W) donde están instalados los sensores para medir parámetros meteorológicos; (b) esquema de los sensores de la VAS; (c) y (d) mástil secundario donde están montados los sensores para medir parámetros de radiación.

**Tabla 2.2** - Relación de parámetros medidos en la VAS y disposición de los sensores

Parámetros	Instrumentos	Resolución	Rango	Modelo
Velocidad del viento a 2 y 15m	Anemómetro (♠)	$\pm 0,1 \text{ m s}^{-1}$	$0 - 50 \text{ m s}^{-1}$	03102
Dirección del viento a 15 m	Veleta (♠)	$\pm 1^\circ$	$0 - 360^\circ$	03302
Temperatura del aire a 0,5 m	Sonda de Temperatura (*)	$\pm 0,1^\circ\text{C}$	$-50 - 50^\circ\text{C}$	STA-212-PVC
Temperatura del aire y Humedad relativa a 2 y 15 m	Sonda de Temperatura y Humedad relativa (*)	$\pm 0,1^\circ\text{C}$	$-50 - 50^\circ\text{C}$	50U-44212
Presión atmosférica	Barómetro (▲)	$\pm 1 \text{ mb}$	$600 - 1100 \text{ mb}$	SPA-900
Radiación SW reflejada y neta	Albedómetro (◆)	$\pm 1 \text{ W m}^{-2}$	$0 - 1500 \text{ W m}^{-2}$	CM14
Radiación LW emitida y neta	Pirgeómetro (◆)	$\pm 1 \text{ W m}^{-2}$	$0 - 1500 \text{ W m}^{-2}$	CG2
Perfil de temperatura en el suelo	Sonda de Temperatura (*)	$\pm 0,1^\circ\text{C}$	$-50 - +50^\circ\text{C}$	STS-212-PVC
Flujo de calor en el suelo	Flujímetro (♣)	$\pm 1 \text{ W m}^{-2}$	$0 - 1500 \text{ W m}^{-2}$	HP3/CN3
Precipitación	Pluviómetro (♠)	$\pm 0,1 \text{ mm}$	$0 - 26 \text{ mm}$	52202/52203

Fabricante y localización: (◆) Kipp & Zonen, Netherland; (♣) Middleton & Co. Pty.Ltd, Australia; (♠) Campbell Scientific Ltd, USA; (\*) Vaisala, USA; y (▲) Druck limited, USA.

Los datos de temperatura de la superficie terrestre (*LST*), con resolución temporal de 15 minutos, se obtuvieron a partir del sensor *SEVIRI* canales espectrales IR 10,8  $\mu\text{m}$  y IR 12,0  $\mu\text{m}$ , generados con resolución espacial de 3 km en el nadir y precisión variando entre 1 y 2 K. Este sensor vuela a bordo de los satélites de órbita geoestacionaria *MSG*, operados por *European Organisation for the Exploitation of Meteorological Satellites (EUMETSAT)*.

Las imágenes *MSG-SEVIRI* de *LST*, en formato *Hierarchical Data Format (HDF, HDF4 o HDF5)*, se obtuvieron de *LandSAF-LSA SAF "Land Surface Analysis Satellite Applications Facility"*, vía *File Transfer Protocol (FTP)* en la dirección electrónica <https://landsaf.meteo.pt/products/disseminationMethod.jsp>.

Los datos de flujo de onda corta (*SWF*) y flujo de onda larga (*LWF*), flujos que se corresponden con las densidades de flujo radiativo de la energía solar reflejada y emitida en el techo de la atmósfera (*TOA*), con resolución temporal de 15 minutos y resolución espacial de  $12 \times 15 \text{ km}^2$ , se obtuvieron a partir del sensor *GERB*, también a bordo de *MSG*. Las dos bandas espectrales de *GERB* van, respectivamente, desde 0,32

a  $100,0 \mu\text{m}$  (*TOT*) y desde  $0,32$  a  $4,0 \mu\text{m}$  (*SW*), y la onda larga, que varía entre  $4,0$  y  $100,0 \mu\text{m}$ , se obtiene por sustracción ( $LW = TOT - SW$ ).

Las imágenes *MSG-GERB* de alta resolución, generadas a partir de la sinergia entre *GERB* y *SEVIRI*, con precisión de 1% para *SWF* y 0,5% para *LWF*, se obtuvieron directamente del *Royal Meteorological Institute of Belgium (RMIB)*, en formato *HDF*, vía *FTP*.

Las imágenes *SEVIRI* y *GERB* se corresponden con las campañas de campo *SCALES* y *FESEBAV-2007*, mencionadas en los Ítems 2.3.1 y 2.3.2, respectivamente. Durante el desarrollo de la Tesis se procesaron 2703 imágenes *SEVIRI*, de aproximadamente  $4,3 \text{ MB}$  cada, y 12606 imágenes *GERB*, de aproximadamente  $47,8 \text{ MB}$  cada una.

Para más detalles acerca de los satélites de órbita geoestacionaria *METEOSAT*, y los sensores *SEVIRI* y *GERB* a bordo de los satélites de la serie *MSG*, ver Apéndice I.

## MODELIZACIÓN DE LA RADIACIÓN NETA Y DEL FLUJO DE CALOR EN EL SUELO

### 3.1 Introducción

La importancia de la radiación neta en superficie y del flujo de calor en el suelo, componentes significativos del balance de energía en superficie, ya fue brevemente discutida en el Capítulo 1. En este apartado examinaremos la serie temporal del flujo de calor en el suelo y de la radiación neta en superficie a partir de los datos recogidos durante el experimento *FESEBAV-2007* para poder deducir el flujo de calor en el suelo a partir de la radiación neta medida en superficie. Además, también se presenta una nueva metodología basada en modelos neuronales para la estimación de la radiación neta en superficie a partir de parámetros meteorológicos y cuyos resultados se comparan con los obtenidos por otros modelos habituales de la bibliografía. Entendemos que esta metodología supone un avance significativo en la estimación de este parámetro que, habitualmente, no se mide de forma rutinaria.

### 3.2 El flujo de calor en el suelo

El flujo de calor en el suelo es función de las características y estado del sistema, flujo radiante que recibe, propiedades térmicas que posee, y su contenido en agua (Casanellas, 2003). Este calor se transfiere al suelo o se intercambia con la atmósfera, a través de diferentes procesos, entre los cuales destacamos la convección, la conducción, la radiación, la evaporación y la condensación del agua.

Aunque la convección y la radiación juegan un cierto papel en la transferencia de calor en el suelo, la conducción es, sin embargo, el mecanismo principal de transporte y es la ley de Fourier la que proporciona el flujo de calor en el suelo (López-

Baeza, 1993). La ley de Fourier para la conducción del calor en un medio homogéneo viene dada como,

$$G = -\lambda \frac{\partial T}{\partial z} \quad (3.1)$$

donde  $G$  es el flujo de calor en el suelo ( $\text{W m}^{-2}$ ),  $\lambda$  es la conductividad térmica del suelo ( $\text{W m}^{-1} \text{K}^{-1}$ ), que da una medida de la capacidad del suelo para conducir calor, y  $\frac{\partial T}{\partial z}$  es el gradiente de la temperatura del suelo. El signo menos en la Ecuación 3.1 significa que el transporte de calor se produce en el sentido contrario al gradiente de temperatura, es decir, de las temperaturas más calientes hacia las temperaturas más frías.

Para un volumen de suelo homogéneo y suponiendo que los puntos situados a una misma profundidad definen un plano isoterma, la temperatura  $T$  es independiente de las direcciones (x,y) por lo que, en ausencia de producción de calor en el volumen considerado, tenemos que:

$$C_V \left( \frac{\partial T}{\partial t} \right) = \frac{\partial}{\partial z} \left( \lambda \left( \frac{\partial T}{\partial z} \right) \right) \quad (3.2)$$

donde  $C_V$  es la capacidad calorífica volumétrica, definida como el producto entre el calor específico ( $c_s$ ) y la densidad del suelo ( $\rho_s$ ): [ $C_V = \rho_s c_s$ ], y  $z$  es la profundidad.

Si consideramos  $\lambda$  constante, el cambio de temperatura en el suelo puede expresarse mediante:

$$\frac{\partial T}{\partial t} = \frac{\lambda}{C_V} \frac{\partial^2 T}{\partial z^2} \quad (3.3)$$

El término  $\frac{\lambda}{C_V}$  es la difusividad térmica,  $\kappa$ , ( $\text{m}^2 \text{s}^{-1}$ ), que expresa la velocidad con que se transmite una perturbación térmica a lo largo de una cierta distancia. Así, la Ecuación 3.3 puede ahora escribirse

$$\frac{\partial T}{\partial t} = \kappa \left( \frac{\partial^2 T}{\partial z^2} \right) \quad (3.4)$$

Por lo tanto,  $G$  puede calcularse después de resolver la ecuación diferencial (3.4) que describe la conducción unidimensional de calor en un suelo homogéneo. Pero, en realidad y de manera general, el flujo de calor en el suelo dependerá de una forma compleja de sus propiedades térmicas, ya que su temperatura y la de la capa de aire en contacto con el suelo están fuertemente acopladas. Además de eso, las propiedades térmicas del suelo dependen de varios factores tales como el tipo de superficie (desnuda o con vegetación), tipo de suelo, si está seco, húmedo, cubierto con hielo o nieve, etc.

La importancia de  $G$ , los problemas asociados con su medición/estimación y los errores asociados, se han discutido en diversos trabajos. Según Anandakumar *et al.* (2001), la estimación precisa de los parámetros térmicos del suelo y de  $G$  son importantes para la modelización numérica implicada en estudios de balance de energía en superficie. Pero, de acuerdo con Liebenthal *et al.* (2005), con frecuencia se ignora  $G$  (por considerarse  $G \approx 0$ ) en estos estudios, mientras que la mayor parte del tiempo,  $G$  desempeña un papel importante en el proceso de transformación de la energía. Ya Lu *et al.* (2005) apuntan hacia la necesidad de corregir las mediciones de  $G$  debido a la diferencia de conductividad térmica entre el fluxímetro (sensor de medida del flujo de calor) y el suelo.

También hay que destacar que, principalmente, en regiones áridas o semiáridas,  $G$  juega un papel de gran relevancia en la ecuación de balance de energía en superficie y a la escala de tiempo diurna (Oke, 1987; Mayocchi y Bristol, 1995; Wang y Bras, 1999; Verhoef, 2004; y Murray y Verhoef, 2007). En un suelo desnudo,  $G$  puede llegar a valer varias decenas por ciento de  $R_n$ , pero puede normalmente ser un término menor en el balance de energía para una superficie con vegetación (Cellier *et al.*, 1996, citando Fuchs y Hadas, 1972 e Idso *et al.*, 1975b).

En este trabajo el flujo de calor en el suelo en superficie se ha estimado de acuerdo con (Kustas *et al.*, 2000);

$$G = G_{(z=7,5 \text{ cm})} + \frac{C_v \Delta T_s \Delta z}{\Delta t} \quad (3.5)$$

donde  $G_{(z=7,5cm)}$  es el flujo de calor en el suelo ( $W m^{-2}$ ) medido a 7,5 cm de profundidad,  $\Delta Ts = T_{7,5cm}^f - T_{7,5cm}^i$  ( $T^f$  es la temperatura final ( $^{\circ}C$ ) en tiempo  $t_f$  y  $T^i$  es la temperatura inicial ( $^{\circ}C$ ) en tiempo  $t_i$ ),  $\Delta t = t_f - t_i$  (es la duración de la medida:  $t_f$  es el tiempo final y  $t_i$  el tiempo inicial), y  $C_v$  es la capacidad calorífica volumétrica del suelo ( $J m^{-3} K^{-1}$ ) que se calcula de acuerdo con De Vries (1963):

$$C_v = 4,18 \times 10^6 (0,46 \theta_m + 0,60 \theta_o + \theta_w) \quad (3.6)$$

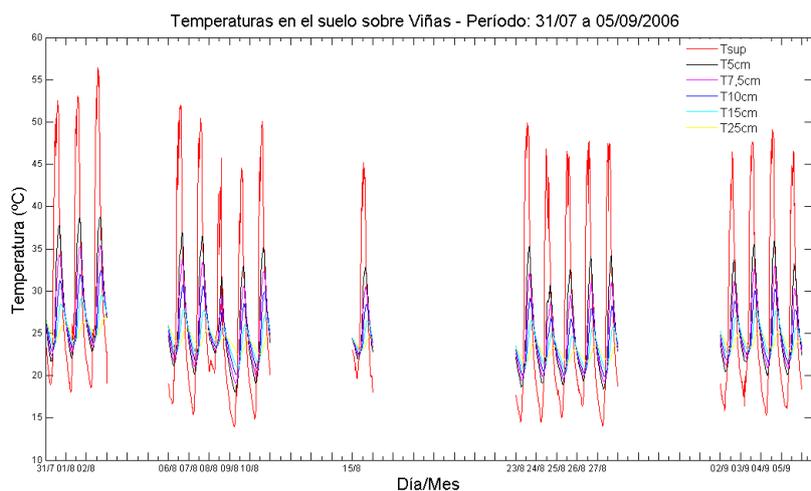
donde  $\theta_m$  es la fracción volumétrica de material mineral,  $\theta_o$  la fracción volumétrica de materia orgánica, y  $\theta_w$  la fracción volumétrica de agua.  $\theta_m$  y  $\theta_o$  se obtienen a partir de análisis de laboratorio y  $\theta_w$  se midió continuamente, *in situ*, conjuntamente con  $T_s$  y  $G_{(z=7,5cm)}$  utilizándose, respectivamente, los sensores: *ML2x ThetaProbe soil moisture sensor (Delta-T Devices, UK)* *platinum resistance thermometers PT100 (Campbell Scientific Ltd)* y *RIMCO HP3 heat flux plate (McVan Instruments, Australia)*.

### 3.2.1 Datos utilizados para estimar el flujo de calor en superficie

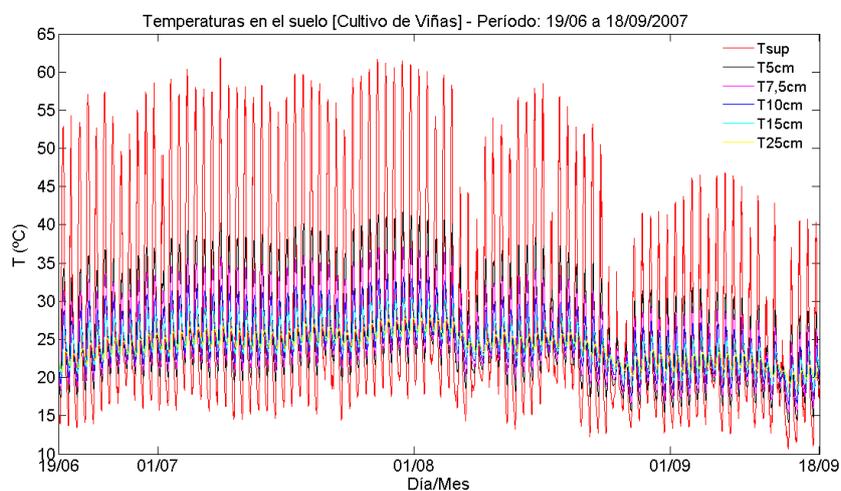
Se muestran, a continuación, los gráficos y los estadísticos de la serie temporal de medidas de temperatura, flujo de calor en el suelo, humedad del suelo, y capacidad calorífica volumétrica. Nótese que las series temporales de  $G$  y  $C_v$  se generaron a partir de las Ecuaciones 3.5 y 3.6, respectivamente, utilizándose como datos de entrada algunos de los parámetros medidos durante las campañas de campo realizadas en 2006 y 2007. Para más detalles sobre estas campañas y la localización de las estaciones móviles instaladas entre las viñas, ver capítulo 2.

#### 3.2.1.1 Estudio estadístico y análisis de las series temporales

En las Figuras 3.1 y 3.2 se muestran las series temporales de la temperatura en superficie y en el suelo a las profundidades de 5, 7,5, 10, 15 y 25 cm, donde se puede observar la evolución diaria de la temperatura a diferentes profundidades.



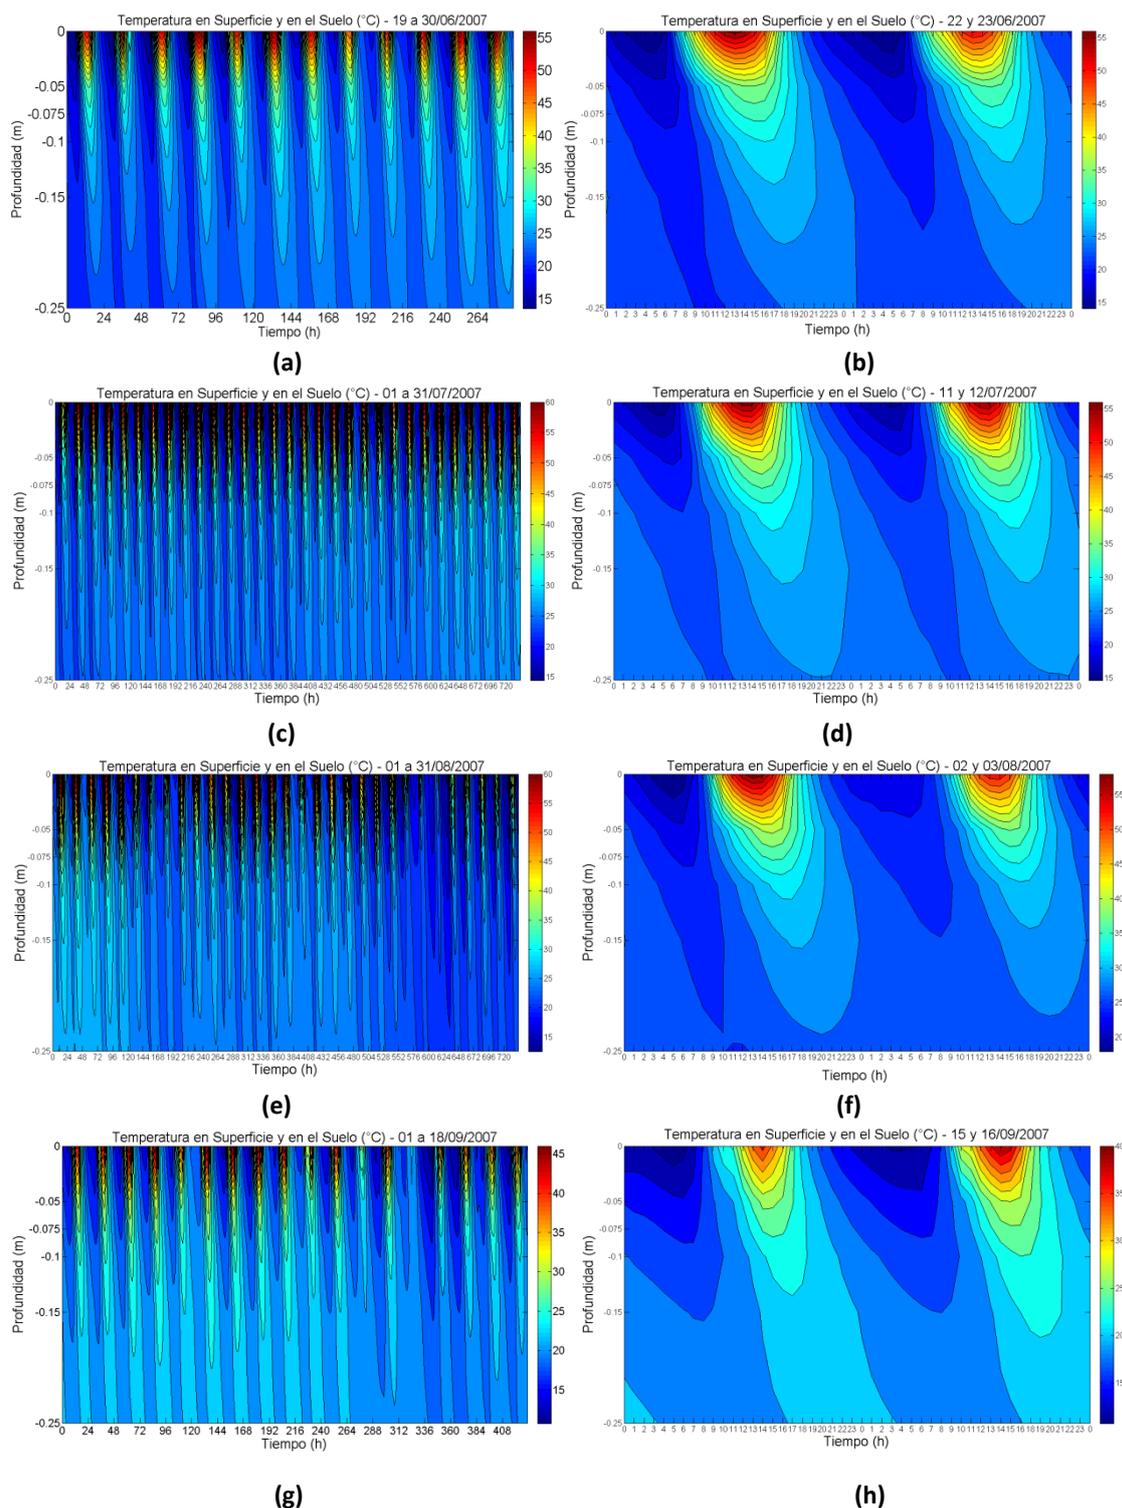
**Figura 3.1** - Serie temporal de la temperatura en superficie ( $\approx 1$  cm), a 5 cm, 7,5 cm, 10 cm 15 cm y 25 cm de profundidad en el suelo. Período: 31/07 a 05/09/2006.



**Figura 3.2** - Serie temporal de la temperatura en superficie ( $\approx 1$  cm), a 5 cm, 7,5 cm, 10 cm 15 cm y 25 cm de profundidad en el suelo. Período: 19/06 a 18/09/2007.

También se puede observar en estas figuras la acentuada oscilación de la temperatura en superficie, relacionada con la absorción de la radiación solar por el suelo. Esta oscilación se va amortiguando con la profundidad del suelo, de modo que a 25 cm, esta oscilación diaria de la temperatura es mínima (Figuras 3.1 y 3.2 - color amarillo).

Para los datos de 2007, por ejemplo, la Figura 3.3 muestra que durante el día la superficie del suelo está más caliente que las capas más profundas. Con el transcurso del día, la superficie se va enfriando y las capas inferiores se van calentando. También se observa que la onda térmica proveniente de la superficie va penetrando en el suelo, disminuyendo su amplitud a medida que desciende hacia las capas más profundas del suelo.



**Figura 3.3** - Serie temporal de la temperatura en superficie y en el suelo a las profundidades de 5 , 7,5, 10, 15 y 25 cm. **(a)** 19 a 30/07/2007; **(c)** 01 a 31/07/2007; **(e)** 01/ a 31/08/2007; **(g)** 01 a 18/09/2007 y **(b)** 22 y 23/06/2007; **(d)** 11 y 12/07/2007; **(f)** 02 y 03/08/2007 y **(h)** 15 y 16/09/2007. Las figuras de la derecha muestran el detalle de las figuras de la izquierda, para dos días consecutivos tomados como muestra del periodo respectivo.

Las temperaturas mínimas, máximas y media de la superficie y de las capas de suelo citadas anteriormente se encuentran en la Tabla 3.1. Se hace notar que de aquí

en adelante, en las tablas,  $\sigma$  designará la desviación estándar, y  $N$  el número de datos utilizados.

**Tabla 3.1** - Estadísticos descriptivos para las series temporales de la temperatura ( $^{\circ}$  C) en superficie y en a diferentes profundidades.

Profundidad	Mínimo	Máximo	Media	$\sigma$	N
<i>Periodo: 31/07 a 05/09/2006</i>					
Superficie ( $\approx 1$ cm)	13,9	56,4	27,7	11,0	2592
5 cm	18,0	38,7	25,9	5,1	
7,5 cm	19,1	35,4	25,4	3,9	
10 cm	19,9	32,4	24,8	2,8	
15 cm	20,6	29,5	24,3	1,9	
25 cm	21,4	26,8	23,8	1,2	
<i>Periodo: 19/06 a 18/09/2007</i>					
Superficie ( $\approx 1$ cm)	10,6	61,9	28,8	13,1	13248
5 cm	14,2	41,7	25,8	6,1	
7,5 cm	15,4	37,2	25,3	4,7	
10 cm	16,5	33,2	24,8	3,5	
15 cm	17,8	30,5	24,6	2,6	
25 cm	19,1	27,8	24,1	1,9	

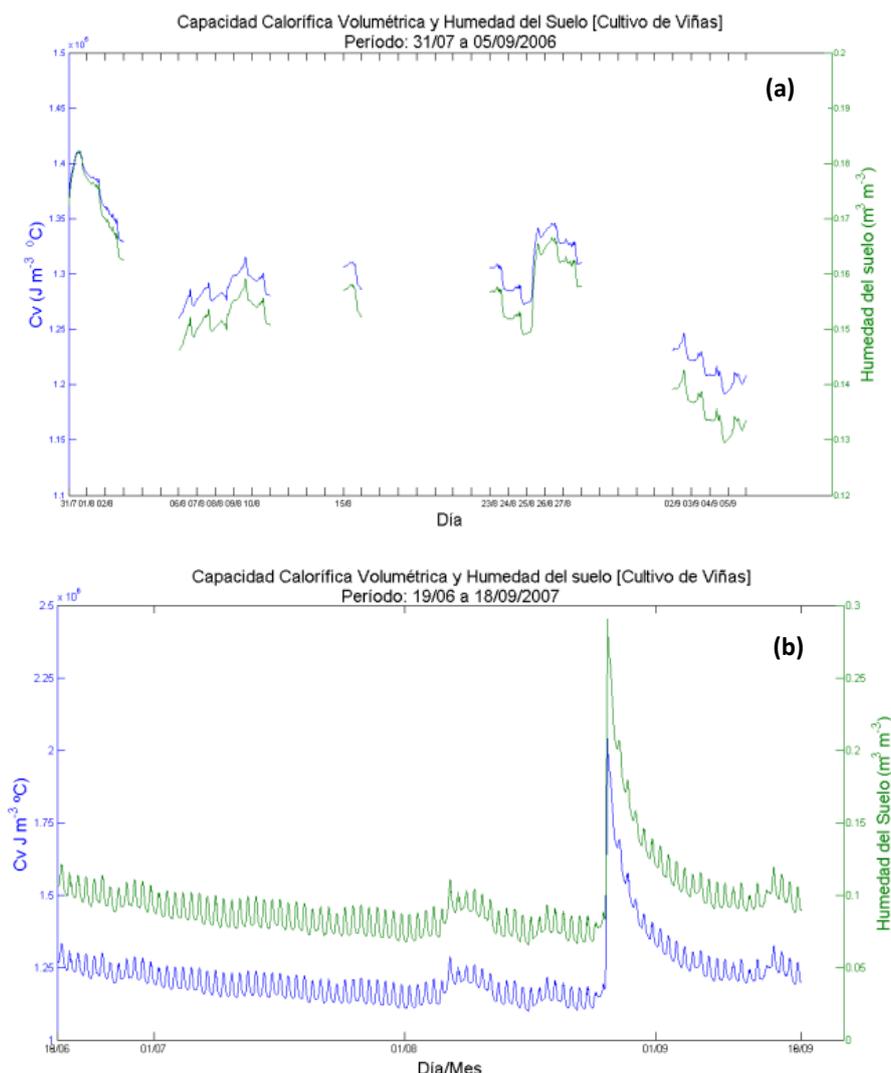
En la Figuras 3.4 (a) y (b) se presentan, respectivamente, las series temporales de capacidad calorífica volumétrica, estimada mediante la Ecuación (3.6) y de humedad del suelo medida “*in situ*” para los períodos indicados. Los estadísticos descriptivos para las campañas de campo de 2006 y 2007 se muestran en la Tabla 3.2.

**Tabla 3.2** - Estadísticos descriptivos para las series temporales de la capacidad calorífica volumétrica  $C_v$  [ $J m^{-3} K^{-1}$ ] y de la humedad del suelo ( $\theta_w$ ) [ $m^3 m^{-3}$ ] medidos a 7,5 cm de profundidad.

Parámetro	Mínimo	Máximo	Media	$\sigma$	N
<i>Periodo: 31/07 a 05/09/2006</i>					
$\theta_w$ ( $m^3 m^{-3}$ )	0,13	0,18	0,15	0,01	2592
$C_v$ ( $J m^{-3} K^{-1}$ )	$1,19 \times 10^6$	$1,41 \times 10^6$	$1,29 \times 10^6$	$5,40 \times 10^4$	
<i>Periodo: 19/06 a 18/09/2007</i>					
$\theta_w$ ( $m^3 m^{-3}$ )	0,07	0,29	0,09	0,03	13248
$C_v$ ( $J m^{-3} K^{-1}$ )	$1,10 \times 10^6$	$2,04 \times 10^6$	$1,22 \times 10^6$	$1,11 \times 10^5$	

Como se puede observar en la Figura 3.4 el efecto de la humedad es aumentar la conductividad térmica del suelo, que en principio debería aumentar la amplitud de

la onda térmica, ya que la respuesta térmica total de un suelo es directamente proporcional a su capacidad de transmitir calor. Pero, el cambio de temperatura que experimenta el suelo como resultado de esa transferencia de calor depende también de su capacidad calorífica por unidad de volumen, es decir, depende de la difusividad térmica.



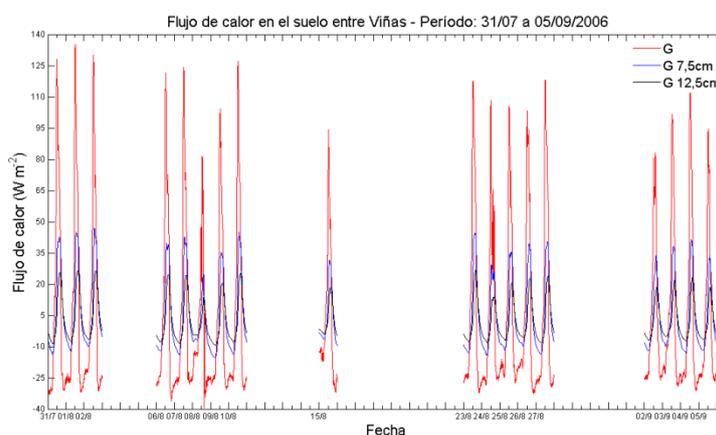
**Figura 3.4** - Capacidad calorífica volumétrica, estimada por la ecuación (3.6) y humedad del suelo. **(a)**: Período: 31 de julio a 5 de septiembre de 2006; **(b)**: Período: 19 de junio a 18 de septiembre de 2007.

El suelo donde estaba instalada la estación meteorológica móvil en 2006 fue clasificado como franco-arenoso y los análisis de laboratorio indicaron una composición de 53% de arena, 31% de limo y 16% de arcilla con una densidad aparente de  $0,97 \text{ g cm}^{-3}$  y 66,93% de porosidad. Teniendo en cuenta estos datos y utilizando la Ecuación (3.6) se determinó que la capacidad calorífica volumétrica ( $C_v$ ) osciló, durante los experimentos entre  $1,19 \times 10^6$  y  $1,41 \times 10^6 \text{ J m}^{-2} \text{ K}^{-1}$ , dependiendo del contenido de

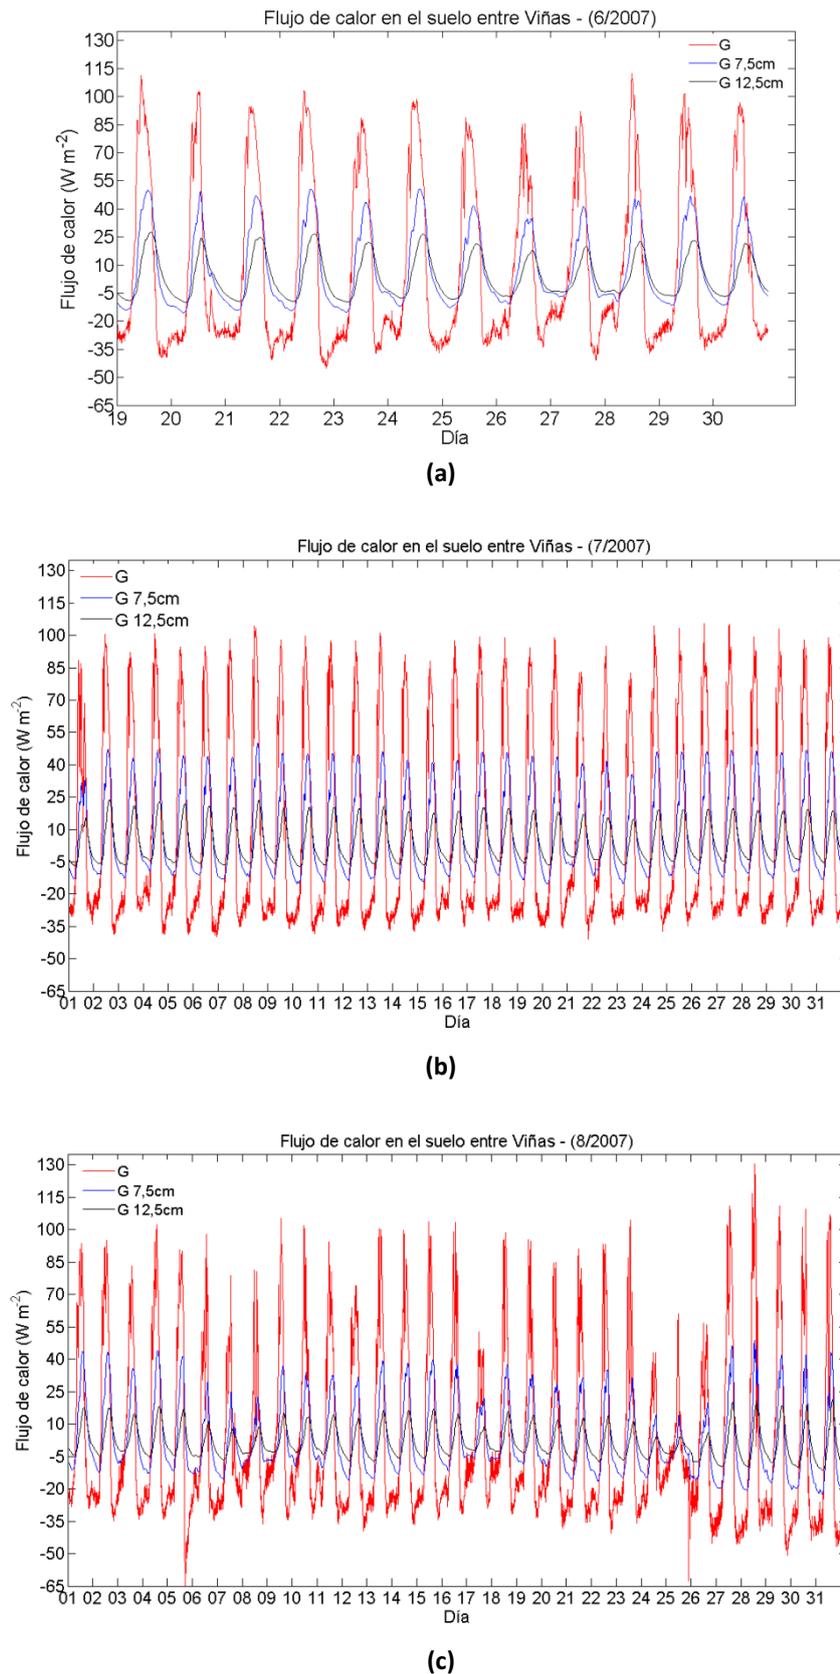
humedad del suelo ( $\theta_w$ ) que, a una profundidad de 7,5 cm, varió entre los valores 0,13 y 0,18  $\text{m}^3 \text{m}^{-3}$  (ver Tabla 3.2). El suelo donde se instaló la estación meteorológica móvil en 2007, fue clasificado como franco-arcillo-arenoso y los análisis de laboratorio indicaron una composición de 51% de arena, 34% de limo y 15% de arcilla con una densidad aparente de 1,10  $\text{g cm}^{-3}$  y 57,49% de porosidad. La capacidad calorífica volumétrica ( $C_v$ ) osciló entre 1,10x10<sup>6</sup> y 2,04x10<sup>6</sup>  $\text{J m}^{-2} \text{K}^{-1}$ , dependiendo del contenido de humedad del suelo ( $\theta_w$ ), que a una profundidad de 7,5 cm, varió entre los valores 0,07 y 0,29  $\text{m}^3 \text{m}^{-3}$  (ver Tabla 3.2).

Durante el período de la campaña de campo de 2006 (31/08 a 05/09/2006), se recogieron 18 días de datos. Durante este período sólo se registró lluvia el día 08/08/2006 con un total diario acumulado de 45,0 mm y el día 17/08/2006 con 19,0 mm. En los 92 días de la campaña de campo de 2007 (19/06 a 18/09/2007), que abarca principalmente los meses de verano, sólo se registraron 9 eventos de precipitaciones, 3 de ellos con una precipitación total diaria más significativa, con valores acumulados de 35 mm (05/08/2007); 20 mm (06/08/2007) y 51 mm (26/08/2007). Este último evento de lluvia se puede ver claramente en la Figura 3.4 y muestra el impacto sobre la humedad del suelo y  $C_v$ . En los otros seis días, la precipitación total diaria varió entre 1 y 7 mm.

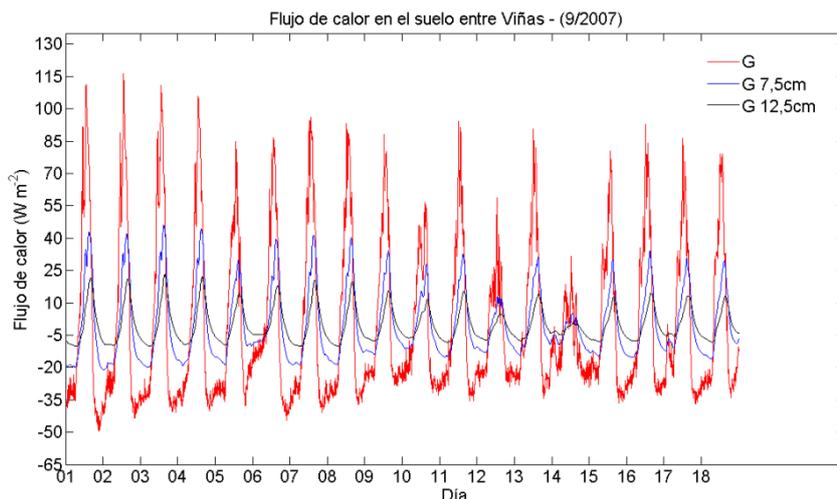
La serie temporal del flujo de calor en el suelo en superficie ( $G \approx 1 \text{ cm}$ ), a 7,5 cm y 12,5 cm de profundidad se presentan en las Figuras 3.5 y 3.6, donde se puede ver la evolución de dicho flujo en cada una de las dos profundidades consideradas.



**Figura 3.5** - Serie temporal del flujo de calor en el suelo en superficie ( $G$ ); a 7,5 cm ( $G_{7,5\text{cm}}$ ); y a 12,5 cm ( $G_{12,5\text{cm}}$ ) de profundidad. Período: 31 de julio a 5 de septiembre de 2006.



**Figura 3.6** - Serie temporal del flujo de calor en el suelo ( $G$ ) en superficie, a 7,5 cm y a 12,5 cm de profundidad. Periodo: **(a)** 19 a 31/06/2007; **(b)** 1 a 31/07/2007 y **(c)** 01 a 31/08/2007.



(d)

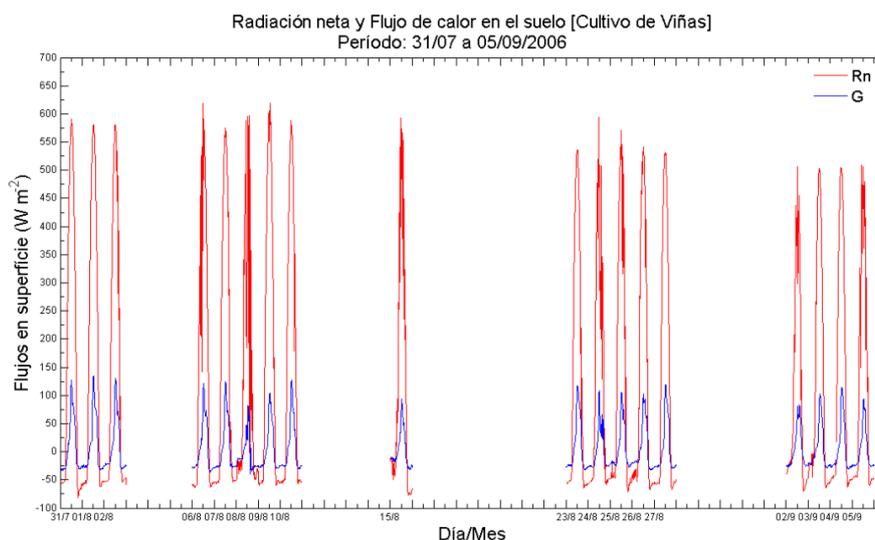
Figura 3.6 (continuación) - Serie temporal del flujo de calor en el suelo ( $G$ ) en superficie, a 7,5 cm y a 12,5 cm de profundidad. Periodo: (d) 01 a 18/09/2007.

Los datos indican (ver Tabla 3.3) que, como media, el flujo de calor a 12,5 cm es 50% inferior al observado a 7,5 cm. Según aumenta la profundidad, o sea, desde la superficie hasta 12,5 cm, más tarde se alcanza el máximo del flujo de calor en el suelo. Los valores máximos en superficie y a 7,5 cm se observan aproximadamente entre las 13 y las 14 horas (UTC) mientras que en 12,5 cm, estos máximos se alcanzan aproximadamente entre las 15 y las 16 horas.

Tabla 3.3 - Estadísticos descriptivos para las series temporales del flujo de calor en el suelo ( $W m^{-2}$ ) entre viñas a diferentes profundidades.

Parámetro	Mínimo	Máximo	Media	$\sigma$	N
<i>Periodo: 31/07 a 05/09/2006</i>					
G en Superficie (~1 cm)	-39,55	135,13	4,53	42,38	2592
G a 7,5 cm bajo el suelo	-15,48	46,92	4,60	17,55	
G a 12,5 cm bajo el suelo	-9,39	26,56	2,54	10,03	
<i>Periodo: 19/06 a 18/09/2006</i>					
G en Superficie (~1 cm)	-64,95	130,60	4,78	41,35	13248
G a 7,5 cm bajo el suelo	-22,54	50,68	4,48	18,46	
G a 12,5 cm bajo el suelo	-11,36	27,66	2,08	8,47	

Las Figuras 3.7 y 3.8 presentan las series temporales de radiación neta y flujo de calor en superficie para los períodos indicados. Durante el experimento de campo de 2006, la radiación neta varió entre  $-81,05 W m^{-2}$  durante la noche hasta  $619,30 W m^{-2}$  durante el día (ver Tabla 3.4). Nótese la gran diferencia de magnitud entre los valores de  $R_n$  y  $G$ .



**Figura 3.7** - Serie temporal de radiación neta y flujo de calor en el suelo. Período: 31 de julio a 5 de septiembre de 2006.

Los valores máximos de  $R_n$  alrededor de  $615 \text{ W m}^{-2}$ , se registraron en torno a las 13:00 h UTC en el mes de agosto de 2006. En septiembre de 2006, los valores máximos de  $R_n$  alrededor de  $505 \text{ W m}^{-2}$ , se registraron en torno a las 12:00 h UTC. En el mes de agosto, las inversiones del flujo de  $R_n$  se registraron alrededor de las 6:00 h y 18:00 h UTC y en septiembre alrededor de 6:00 h y 17:30 h UTC. En agosto, las mínimas alrededor de  $-77 \text{ W m}^{-2}$  y las máximas alrededor de  $618 \text{ W m}^{-2}$  se dieron alrededor de las 19:30 h UTC y 12:30 h UTC, respectivamente. En septiembre, las mínimas alrededor de  $-68 \text{ W m}^{-2}$  y las máximas de  $505 \text{ W m}^{-2}$  se dieron próximas a las 19:00 h UTC y 12:00 h UTC, respectivamente. Los valores medios diarios durante el experimento de 2006 variaron entre  $97,62 \text{ W m}^{-2}$  (02/09/2006) y  $166,99 \text{ W m}^{-2}$  (09/08/2006).

En el experimento de 2007  $R_n$  varió entre  $-73,33 \text{ W m}^{-2}$  hasta los  $741,30 \text{ W m}^{-2}$  (ver Tabla 3.4). Los valores máximos de  $R_n$  alrededor de  $640 \text{ W m}^{-2}$ , se registraron en torno a las 12:00 h UTC en el mes de julio donde valores máximos de radiación solar en superficie se registraron coincidiendo con días de cielo despejado.

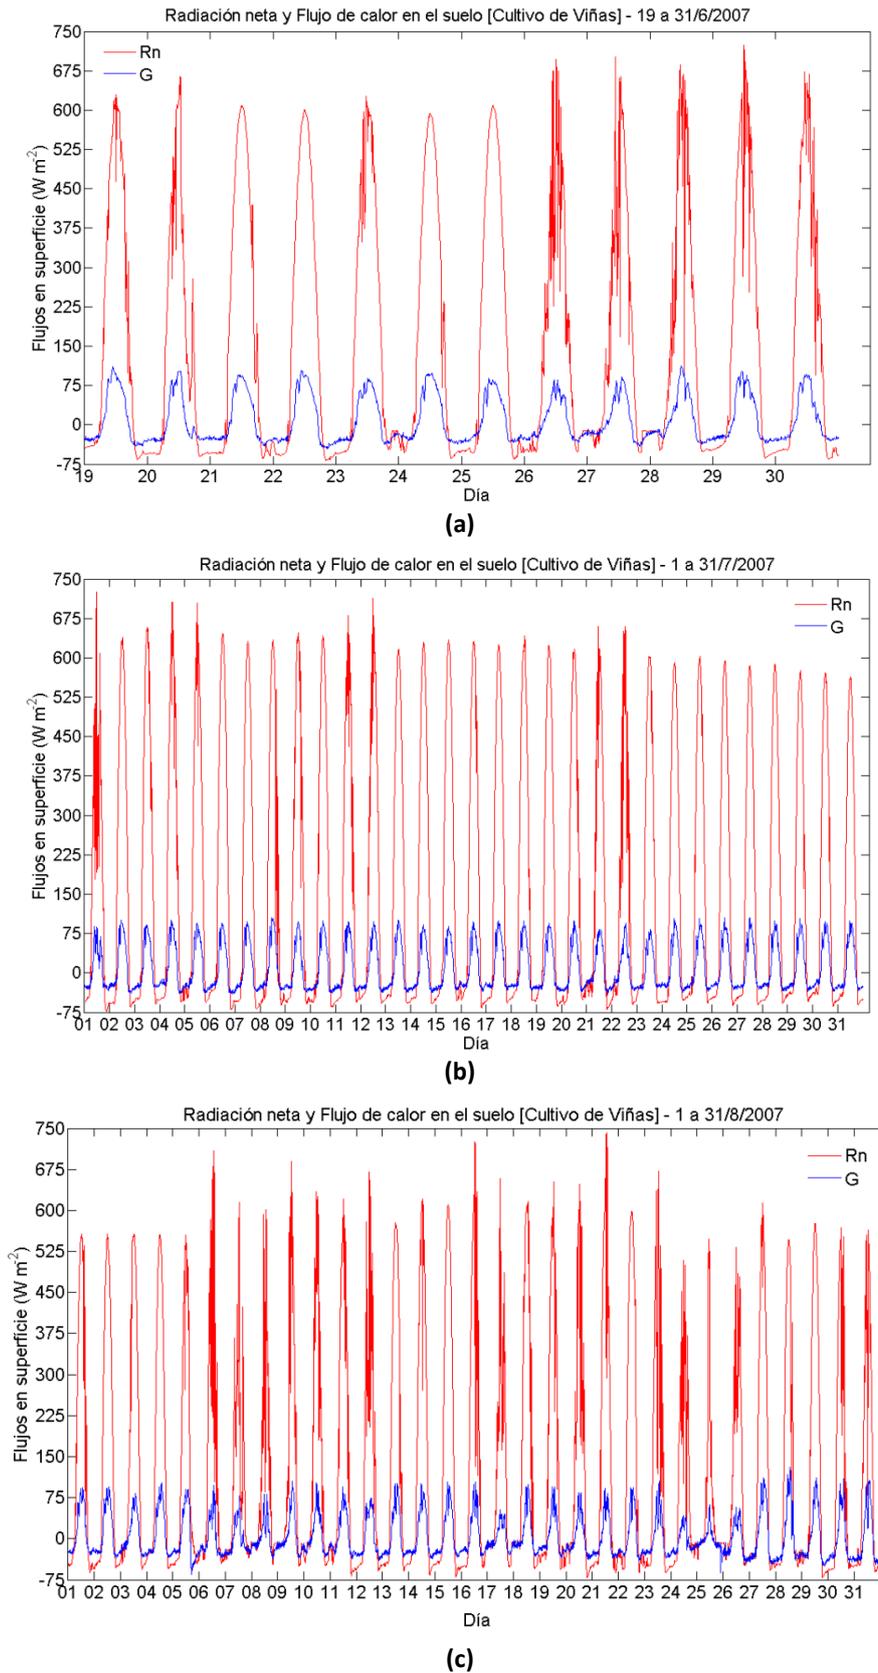
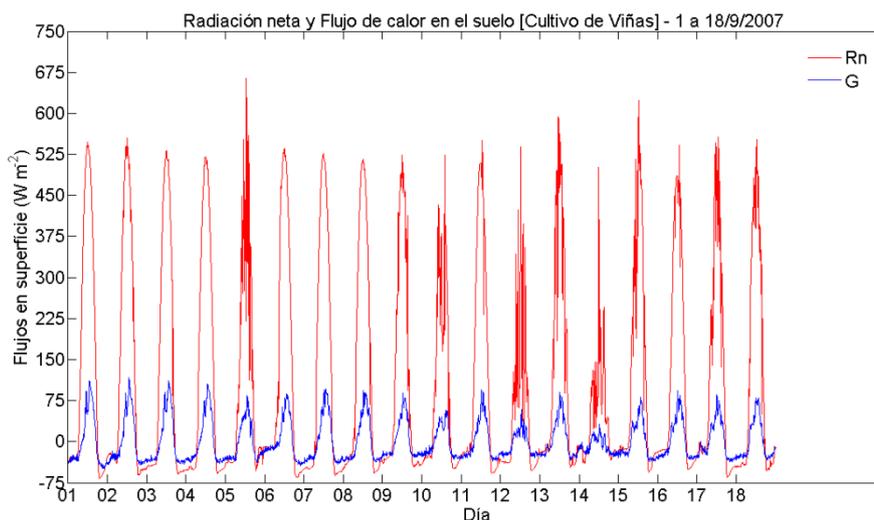


Figura 3.8 - Serie temporal de radiación neta y flujo de calor en el suelo. Periodo: (a) 19 a 31/06/2007; (b) 1 a 31/07/2007 y (c) 01 a 31/08/2007.



(d)

Figura 3.8 (continuación) - Serie temporal de radiación neta y flujo de calor en el suelo. Periodo: (d) 01 a 18/09/2007.

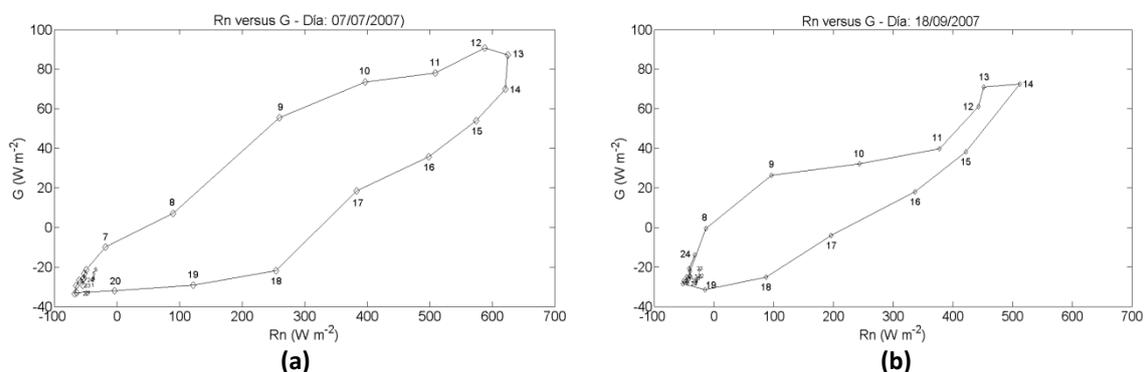
Tabla 3.4 - Estadísticos descriptivos para la serie temporal de la radiación neta en superficie ( $W m^{-2}$ ).

Parámetro	Mínimo	Máximo	Media	$\sigma$	N
<i>Periodo: 31/07 a 05/09/2006</i>					
$R_n$	-81,05	619,30	136,44	226,49	2592
<i>Periodo: 19/06 a 18/09/2007</i>					
$R_n$	-73,33	741,30	144,94	231,24	13248

Picos aislados de  $R_n$  de aproximadamente  $700 W m^{-2}$  se registraron en días posteriores a los eventos de lluvia ( $709 W m^{-2}$  en 06/08/2007, después de la lluvia registrada el día 05/08/2007, ya mencionada anteriormente). En los meses de junio y julio, las inversiones del flujo de  $R_n$  se dieron alrededor de las 5:30 h y 18:30h UTC, en agosto alrededor de las 6:00 h y 18:00 h UTC, y en septiembre alrededor de las 6:00 h y 17:30 h UTC. En junio los valores máximos de  $R_n$  de aproximadamente  $700 W m^{-2}$  se registraron alrededor de las 12:00 h UTC y las mínimas de aproximadamente  $-67 W m^{-2}$  a las 20:00 h UTC. En julio, las mínimas y máximas respectivas de aproximadamente  $-73 W m^{-2}$  y  $710 W m^{-2}$  se registraron a las 21:30 h UTC y 12:00 h UTC. En agosto y septiembre, las mínimas de  $-71 W m^{-2}$  y  $-66 W m^{-2}$  y las máximas de  $730 W m^{-2}$  y  $600 W m^{-2}$  se dieron, respectivamente, alrededor de las 19:00 h UTC y 12:30 h UTC. Los valores medios diarios durante el experimento variaron entre  $39,65 W m^{-2}$

(14/09/2007) y  $191,38 \text{ W m}^{-2}$  (06/07/2007) con valores medios diarios máximos situándose entre el 3 y el 6 de julio, días después del solsticio de verano en el hemisferio norte. Pero, en general, las magnitudes de los valores máximos de  $R_n$  tienden a disminuir a medida que se aleja del solsticio de verano con la disminución de la radiación solar en superficie, como se puede observar en las Figuras 3.7 y 3.8.

Una vez evaluadas las series temporales de  $G$  y  $R_n$ , vamos a discutir a continuación la variación conjunta de  $G$  con  $R_n$ , y para ello utilizaremos los datos de los días 07/07/2007 y 18/09/2007, los cuales se presentan en la Figuras 3.9a y b. Se puede observar que  $R_n$  y  $G$  presentan un comportamiento en forma de lazo en el sentido horario, indicando que el flujo del calor en superficie, para la misma cantidad de radiación neta, es mayor durante la fase de calentamiento (periodo de la mañana), que durante la fase de enfriamiento (periodo de la tarde). Se recuerda aquí que en los días 14 y 15/09/2007, se registró lluvia, lo que conllevó un aumento en la humedad del suelo.



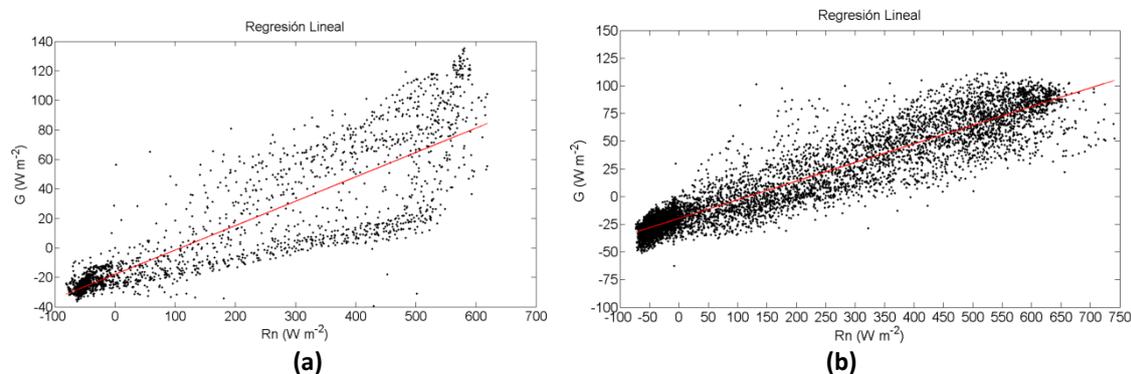
**Figura 3.9** - Relación entre  $R_n$  y  $G$  para las viñas para los días 07/07/2007 **(a)** y 18/09/2007 **(b)**. En ambos casos se dan condiciones de cielo despejado.

Verificamos también que el máximo de  $G$  se alcanza antes que el máximo de  $R_n$ , Figura 3.9a. Según Anandakumar *et al.* (2001), esto se explica por el hecho de que como la superficie del suelo se calienta, la diferencia de temperatura entre la superficie y el aire aumenta, y se transfiere una cantidad apreciable de calor a la atmósfera en forma de flujo de calor sensible y de calor latente. Debido a este hecho, durante la fase de enfriamiento, la cantidad de energía radiante disponible para transformarse en  $G$  es menor comparada con la fase de calentamiento.

En la Figura 3.9b, sin embargo, verificamos también que el máximo de  $G$  se alcanza prácticamente al mismo tiempo que  $R_n$  y la magnitud de los picos es menor que para el caso seco, Figura 3.9a. Dos factores conducen a esta diferencia: (i) la apreciable cantidad de energía que se pierde a la atmósfera en forma de calor latente y (ii) la conductividad y la capacidad térmica del suelo es mayor debido a la presencia de contenido en humedad (Anandakumar *et al.*, 2001). Como se ha mencionado anteriormente, en los días 14 y 15/09/2007, hubo registro de lluvia, lo que conllevó a un aumento en la humedad del suelo.

### 3.2.1.2 Estimación del flujo de calor en superficie a partir de la radiación neta

La Figura 3.10, muestra los diagramas de dispersión entre las variables  $R_n$  y  $G$  indicando que la relación entre ambas variables presenta una tendencia lineal creciente, lo que nos llevó a aplicar un modelo de regresión lineal simple para correlacionar los dos flujos. Para desarrollar y validar el modelo lineal se dividió el conjunto de datos en dos subconjuntos: un conjunto de entrenamiento y otro de validación. Los porcentajes escogidos para esta división fueron, respectivamente, 2/3 y 1/3 del conjunto total de datos. Los modelos lineales obtenidos para cada zona analizada, con el error del ajuste para cada ecuación se presentan en la Tabla 3.5. Los índices de errores que se consideran son la raíz cuadrada del error cuadrático medio ( $RMSE$ ), el error medio absoluto ( $MAE$ ) y el error medio ( $ME$ ). Además, también se incluyen el coeficiente de determinación ( $R^2$ ) y la desviación standard ( $\sigma$ ).

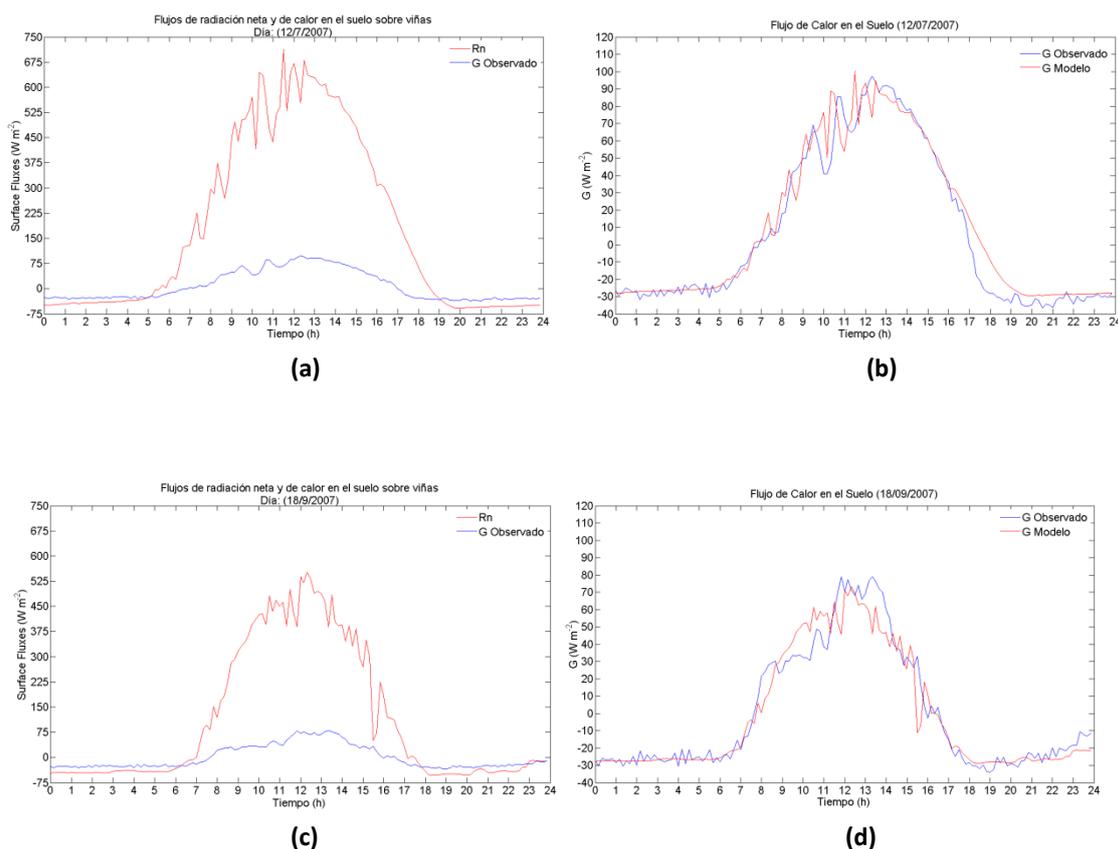


**Figura 3.10** - Diagramas de dispersión de  $R_n$  frente a  $G$  y recta de regresión indicada en rojo. **(a)** año 2006 y **(b)** año 2007. Los datos de  $R_n$  se obtuvieron sobre los cultivos de viña mencionados en el ítem 2.3 del Capítulo 2 y los valores  $G$  se estimaron mediante la Ecuación 3.5.

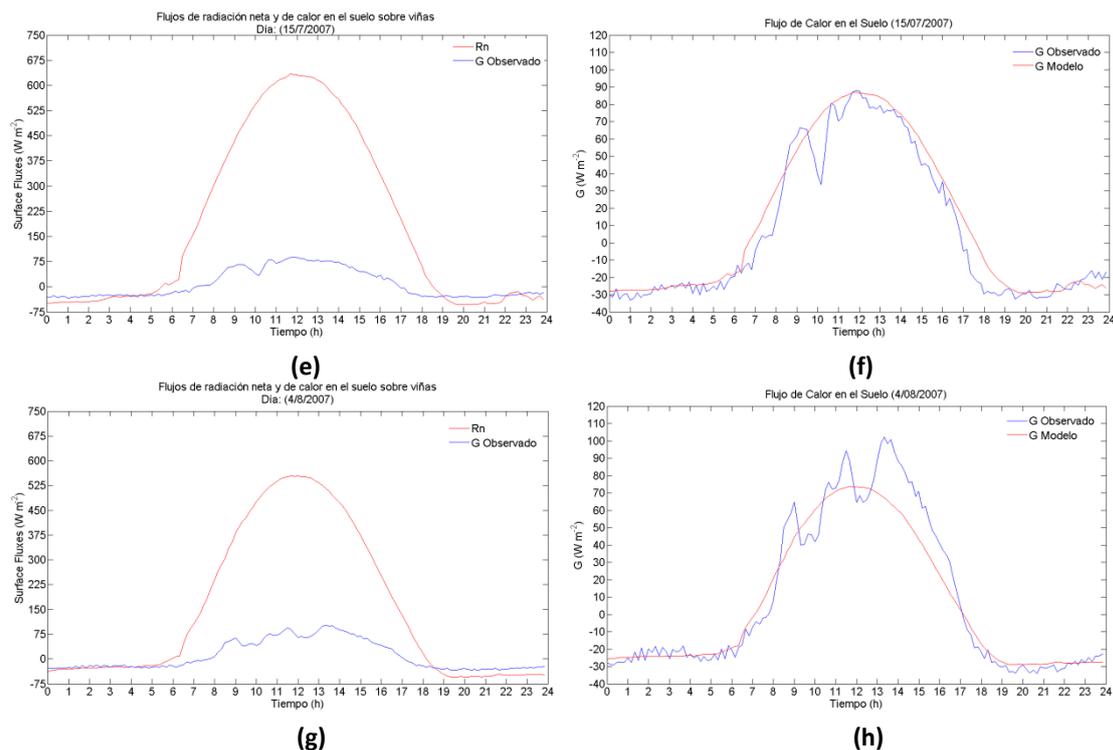
**Tabla 3.5** - Modelos lineales obtenidos para  $G$  y resultados estadísticos de la comparación entre  $G$  estimado a partir de la Ecuación (3.5) y mediante el modelo.  $RMSE$ ,  $MAE$  y  $ME$  se expresan en  $W m^{-2}$ .

Modelo lineal	$R^2$	RMSE	MAE	ME	$\sigma$	N
2006						
$G = 0,17 R_n - 18,6$	0,78	20,36	13,56	0,0	38,18	1728
2007						
$G = 0,17 R_n - 19,7$	0,89	13,73	9,55	0,0	39,14	8784

Para los sitios estudiados, los resultados mostraron que, en promedio, el componente  $G$ , obtenido partir de los modelos lineales, representaba aproximadamente un 18% de  $R_n$ . Pero cuando se considera el promedio horario, para 2007 por ejemplo, el modelo obtenido fue  $G = 0,28 R_n - 36,7$  ( $W m^{-2}$ ), que está en buena concordancia con los modelos  $G = 0,28 R_n - 20$  ( $W m^{-2}$ ) y  $G = 0,26 R_n - 21$  ( $W m^{-2}$ ), obtenidos para un cultivo de viñas, por Oliver y Sene (1992) y Sene (1994), respectivamente.



**Figura 3.11** - Variación diurna de los flujos de  $R_n$  y  $G$  sobre el cultivo de viñas: (a) y (c) valores observados de  $G$  y (b) y (d) estimados a partir del modelo  $G = 0,17 R_n - 19,7$ . Días nublados: (a), (b), (c) y (d).



**Figura 3.11 (continuación)** - Variación diaria de los flujos de  $R_n$  y  $G$  sobre el cultivo de viñas: **(e)** y **(g)** valores observados de  $G$  y **(f)** y **(h)** estimados a partir del modelo  $G = 0,17 R_n - 19,7$ . Días con cielo despejado: **(e)**, **(f)**, **(g)** y **(h)**.

Verificamos a través de las Figuras 3.11e y g que tanto el flujo de radiación como el de calor en el suelo están dominados por el ciclo diario (fundamentalmente en condiciones de cielo despejado) y que los niveles de radiación solar interceptados por el cultivo en estudio, vienen afectados en días nublados Figuras 3.11a y c. Durante el día, en que se tiene radiación de onda corta, las curvas representadas en las Figuras 3.11a, c, e y g presentan valores positivos, mientras que en el periodo de la noche, ocurre lo contrario. Como por la noche no se dispone de radiación de onda corta que llegue a la superficie, los valores negativos representan el saldo de radiación de onda larga. Lo mismo se observa para el flujo de calor en el suelo: durante el día, como la radiación neta es positiva, hay una transferencia de energía, por conducción, hacia el suelo subyacente y éste se calienta. Durante la noche,  $G$  asume valores negativos, pues hay una pérdida radiativa y como  $G$  sale del suelo, éste se enfría (entradas y pérdidas energéticas se consideran positivas y negativas respectivamente).

Teniendo en cuenta los estadísticos presentados en la Tabla 3.5 los modelos desarrollados facilitan una metodología simple para la estimación de  $G$  a partir de  $R_n$ , una vez que se puede observar el ciclo diario de  $G$  con buen grado de fiabilidad.

### 3.3 Modelos de estimación de la radiación neta en superficie

A pesar de su importancia  $R_n$  se mide rutinariamente, con radiómetros netos, sólo en las muy pocas estaciones climatológicas existentes alrededor del mundo, o por científicos en campañas de campo diseñadas específicamente con esta finalidad. Esto se debe en parte a la dificultad de contar con una superficie estándar, pero también a que los instrumentos que miden la radiación neta requieren un mantenimiento continuo (Irmak *et al.*, 2003; Monteith y Unsworth, 1973). Teniendo esto en consideración, varios estudios han dedicado un gran esfuerzo a la determinación lo más precisa posible de  $R_n$  para un determinado lugar, teniendo en cuenta su cobertura vegetal y uso del suelo, a partir de datos meteorológicos, como la temperatura de la superficie del suelo y del aire, la fracción del cielo cubierta por nubes, humedad relativa del aire, la radiación emitida por la atmósfera y la radiación solar entrante, dando origen a diversos modelos que han sido propuestos y evaluados (Carrasco y Ortega-Farías, 2008; de Jong *et al.*, 1980; Irmak *et al.*, 2003; Jegede *et al.*, 2006; Kjaersgaard *et al.*, 2007; Wang y Liang, 2009).

Estos modelos, basados en ecuaciones empíricas con coeficientes procedentes de la literatura o en los principios físicos del balance de energía en superficie, difieren entre sí en cuanto a la complejidad de los datos meteorológicos requeridos como datos de entrada (Sentelhas y Gillespie, 2008). Sin embargo, mirando más detenidamente, la mayoría de las ecuaciones utilizadas para estimar  $R_n$  ya sea a nivel horario, diario o a más largo plazo, necesitan de la radiación solar que llega a la superficie como parámetro de entrada. Pero este parámetro no siempre se mide en la mayoría de las estaciones meteorológicas.

A partir de lo expuesto anteriormente, los objetivos planteados para este apartado fueron: (i) desarrollo de un nuevo modelo para la estimación de  $R_n$  sobre un cultivo de viña empleando Redes Neuronales Artificiales (RNA) y utilizando como datos de entrada parámetros meteorológicos medidos de forma rutinaria en las estaciones meteorológicas, (ii) utilizando datos de campo, generar parámetros locales, para aplicar dos de los modelos lineales (ML) más comúnmente utilizados para la estimación de  $R_n$  (estos modelos utilizan como datos de entrada la radiación solar

incidente y el albedo), y (iii) analizar y comparar la actuación de los modelos lineales frente al modelo neuronal propuesto.

### 3.3.1 Análisis mediante modelos neuronales

En este apartado se describe el modelo neuronal utilizado para estimar la radiación neta en superficie, el Perceptrón Multicapa, y los mapas autoorganizados para pasar, posteriormente, a describir los datos utilizados como parámetros de entrada en el modelo neuronal propuesto. Se dan a continuación los resultados obtenidos y las conclusiones obtenidas del estudio.

#### 3.3.1.1 El Modelo *Perceptrón Multicapa (MLP)* de Redes Neuronales

El *Perceptrón Multicapa (MLP)* es el modelo neuronal artificial (ANN) usado en este trabajo, que consta de unos elementos individuales de proceso, las neuronas, que se disponen en una serie de capas. La Figura 3.12 muestra la estructura de estas neuronas.

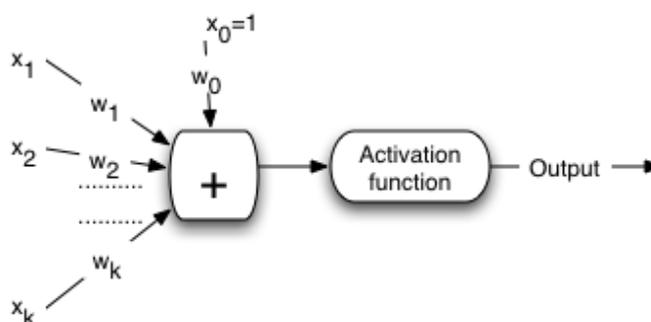


Figura 3.12 - Esquema de una neurona artificial.

En este modelo (Figura 3.12), las *entradas (inputs)*  $x_i$  de una neurona se multiplican por coeficientes sinápticos o adaptativos  $w_i$ , llamados *pesos sinápticos (synaptic weights)*, que representan la conexión entre las neuronas. El sumador (+) determina la suma del producto de las entradas por los coeficientes sinápticos. Si se considera  $w = [w_0, w_1, w_2, \dots, w_k]$ , es inmediato comprobar que dicha suma es el

producto escalar de esos vectores. El coeficiente  $w_0$  tiene un papel relevante en el funcionamiento de la neurona y se conoce como *umbral*. El proceso de buscar los pesos óptimos se conoce como *algoritmo de aprendizaje (learning algorithm)*.

La *función de activación (activation function)*, es la función que le da su carácter no lineal al modelo neuronal. La capacidad de resolución de problemas complejos de las redes neuronales radica precisamente en esta función. La *función sigmoide* (tangente hiperbólica modificada cuyo rango de salida está entre 0 y 1) y la *tangente hiperbólica*, que varía entre -1 y +1 (Figura 3.13), están entre las funciones de activación más utilizadas.

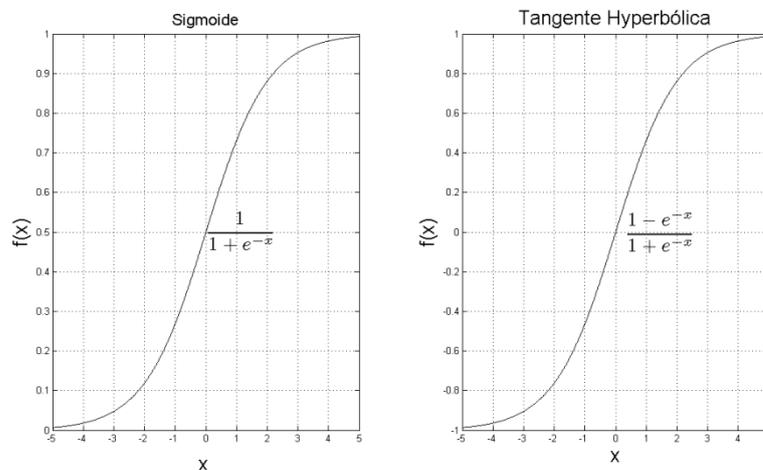


Figura 3.13 - Funciones sigmoide y tangente hiperbólica

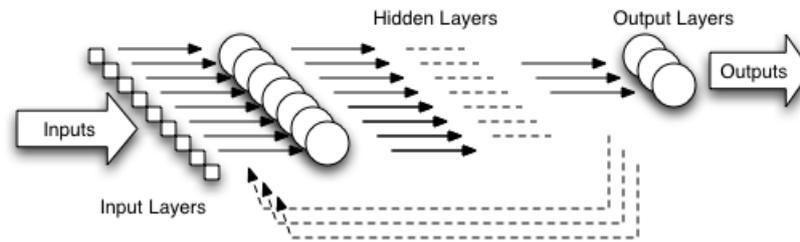
Por lo comentado anteriormente, la salida de la neurona  $j^{th}$  viene dada por

$$O_j = \varphi\left(\sum_{i=0}^m w_{ij} x_i\right) \tag{3.7}$$

donde  $\varphi$  es la función de activación ya mencionada.

Se conoce como *arquitectura de un modelo neuronal* a la forma en que se disponen los elementos de proceso (neuronas). En el *MLP*, esos elementos de proceso se disponen en una serie de capas; la primera de ellas se conoce como *capa de entrada* y la última se conoce como *capa de salida*. Todas las capas intermedias se conocen con el nombre de *capas ocultas* (Arbib, 2003). Esta disposición de capas se debe a que las salidas de las neuronas se utilizan como entradas de capas posteriores (*red no*

retroalimentada) y/o anteriores (redes realimentadas o recurrentes). Un esquema de este tipo de modelo neuronal se puede ver en la Figura. 3.14.



**Figura 3.14** - Esquema de un perceptrón multicapa. Las líneas discontinuas muestran realimentaciones en el modelo; en este análisis no se usan este tipo de conexiones.

El objetivo del algoritmo de aprendizaje es determinar los mejores parámetros de la red para modelizar la relación entre las variables de entrada y de salida. Este objetivo se puede cumplir con un procedimiento de minimización de una función que depende de la diferencia entre el valor de las salidas obtenidas por la red neuronal y el valor de salida deseado, o sea, la señal deseada. El proceso en el que los coeficientes (pesos sinápticos) del *MLP* se ajustan se conoce como *entrenamiento (training)*.

A continuación, destacamos algunas de las características del *MLP* (Haykin, 2008):

- *A priori* no se necesita conocer las relaciones entre las variables del problema planteado. El ajuste entre las variables de entrada y las variables de salida se realiza sin ningún tipo de hipótesis sobre la relación entre las variables.
- Dado que la Ecuación (3.7) no es lineal, la *RNA* actuará como un modelo no lineal. Por lo tanto, la *RNA* debe ser capaz de encontrar relaciones no lineales entre las variables de entrada y de salida(s). De hecho, es posible demostrar matemáticamente que un *MLP* es un modelo de regresión universal, i. e., el *MLP* puede encontrar la relación entre cualquier par de conjuntos de datos, si están relacionados y representan suficientemente el problema (Haykin, 1999).

Finalmente, a continuación, hacemos algunas observaciones sobre el proceso de aprendizaje (Arbib, 2003; Bishop, 1996; Haykin, 1999):

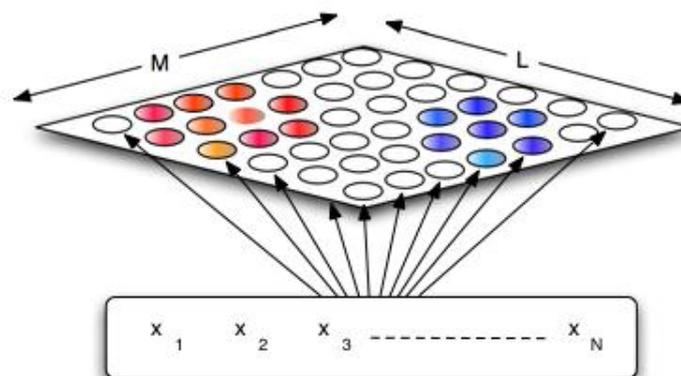
1. La tasa de aprendizaje debe elegirse apropiadamente. El algoritmo de aprendizaje se basa en encontrar el mínimo más cercano de la función que define el funcionamiento de la red, siendo la tasa de aprendizaje un parámetro que mide la velocidad de acercamiento al mínimo,
2. La arquitectura de la red también debe ser elegida adecuadamente. Mientras que el número de neuronas en la capa de entrada y en la capa de salida viene dado por el problema, el número de capas ocultas y la cantidad de neuronas en cada capa oculta se debe elegir en función del problema objeto de estudio,
3. Debido a la naturaleza iterativa del proceso de aprendizaje, es necesario elegir los valores iniciales de los pesos sinápticos. Suelen probarse diferentes valores iniciales para lograr un modelo óptimo, ya que el algoritmo busca el mínimo más cercano a los valores iniciales de la red,
4. Para obtener un modelo con capacidad de validación, los datos se dividen en dos conjuntos: un *conjunto de entrenamiento* utilizado para obtener el modelo neuronal, y un *conjunto de validación* utilizado para probar el comportamiento del modelo con datos diferentes del conjunto de entrenamiento utilizado para obtener el modelo,
5. Se pueden desarrollar dos enfoques diferentes para entrenar la red: 1) basado en la actualización de los pesos sinápticos para cada patrón del conjunto de datos (*on-line approach*), o sea, durante todo el entrenamiento se le pasa al *MLP* cada entrada junto con su salida deseada. Se mide el error y en función de éste se adaptan los pesos sinápticos utilizando el algoritmo de aprendizaje escogido; y 2) basado en la actualización de los pesos sinápticos de una sola vez para todos los datos del conjunto de entrenamiento (*batch approach*), es decir, en este tipo de aprendizaje se calcula el error cometido por el modelo neuronal para todos los patrones. Posteriormente se adaptan

los coeficientes del modelo en función de este valor del error promediado según el número de patrones. Se conoce como *época* al cálculo de todas las salidas del modelo neuronal para los patrones de entrada que se disponen.

Seguidamente pasamos a explicar brevemente el otro tipo de modelo neuronal usado en este trabajo y que se utiliza, fundamentalmente, para establecer relaciones cualitativas entre variables; este modelo se conoce como *mapa auto-organizado* o *mapa de Kohonen* (Arbib, 2003; Kohonen, 2001).

### 3.3.1.2 Mapas Autoorganizados

Un *Self-Organizing Map (SOM)* es una red neuronal propuesta por Teuvo Kohonen in 1984 (Haykin, 1999; Kohonen, 2001). En este modelo, las neuronas se organizan en una arquitectura en dos capas. La primera es la capa de entrada, que consiste en  $m$  neuronas, una por cada variable de entrada. El procesamiento se realiza en la segunda capa o capa de competición, que forma el mapa de rasgos. Esta capa se organiza normalmente en una estructura bidimensional (ver Figura 3.15).



**Figura 3.15** - Arquitectura del SOM

Cada una de las neuronas de entrada está conectada con todas las neuronas de la segunda capa mediante pesos sinápticos. La capa de entrada tiene la misma dimensión que el dato o patrón de entrada, y la actividad de las neuronas de esta capa es proporcional a dicho patrón. A cada una de las neuronas de la segunda capa se le asigna un vector de pesos que tiene la misma dimensión que los vectores de entrada,

es decir, para la neurona  $i,j$  (primer índice fila, segundo columna) se tendrá entonces  $w_{ij} = [w_{ij}^1 w_{ij}^2 \dots w_{ij}^M]$ , siendo  $M$  la longitud del vector de entrada. Lo que se persigue en definitiva, es que patrones semejantes de entrada aumenten la actividad de neuronas próximas en la capa de salida de dicho mapa autoorganizado (Kohonen, 2001). A continuación se describe el algoritmo habitual para el entrenamiento del mapa de Kohonen (Haykin, 1999).

1. Inicialización aleatoria de los pesos,
2. Presentación en cada iteración de un patrón de entrada  $x(r) = [x_r^1 x_r^2 \dots x_r^n]$ ,
3. Determinación de la similitud entre los pesos de cada neurona y las entradas. Si consideramos la distancia euclidiana como medida de comparación tenemos:

$$d(w_{ij}, x_r) = \sum_{k=1}^M (w_{ij}^k - x_r^k)^2 \quad (3.8)$$

La neurona más parecida al patrón de entrada se llama *best matching unit (BMU)*,

4. Determinación de la neurona ganadora, que será aquella en la que obtengamos menor medida de comparación,
5. Actualización de los pesos sinápticos; si estamos usando como función similitud la función cuadrática se tiene:
 
$$w_{ij} = w_{ij} + \alpha \cdot h(BMU, w_{ij}) \cdot (x_j - w_{ij}) \quad (3.9)$$
 donde  $\alpha$  es la velocidad de aprendizaje, equivalente a la constante de adaptación del *perceptrón multicapa* y  $h$  es la *función de vecindad* (con pico de amplitud en la neurona vencedora),
6. Si se ha alcanzado el máximo número de iteraciones se acaba el proceso, si no, se vuelve al paso 2.

Una vez que el mapa de entrenamiento ha terminado, la visualización de los mapas en dos dimensiones proporciona una información cualitativa acerca de cómo las variables de entrada están relacionadas unas con otras considerando el conjunto de datos utilizados para entrenar el mapa. El *SOM* es más una herramienta de visualización que una *herramienta de agrupación (clustering)* a pesar de que es posible obtener *grupos (clusters)* de patrones similares a partir de los mapas de dos dimensiones.

### 3.3.1.3 SOM en el análisis de la radiación neta

En primer lugar, y antes de llevar a cabo nuestro principal objetivo de desarrollar un modelo para la estimación de la radiación neta a partir de variables meteorológicas estándar, se propone utilizar el *SOM* para analizar de forma cualitativa nuestro problema. Para ello, se usará esta red neuronal para visualizar las relaciones entre las variables meteorológicas medidas durante el experimento *FESEBAV-2007* y la radiación neta. En la Tabla 3.6 aparecen las variables que se utilizó para entrenar al mapa auto-organizado junto con sus acrónimos que se utilizarán en la representación gráfica (Figuras 3.17 y 3.18).

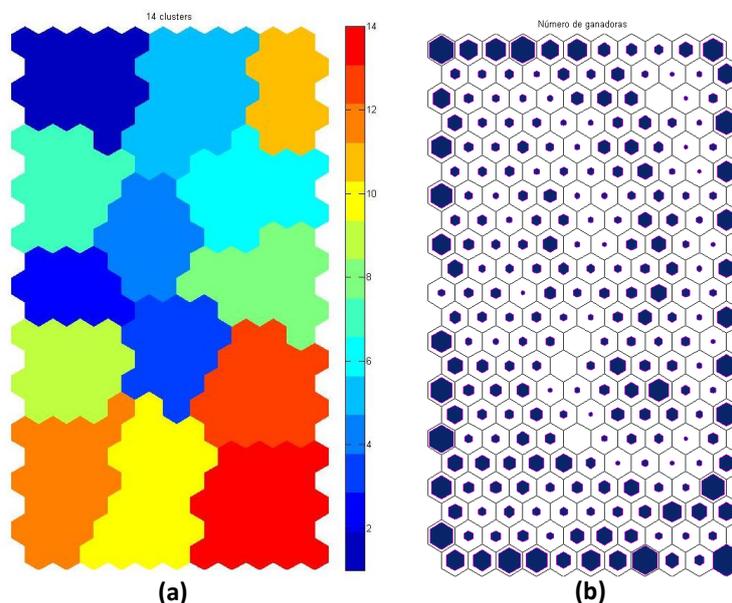
**Tabla 3.6** - Parámetros meteorológicos y del suelo recogidos durante el experimento *FESEBAV-2007* y utilizados para entrenar el *SOM*.

Acrónimos	Variable	Unidad
g7_5 cm y g12_5cm	Flujo de calor en el suelo ( $W m^{-2}$ ) a 7,5 y 12,5 cm de profundidad	$W m^{-2}$
Rad_inc Rad_ref Rad_neta Albedo	Radiación incidente, reflejada y neta a 2 m de altura  Albedo	$W m^{-2}$
Vel_viento Dir_viento	Velocidad del viento ( $m s^{-1}$ ) a 2,1 m de altura. Dirección del viento a 2,1 m de altura	$m s^{-1}$ grados
Temp_suelo_25cm Temp_suelo_15cm Temp_suelo_10cm Temp_suelo_5cm Temp_sup Temp_air	Temperatura del suelo a diferentes profundidades 25, 15, 10 y 5 cm  Temperatura de la superficie Temperatura del aire a 2 m de altura	$^{\circ}C$  $^{\circ}C$ $^{\circ}C$
Hum_rel Hum_suelo	Humedad relativa del aire a 2 m de altura Humedad del suelo a 15 cm de profundidad	% $m^3 m^{-3}$
Prec	Precipitación	dmm

Con las variables comentadas (17 variables en total) y con un total de 2100 patrones se entrenó un mapa auto-organizado. Previamente, y para evitar que la diferencia de rango de las variables tuviera influencia en los resultados, todas ellas se estandarizaron (transformación que conduce a nuevas variables con valor medio cero y varianza unidad). Al desarrollar el mapa éste tenía unas dimensiones de 11x22 de acuerdo con los criterios de entrenamiento y desarrollo dados en (Kohonen, 2001) y

que tienen en cuenta las características de los datos (dispersión) así como su dimensionalidad.

El mapa auto-organizado escogido finalmente para su análisis fue el que tenía menor valor de producto de error de cuantización y topográfico. El primero refleja lo bien que el mapa auto-organizado modeliza los datos y el segundo refleja lo bien que el mapa auto-organizado mantiene las relaciones de cercanía entre el espacio original (considerando todas las variables) y el espacio bidimensional que muestra. La Figura 3.16 presenta los agrupamientos obtenidos con el *SOM* y la representación del número de patrones asignados a cada neurona.

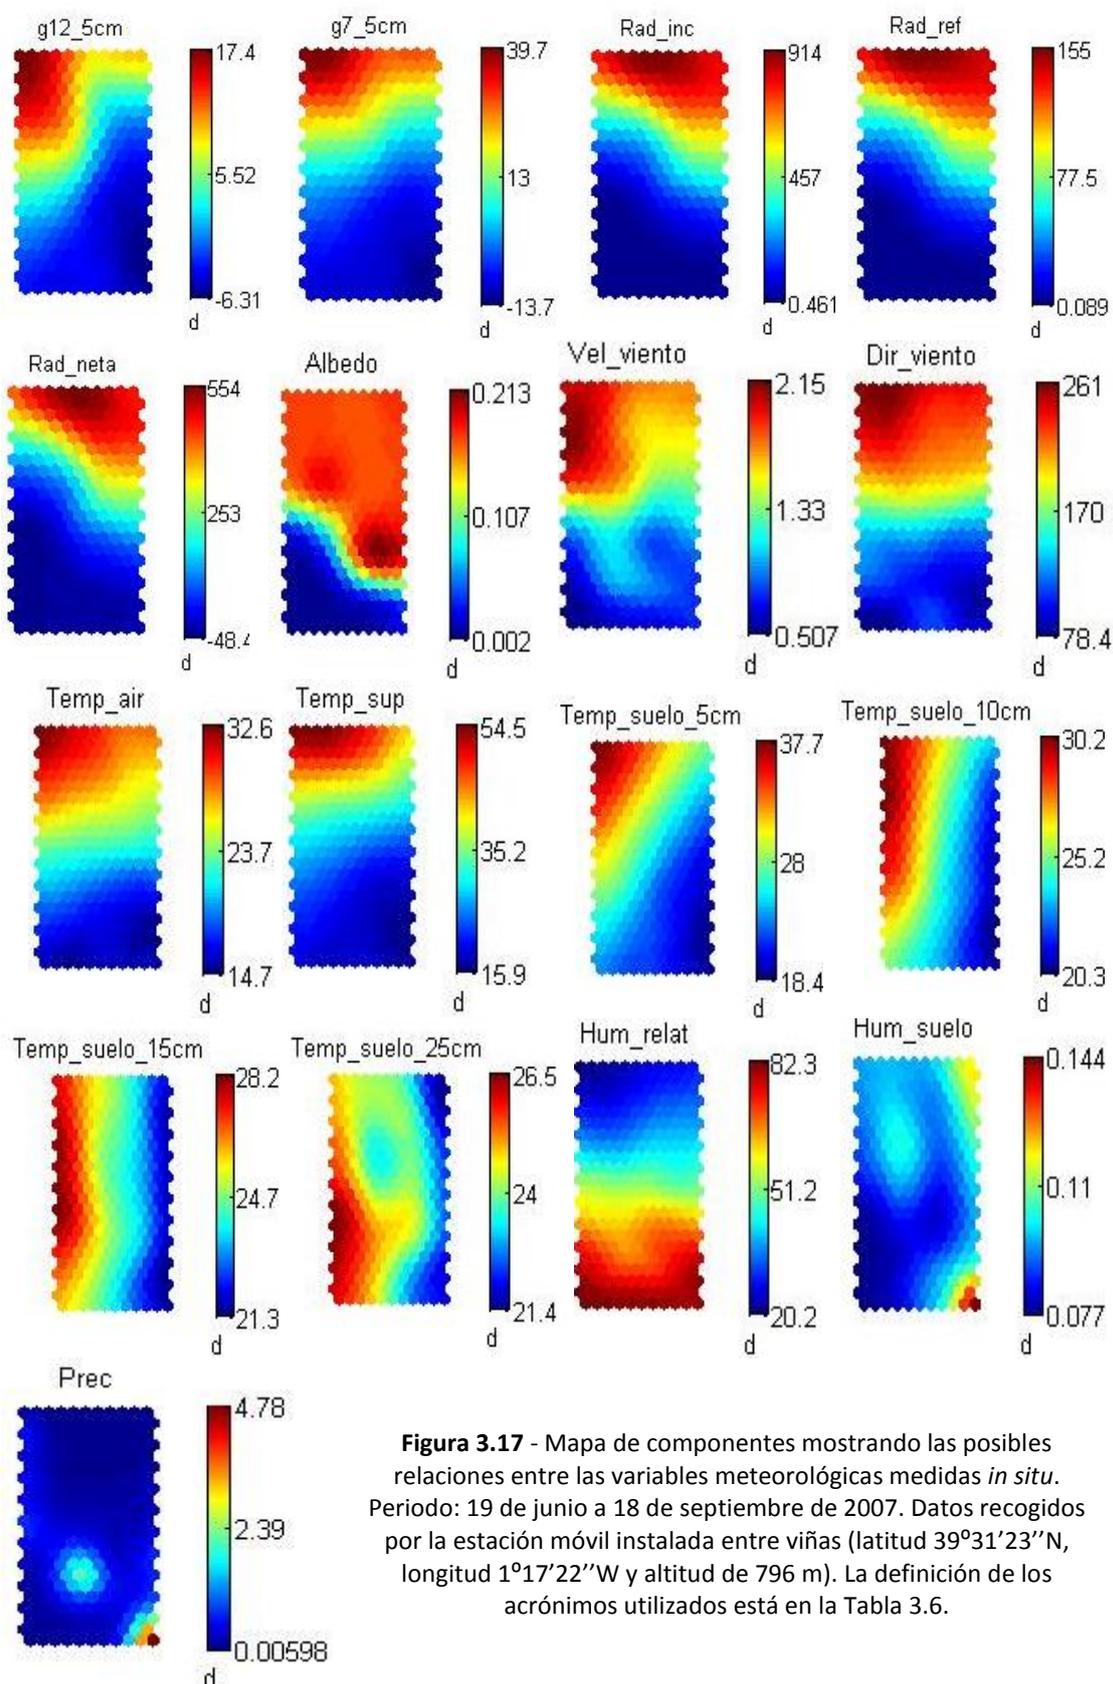


**Figura 3.16 - (a)** agrupamientos establecidos en el *SOM*, y **(b)** representación del número de patrones asignados a cada neurona del *SOM*.

La Figura 3.16a es la primera que debe analizarse si se utiliza el *SOM* como herramienta descriptiva de un problema ya que indica el número de zonas a considerar dentro del mapa bidimensional; cada una de ellas tiene características específicas, diferentes de las demás. El número de patrones asignados a cada neurona del *SOM* está representado en la Figura 3.16b. Cuanto mayor sea el área de la neurona rellenada con color mayor será el número de patrones asignados. De esta forma se pueden ver:

- Zonas del mapa que no hay que analizar porque no tienen patrones asignados,
- Zonas del mapa que hay que ver con más detalle debido a que se les asigna un número de patrones elevado.

El siguiente paso es generar el mapa que establece las posibles relaciones entre las variables y que se conoce como *mapa de componentes*, representado en la Figura 3.17.



**Figura 3.17** - Mapa de componentes mostrando las posibles relaciones entre las variables meteorológicas medidas *in situ*. Periodo: 19 de junio a 18 de septiembre de 2007. Datos recogidos por la estación móvil instalada entre viñas (latitud 39°31'23"N, longitud 1°17'22"W y altitud de 796 m). La definición de los acrónimos utilizados está en la Tabla 3.6.

En esta representación hay que comparar las diferentes zonas espaciales del SOM para cada variable estableciendo las posibles relaciones entre ellas. Así que, en la Figura 3.17 se observa, por ejemplo, que las variables *Rad\_inc*, *Rad\_ref* y *Rad\_neta*, presentan patrones similares. El color rojo indica valores altos de *Rad\_inc*, lo cual implica más radiación reflejada (*Rad\_ref*) y más radiación neta (*Rad\_neta*), lo que conlleva más energía disponible en la superficie para procesos físicos y biológicos. El caso opuesto también se cumple (zonas de color azul en la Figura 3.17). De aquí también se puede inferir que los tres flujos radiativos mencionados presentan un ciclo diurno bien definido (ver Figura 3.21), donde hay una entrada energética durante el período diurno y una salida durante el período nocturno.

Si nos fijamos ahora en las variables que definen las temperaturas: aire a 2 m (*Temp\_air*), superficie (*Temp\_sup*) y a profundidades de 5 cm (*Temp\_suelo\_5cm*), 10 cm (*Temp\_suelo\_10cm*), 15 cm (*Temp\_suelo\_15cm*) y 25 cm (*Temp\_suelo\_25cm*), vemos que se produce un desplazamiento en los valores más altos (color rojo) lo cual indica un fenómeno de propagación por una parte y, por otra, la atenuación sufrida por la onda térmica, debido a la gran inercia térmica que el suelo posee. También se puede observar que los valores máximos de la temperatura del aire y del suelo cerca de la superficie están desplazados en relación a los valores más altos de la *Rad\_Inc*. Este retardo se debe a la inercia térmica del suelo.

En lo que se refiere a las variables *g7\_5cm* (flujo de calor en el suelo a 7,5 cm), *Temp\_sup* y *Temp\_air*, verificamos que el color rojo, en la gráfica del SOM, sufre un desplazamiento hacia la esquina superior izquierda en relación a la *Rad\_inc*. Esto significa que la radiación de onda corta (solar) que llega a la superficie comienza, después de un retraso en el tiempo, a calentar la superficie. A continuación, parte de esta energía se transfiere desde la superficie al suelo, calentándolo y, además, parte de la energía se usa también para calentar el aire cerca de la superficie. Durante el día, la superficie recibe una cantidad mayor de *Rad\_inc* del sol (color rojo) y, en consecuencia, la superficie se calienta, y una cantidad mayor de calor se transfiere desde la superficie hacia el suelo en forma de *G* y desde la superficie hacia la atmósfera en forma de calor sensible (*H*) y calor latente ( $\lambda E$ ). Durante la noche no hay

*Rad\_inc* (color azul), por lo tanto, la superficie no recibe energía del sol y se enfría por lo que el calor empieza a ser transferido de las capas más profundas del suelo hacia la superficie (Ferreira et al., 2010).

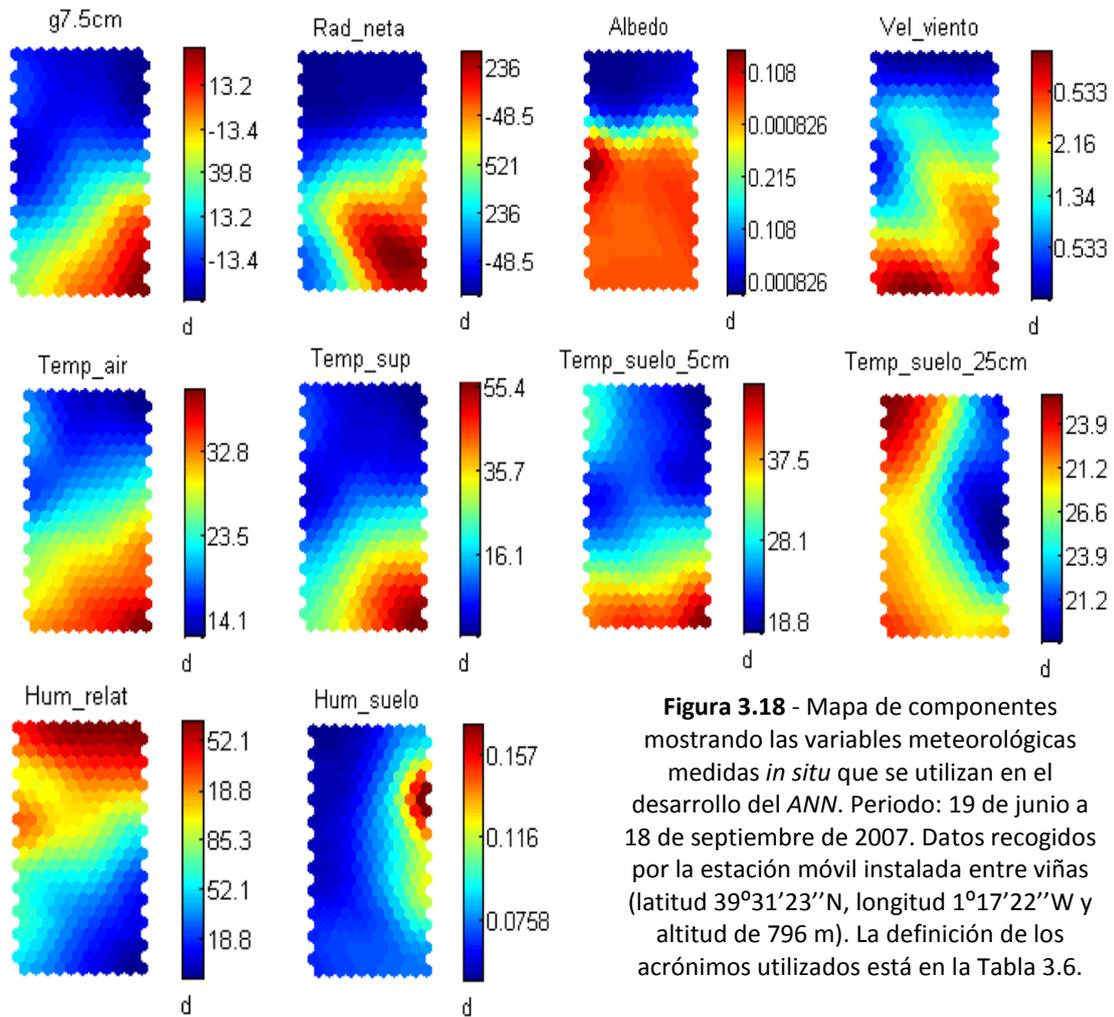
Comparando ahora *Hum\_relat* y *Temp\_air* se verifica que estas variables presentan una tendencia opuesta, es decir, cuando la *Hum\_relat* es baja/alta (color azul/color rojo) la *Temp\_air* es alta/baja (color rojo/color azul). La humedad relativa (*RH*) es una medida de la cantidad de humedad en el aire. Expresada como porcentaje, ésta describe la cantidad de vapor de agua en el aire en comparación con la cantidad necesaria para que el aire se sature (es decir, 100% de *RH*). La humedad varía con la temperatura de tal forma que cuando ésta aumenta, la humedad disminuye (y viceversa). Esto indica, basados en los análisis hechos anteriormente, que los patrones de comportamiento presentados por el *SOM* poseen sentido físico.

#### 3.3.1.4 Datos utilizados en el desarrollo del modelo propuesto

Dado que el *MLP* no requiere ningún conocimiento previo entre las variables y sus relaciones, los criterios utilizados para seleccionar las variables que se utilizarán como datos de entrada de la capa del modelo neuronal fueron los siguientes: (i) variables meteorológicas que no están directamente vinculadas con nuestra variable de salida, i. e.,  $R_n$ , y (ii) las variables que se miden generalmente de forma rutinaria en las estaciones meteorológicas. Por estas razones, datos relativos a *Rad\_inc*, *Rad\_ref*, *g12\_5m*, *Temp\_suelo\_15cm*, *Temp\_suelo\_10cm* y *Prec*, no serán utilizados en el desarrollo del modelo que será presentado a continuación. La precipitación, a pesar de ser una variable medida rutinariamente en las estaciones meteorológicas, no fue incluida porque durante el experimento, como ya se ha mencionado anteriormente, hubo apenas algunos eventos aislados de lluvia.

Después de analizar los mapas *SOM* (Figura 3.17), y considerando los criterios mencionados en el párrafo anterior, las variables de entrada para el *ANN*, fueron: flujo de calor en el suelo a 7,5 cm de profundidad, albedo, velocidad del viento,

temperatura del aire, temperatura de la superficie, temperatura del suelo a 5 y 25 cm de profundidad, humedad relativa del aire, y humedad del suelo. La variable de salida es la radiación neta. A partir de estas variables se entrenó un nuevo SOM con finalidad de visualizar las relaciones entre las variables de entrada del MLP y la de salida, la radiación neta. Los mapas de componentes se presentan en la Figura 3.18.



**Figura 3.18** - Mapa de componentes mostrando las variables meteorológicas medidas *in situ* que se utilizan en el desarrollo del ANN. Periodo: 19 de junio a 18 de septiembre de 2007. Datos recogidos por la estación móvil instalada entre viñas (latitud 39°31'23"N, longitud 1°17'22"W y altitud de 796 m). La definición de los acrónimos utilizados está en la Tabla 3.6.

### 3.3.1.5 Uso del *Perceptrón Multicapa* para la modelización de la radiación neta

Nuestro objetivo en este punto es obtener un modelo neuronal para la modelización de la radiación neta a partir de las variables meteorológicas seleccionadas y mencionadas anteriormente.

Para obtener el modelo neuronal “ideal” se escogieron modelos con dos capas ocultas (por el Teorema de Cybenko - Cybenko, 1989). Se varió el número de neuronas ocultas en cada capa de 2 a 20 y se varió el número de capas ocultas una y dos. Se impusieron estos límites porque en todas las pruebas realizadas nunca se alcanzaban los límites superiores en cuanto a número de neuronas. Además, dado que el algoritmo de aprendizaje es un algoritmo de búsqueda local sobre cada arquitectura, se plantearon un total de 100 inicializaciones diferentes. Como se comentó anteriormente se escogió el algoritmo de Levenberg-Marquardt de tipo *on-line* (Luenberger, 2008). Este algoritmo es el más indicado cuando se tiene un problema de predicción/modelización de series temporales con variaciones no muy bruscas, y además, muestra un mejor rendimiento que otros más comúnmente utilizados, como el clásico algoritmo conocido como *Backpropagation (BP)*.

En lo que respecta a los nodos ocultos sólo una capa oculta se ha tenido en cuenta ya que se obtuvieron resultados parecidos a los obtenidos con dos capas ocultas. El criterio para detener el aprendizaje se basaba en la validación cruzada (Bishop, 1996; Haykin, 1999) lo que permitía obtener la red que mejor generalizaba.

Ya que  $R_n$  puede asumir valores positivos, negativos, o incluso cero, a fin de investigar mejor su comportamiento durante la campaña de campo de 2007, el conjunto de datos se dividió en tres partes: la primera considerando todos los datos de  $R_n$  medidos *in situ*, la segunda parte considerando sólo la radiación neta con valores negativos ( $R_n < 0$ ), y la tercera parte considerando sólo la radiación neta con valores positivos ( $R_n > 0$ ), y de aquí en adelante referidas respectivamente como:  $R_{n\pm}$ ,  $R_{n-}$ , y  $R_{n+}$ . Este procedimiento permitió encontrar un modelo general para la estimación de la  $R_{n\pm}$ , así como modelos más específicos para  $R_{n-}$  y  $R_{n+}$ . A continuación, cada uno de los conjuntos de datos se dividieron en dos subgrupos: el primero con 2/3 de los datos para la fase de entrenamiento del modelo neuronal y el restante 1/3 para la fase de validación del mismo. La precisión de los modelos obtenidos se midió con los coeficientes habitualmente utilizados: el coeficiente de determinación ( $R^2$ ), la raíz cuadrada del error cuadrático medio (*RMSE*), la media de los valores absolutos de los errores cometidos por los modelos (*MAE*), y el error medio (*ME*).

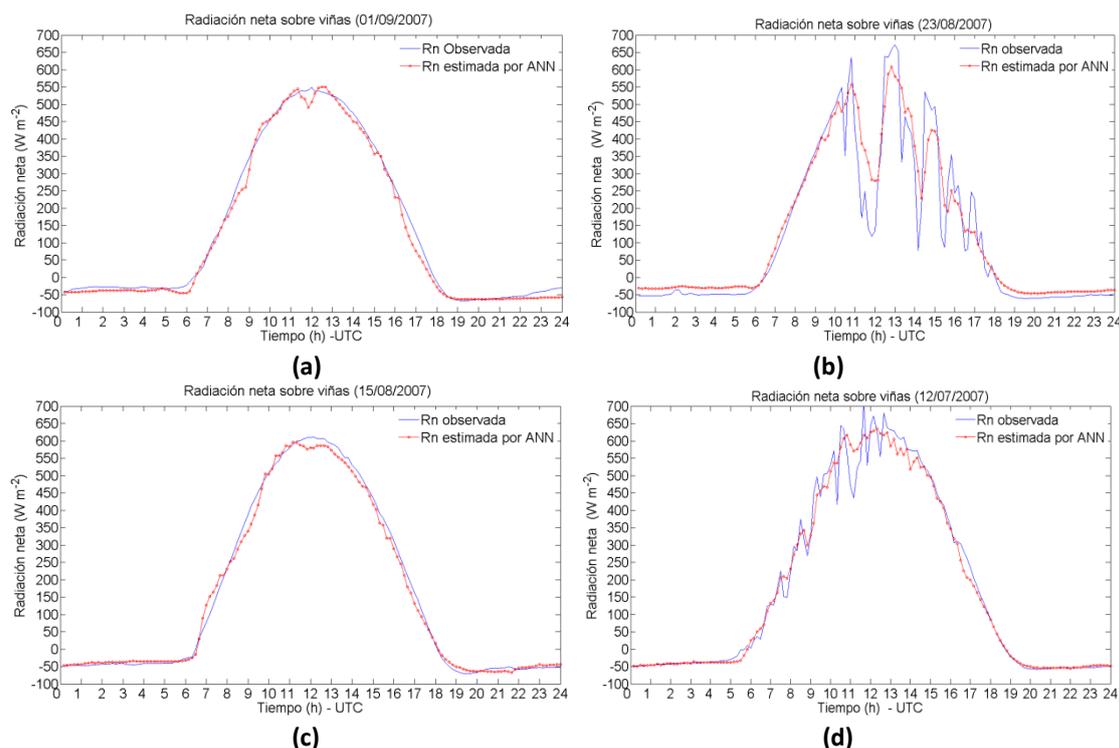
Los resultados para los modelos neuronales propuestos para  $R_{n\pm}$ ,  $R_{n+}$  y  $R_{n-}$ , teniendo en cuenta los conjuntos de entrenamiento y validación, y utilizando sólo los parámetros meteorológicos especificados en la Tabla 3.6, se muestran en la Tabla 3.7.

**Tabla 3.7** - Resultados estadísticos para  $R_n$  utilizando la red neuronal artificial (entrenamiento/validación).

Modelo	$R^2$	RMSE ( $W m^{-2}$ )	MAE ( $W m^{-2}$ )	ME ( $W m^{-2}$ )
$R_{n\pm}$	0,98 / 0,98	38,09 / 39,26	21,67 / 22,60	0,02 / 1,41
$R_{n+}$	0,97 / 0,96	42,90 / 48,75	26,81 / 29,29	-0,33 / 0,26
$R_{n-}$	0,92 / 0,92	6,23 / 6,54	4,59 / 4,76	0 / 0,09

Los resultados muestran que el *MLP* propuesto (ver Tabla 3.7) proporciona buenos resultados, principalmente en lo que se refiere a la estimación de  $R_{n-}$ , donde el valor del coeficiente de correlación ( $R^2 = 0,92/0,92$ ), fue alto y el error cuadrático medio (RMSE = 6,23/6,54  $W m^{-2}$ ), fue bajo. Considerando las fases de entrenamiento/validación, los resultados obtenidos para  $R_{n+}$  y  $R_{n\pm}$ , fueron, respectivamente:  $R^2 = 0,97/0,96$  y  $0,98/0,98$  y  $RMSE = 42,9/48,75$  y  $38,09/39,26$ . Los demás valores estadísticos se encuentran también en la Tabla 3.7 y, como puede verificarse, muestran una buena actuación del modelo propuesto para estimar la radiación neta en superficie cuando se utilizan los parámetros meteorológicos mencionados anteriormente en la capa de entrada del modelo.

En la Figura 3.19 se muestran los ciclos diurnos de los valores estimados de  $R_{n\pm}$  obtenidos por el modelo neuronal y los valores de  $R_n$  medidos en el campo para cuatro días diferentes. Puede observarse que las estimaciones obtenidas en condiciones de cielo despejado (día 15/08/2007:  $RMSE = 17,80 W m^{-2}$  y  $MAE = 13,38 W m^{-2}$ ; día 01/09/2007:  $RMSE = 18,33 W m^{-2}$  y  $MAE = 13,38 W m^{-2}$ ) son mejores si se comparan con los días que presentaban nubosidad (día 12/07/2007:  $RMSE = 31,45 W m^{-2}$  y  $MAE = 18,28 W m^{-2}$ ; día 23/08/2007:  $RMSE = 63,51 W m^{-2}$  y  $MAE = 39,27 W m^{-2}$ ) cuando se comparan con los valores medidos en el campo.



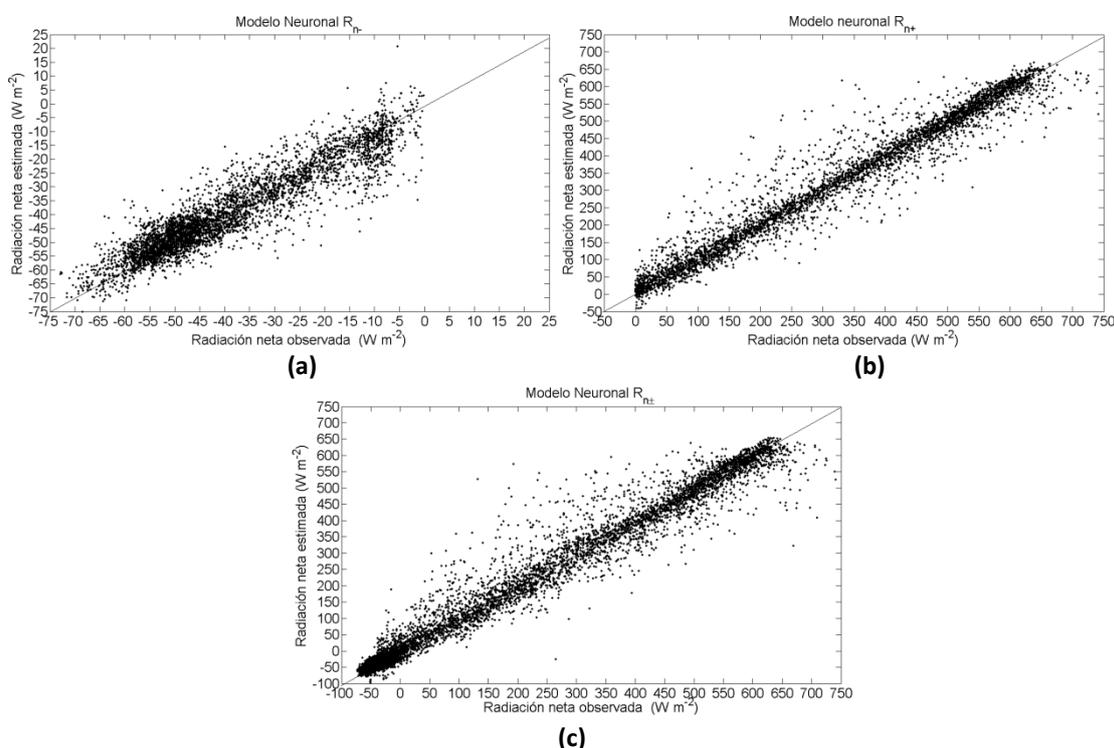
**Figura 3.19** -  $R_n$  estimada utilizando ANN y  $R_n$  medida en el campo para: **(a)** y **(c)** cielo despejado (días: 01/09/2007 y 15/08/2007) y **(b)** y **(d)** cielo con nubosidad (días: 23/08/2007 y 12/07/2007).

A efectos de comparación, citamos el trabajo de Carrasco y Ortega-Farías (2008), que evaluando modelos físicos para simular  $R_n$  sobre un cultivo de viñas en Péncahue Valley, Maule Región, Chile, considerando la estación 2004-2005, encontraron, para días con cielo despejado,  $MAE = 29 \text{ W m}^{-2}$  y  $RMSE = 42 \text{ W m}^{-2}$ , y para días nubosos,  $MAE = 39 \text{ W m}^{-2}$ ,  $RMSE = 60 \text{ W m}^{-2}$ . En este trabajo, para días con cielo despejado, se obtuvo  $MAE = 11,41 \text{ W m}^{-2}$  y  $RMSE = 17,21 \text{ W m}^{-2}$ , y para días nubosos  $MAE = 24,74 \text{ W m}^{-2}$  y  $RMSE = 43,85 \text{ W m}^{-2}$ . Las variables utilizadas por los autores mencionados fueron emisividad del aire, temperatura del aire, temperatura y emisividad de la cobertura vegetal, albedo y radiación solar.

En condiciones de cielo despejado, normalmente todos los componentes de la radiación en superficie están en fase y no sufren variaciones bruscas en sus magnitudes (Figura 1.10 y Figuras 3.21a y c). Sin embargo, bajo condiciones de cielo nuboso, las nubes producen cambios bruscos y rápidos en la radiación solar que llega a la superficie, dando lugar a fuertes variaciones en la magnitud de  $R_n$  en cortos espacios de tiempo (Figuras 3.21b y d), dependiendo de la fracción cubierta del cielo y del tipo de nube, lo que genera valores atípicos en el conjunto de datos, registradas por el

radiómetro neto. Estos valores extremos son difíciles de modelizar y hacen que el modelo subestime o sobrestime  $R_n$ , dependiendo del período del día, sobre todo cuando se utilizan los parámetros meteorológicos para la estimación de  $R_n$  a partir del ANN.

El diagrama de dispersión (representación de los valores observados frente a los estimados de  $R_n$ ) se muestra en la Figura 3.20 para los tres modelos neuronales ( $R_n$ ,  $R_{n+}$  y  $R_{n\pm}$ ). Estos tres modelos presentan valores bajos de dispersión indicando la concordancia entre los valores observados y estimados.



**Figura 3.20** - Diagramas de dispersión de la radiación neta (observada versus estimada por el modelo ANN. **(a)** por la noche ( $R_{n-}$ ), **(b)** durante el día ( $R_{n+}$ ) y **(c)** ciclo diurno ( $R_{n\pm}$ ).

Teniendo también en cuenta que no se utilizó  $R_s^\downarrow$  como parámetro de entrada en el MLP, este modelo ha demostrado ser una herramienta muy útil para estimar  $R_n$  partir de datos meteorológicos como los mencionados en la Tabla 3.6, sobre todo en sitios donde los parámetros relacionados a los flujos de radiación no se miden de forma rutinaria.

### 3.4 Uso de modelos lineales para la modelización de la radiación neta

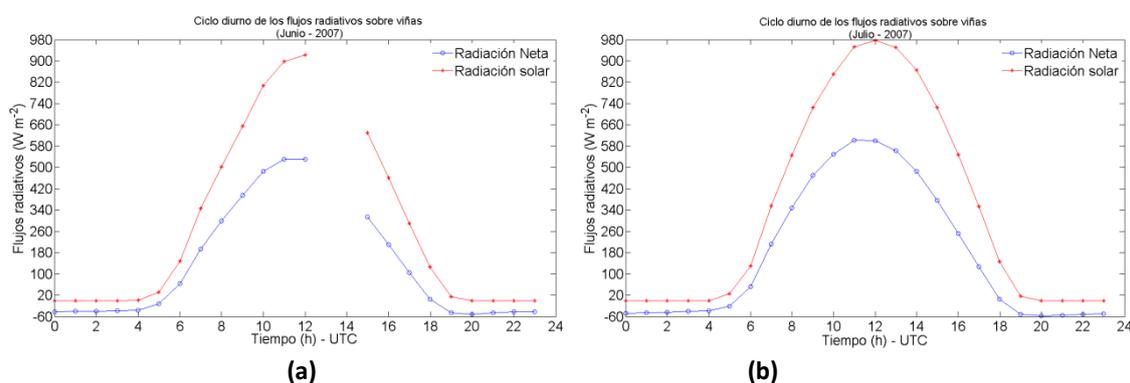
Generalmente, para el cálculo de  $R_n$  a partir de parámetros climáticos se suelen utilizar los modelos de regresión lineal que proporcionan relaciones empíricas entre las variables consideradas. Según Kjaersgaard *et al.* (2007), las ecuaciones más utilizadas para estimar  $R_n$  son

$$R_n = a_1 R_s^\downarrow + b_1 \quad (3.9)$$

$$R_n = a_2 (1 - \alpha) R_s^\downarrow + b_2 \quad (3.10)$$

donde  $a_1$ ,  $b_1$  y  $a_2$ ,  $b_2$  son parámetros del modelo,  $\alpha$  representa el albedo de la superficie y  $R_s^\downarrow$  es la radiación solar incidente, más comúnmente medida que  $R_n$ .

En la Figura 3.21 se muestran los ciclos diurnos de  $R_n$  y  $R_s^\downarrow$  para los datos de la campaña de campo FESEBAV-2007. Se observa que los valores máximos de estos parámetros físicos se dan alrededor de las 12:00 h (UTC); y julio es el mes donde  $R_s^\downarrow$  es máxima sobre el viñedo, por lo que se tiene una mayor cantidad de  $R_n$  disponible para el sistema suelo-planta-atmósfera y, en consecuencia, para los procesos físicos y biofísicos requeridos para el crecimiento de la viña. Las razones entre  $R_n$  y  $R_s^\downarrow$  fueron en promedio de 0,54, 0,58, 0,57 y 0,54 para junio (19 a 31), julio (1 a 31), agosto (1 a 31) y septiembre (1 a 18), respectivamente.



**Figura 3.21** - Variación promediada de  $R_n$  y  $R_s^\downarrow$  sobre el viñedo en los periodos: **(a)** junio (19-31); **(b)** julio del año 2007.

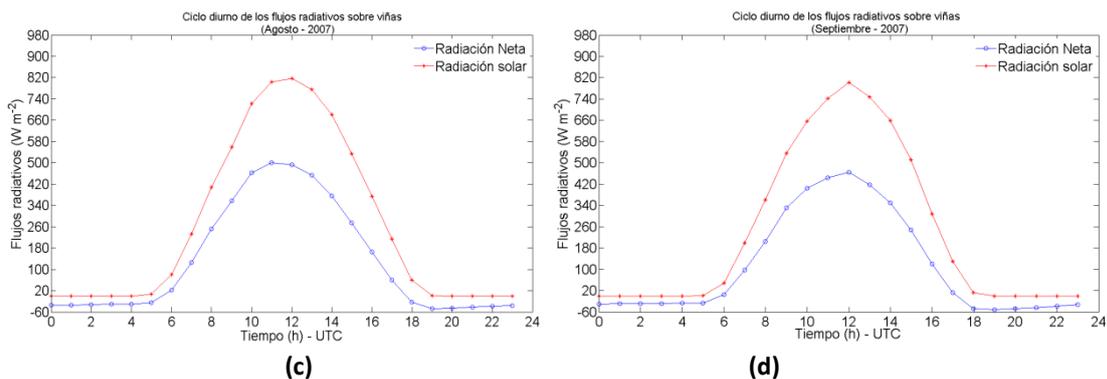


Figura 3.21 (continuación) - Variación promediada de  $R_n$  y  $R_s^\downarrow$  sobre el viñedo en los periodos: (c) agosto y (d) septiembre (1-18) del año 2007.

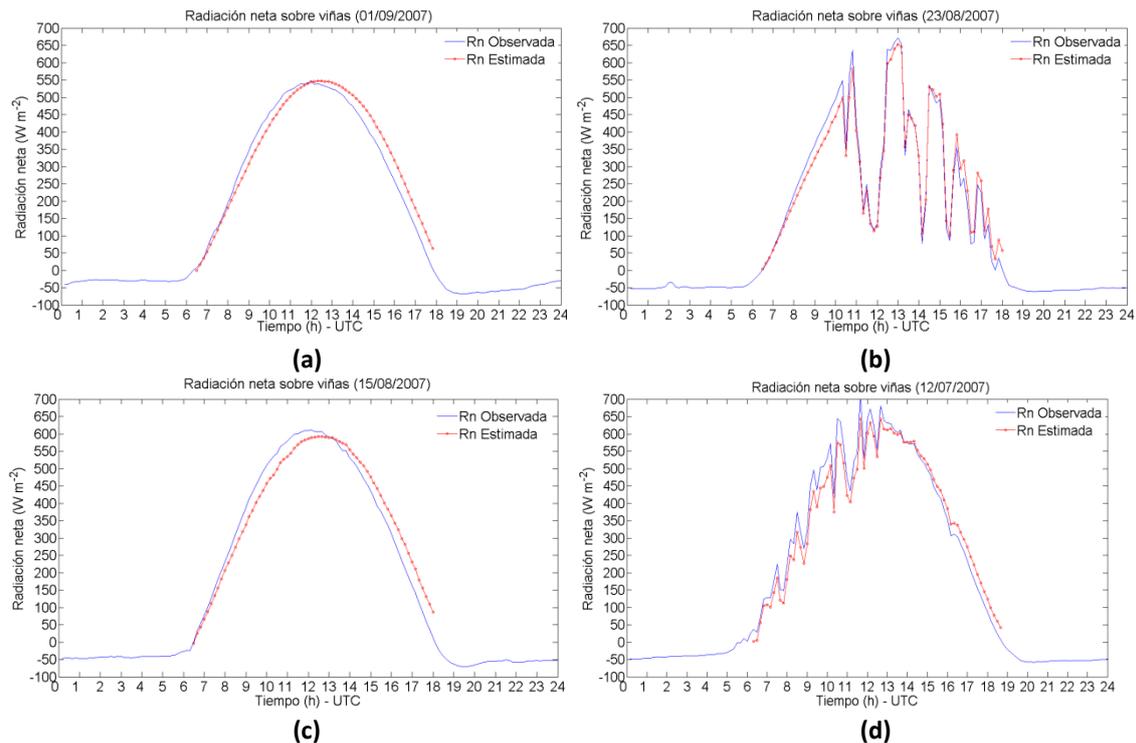
Utilizando las Ecuaciones (3.9) y (3.10) que, a partir de ahora, llamaremos modelos  $R_{n1}$  y  $R_{n2}$ , respectivamente, a partir de los datos de campo, se obtuvieron los coeficientes  $a_1$ ,  $b_1$  y  $a_2$ ,  $b_2$  de dichos modelos, los cuales se representan en la Tabla 3.8.

Tabla 3.8 - Modelos de regresión lineal obtenidos para  $R_n$  y resultados estadísticos de la comparación entre los valores observados y estimados de  $R_n$ . Los resultados estadísticos para las fases de desarrollo y validación están separadas por /.

Modelo	$R^2$	RMSE	MAE	ME	N
$R_{n1} = a_1 R_s^\downarrow + b_1$ $R_{n1} = 0,657R_s^\downarrow - 54,273$	0,96 / 0,97	39,48 / 35,38	34,19 / 30,87	0,01 / 7,10	4397 / 2198
$R_{n2} = a_2 (1 - \alpha) R_s^\downarrow + b_2$ $R_{n2} = 0,791(1 - \alpha)R_s^\downarrow - 54,161$	0,96 / 0,97	37,85 / 34,10	32,94 / 30,15	-0,01 / 8,21	4397 / 2198

Observación: RMSE, MAE y ME están en unidades de  $W m^{-2}$

La figura. 3.22 muestra el ciclo diurno de  $R_n$  observada, así como los valores estimados de ese parámetro, durante el día, usando  $R_{n1}$  y  $R_{n2}$ . Las gráficas se presentan para cuatro días con diferentes características, dos de los cuales se caracterizan por ser de cielo despejado (Figuras 3.22a y c), y los otros dos por ser nubosos durante la mayor parte del día (Figuras 3.22b y d).



**Figura 3.22** - Radiación neta observada y estimada para diferentes condiciones de nubosidad. **(a)** y **(c)**: días despejados (23/08/2007 y 12/07/2007); y **(b)** y **(d)**: días nubosos (01/09/2007 y 15/08/2007). Los modelos lineales utilizados para estimar  $R_n$  fueron: **(a)** y **(b)**:  $R_{n1} = 0,657 R_S^\downarrow - 54,273$ ; y **(c)** y **(d)**:  $R_{n2} = 0,791(1 - \alpha)R_S^\downarrow - 54,161$

Para estos días, ambos modelos  $R_{n1}$  y  $R_{n2}$  tienden a sobreestimar  $R_n$  ligeramente a partir de las 13:00 h y subestimarla ligeramente en el intervalo 9:00-13:00 h aproximadamente. En la tabla 3.8 se proporcionan los errores de los ajustes para las diferentes condiciones de nubosidad y puede observarse que las estimaciones son muy similares a los valores observados como puede verse en la Figura 3.22.

**Tabla 3.9** - Errores de ajuste para días específicos con diferentes condiciones de nubosidad.

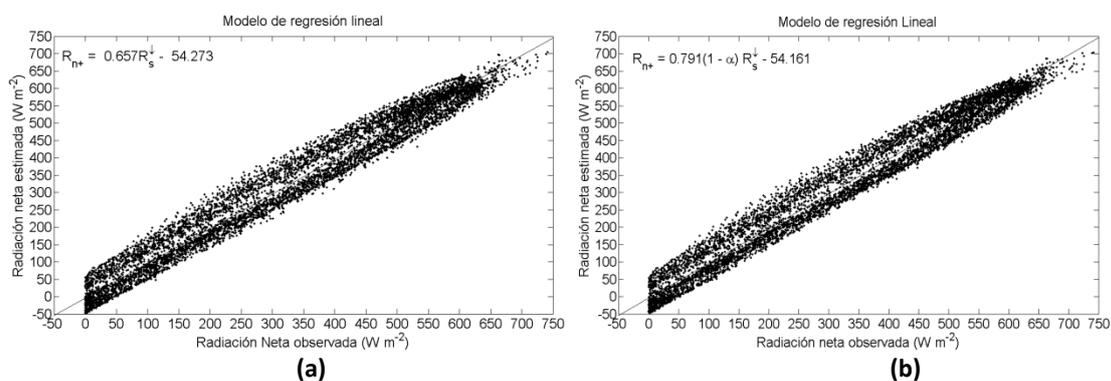
Día	Condiciones del Cielo	RMSE ( $W m^{-2}$ )	MAE ( $W m^{-2}$ )
12/07/2007	Nuboso	37,72	33,93
15/08/2007	Despejado	41,93	37,74
23/08/2007	Nuboso	30,03	25,71
01/09/2007	Despejado	36,20	31,94

De acuerdo con los resultados presentados en la Tabla 3.9, se observa una gran precisión de los modelos lineales en la estimación de  $R_{n1}$  y  $R_{n2}$ , considerando que estos modelos no tienen en cuenta la componente de onda larga de la radiación neta que es,

obviamente, más significativa durante el período nocturno. Por la noche, la radiación neta suele tener valores negativos (ver Figuras 3.21 y 3.22) porque no hay radiación solar entrante y la radiación de onda larga neta está dominada por el flujo terrestre de onda larga saliente. Los modelos de regresión simples como  $R_{n1}$  y  $R_{n2}$  no contienen ninguna corrección para la radiación de onda larga, ni para los factores que la afectan tales como la temperatura de la superficie y los perfiles verticales de la temperatura o del vapor de agua atmosférico (Kjaersgaard *et al.*, 2007).

Durante el día, la radiación solar domina el ciclo diurno y es casi siempre incidente en la superficie, mientras que por la noche, la radiación neta es mucho más débil y sale de la superficie. Como resultado, la superficie se calienta durante el día, mientras que se enfría durante la tarde y noche, especialmente bajo condiciones de cielo despejado y condiciones atmosféricas estables (Arya, 1988).

En la Figura 3.23, se presentan los diagramas de dispersión de  $R_n$ , obtenidos a partir de los modelos  $R_{n1}$  y  $R_{n2}$ , frente a los medidos por el radiómetro neto, presentando coeficientes de correlación elevados ( $0,96 \leq R^2 \leq 0,97$ ), tanto para los datos de la fase de desarrollo como la de validación del modelo.



**Figura 3.23** - Diagrama de dispersión de la radiación neta (observada frente estimada) (a)  $R_{n1}$  y (b).  $R_{n2}$  para  $R_{n^*}$  (período diurno).

Como se mencionó en el Capítulo 2, la campaña FESEBAV-2007 se realizó sobre un viñedo, que es un tipo de vegetación poco densa y, de acuerdo con los resultados de (Fritschen, 1967; Kjaersgaard *et al.*, 2007), la inclusión del término  $\alpha$  en la Ecuación 3.10 no mejora significativamente el resultado del modelo si se compara con el de la Ecuación 3.9, (ver Tabla 3.8).

Durante el experimento, el rango de los valores de albedo de la viña ( $\alpha$ ) y sus promedios mensuales ( $\bar{\alpha}$ ) fueron respectivamente:  $0,15 \leq \alpha \leq 0,21$ ,  $\bar{\alpha} = 0,18$  (junio);  $0,10 \leq \alpha \leq 0,22$ ,  $\bar{\alpha} = 0,17$  (julio);  $0,11 \leq \alpha \leq 0,25$ ,  $\bar{\alpha} = 0,17$  (agosto) y  $0,11 \leq \alpha \leq 0,30$ ,  $\bar{\alpha} = 0,18$  (septiembre). De acuerdo con los resultados obtenidos por Alados *et al.*, (2003); Azevedo *et al.*, (1997); Fritschen (1967); y Kjaersgaard *et al.*, (2007), la inclusión del término  $\alpha$  en la Ecuación 3.10 mejora ligeramente los resultados de la regresión en comparación con los de la Ecuación 3.9.

En este estudio, el análisis estadístico indica también que la inclusión del término  $\alpha$  en la Ecuación 3.10, en comparación con la Ecuación. 3.9, conlleva una pequeña mejora en la estimación de  $R_n$  (ver  $R^2$  y  $RMSE$  en la Tabla 3.8 para los dos modelos que representan estas ecuaciones).

Los autores mencionados anteriormente llevaron a cabo sus estudios, respectivamente, sobre un cultivo de viñas de regadío, sobre arbustos poco densos y agrupados de diferentes especies y sobre césped corto rodeado por campos de cultivo. Pero Alados *et al.* (2003), citando los trabajos de Kaminsky y Dubayah (1997) sobre bosque boreal y praderas del norte, indicaron que la inclusión del albedo de la superficie conduce a una mejora general de los coeficientes de determinación. Esto significa entonces que, al hacer la estimación de  $R_n$  para una superficie determinada, el modelo debe aplicarse de acuerdo con la ocupación y uso del suelo, para así obtener los coeficientes de calibrado correspondientes.

### 3.5 - Comparación del modelo neuronal con los modelos lineales

La Tabla 3.10 muestra los valores de la pendiente y de la ordenada en el origen de los diagramas de dispersión tanto para los modelos lineales ( $R_{n1}$  y  $R_{n2}$ ) como para los neuronales ( $R_{n+}$ ,  $R_{n-}$  y  $R_{n\pm}$ ), y también los valores medios medidos *in situ* de  $R_n$ . Las pendientes de las rectas de regresión de  $R_n$  observada frente a  $R_n$  estimada son próximas a 1, variando entre 0,95 y 0,98 para  $R_{n+}$  y  $R_{n\pm}$  (ML y ANN). Para  $R_{n-}$ , la pendiente del modelo neuronal es de 0,86.

**Tabla 3.10** - Regresión lineal de los diagramas de dispersión ( $a$  = pendiente y  $b$  = sesgo del modelo) de  $R_n$  ( $W\ m^{-2}$ ) medida frente a  $R_n$  estimada usando modelos lineales ( $ML$ ) y modelos neuronales ( $ANN$ ).  $\overline{R_n}$  indica el promedio de los valores medidos *in situ* de  $R_n$ .

Modelo	ML		ANN		Media		
	$R_{n1}$	$R_{n2}$	MLP				
	$a$	$b$	$a$	$b$	$\overline{R_n}$		
$R_{n+}$	0,98	5,48	0,98	4,23	0,95	16,28	330,44
$R_{n-}$	—	—	—	—	0,86	-5,50	38,94
$R_{n\pm}$	—	—	—	—	0,97	3,92	144,94

El sesgo del modelo (parámetro  $b$ ) para  $R_{n+}$  y  $R_{n\pm}$  es aproximadamente un 5% o menos de la media de los valores medidos de  $R_{n+}$  y  $R_{n\pm}$  ( $ML$  y  $ANN$ ). El sesgo para el modelo  $ANN$  para  $R_{n-}$  (noche) es aproximadamente 14% de la media de los valores medidos de  $R_{n-}$ , y el  $RMSE$  es de 16,8%. Esto significa que el modelo neuronal tiene una mayor destreza que el  $ML$  para predecir la radiación neta. Además hay que tener en cuenta que los modelos lineales no se pueden aplicar para estimar  $R_{n-}$  o  $R_{n\pm}$ .

Amarakoon y Chen (1999) consideraron, para su conjunto de datos, que una ordenada en el origen y un  $RMSE$  aproximadamente igual al 10% o menos de la medida de los valores medidos de  $R_n$  son aceptables para los diferentes tipos de condiciones (clima, estaciones, tipos de cubiertas del suelo, humedad de la superficie, tipo de suelo, etc). En nuestro trabajo, obtuvimos porcentajes similares cuando sólo se consideran valores de  $R_{n+}$  (diurnos). Para  $R_{n\pm}$  (ciclo diario completo) la ordenada en el origen obtenida es aproximadamente un 2,7% del valor promedio de  $R_{n\pm}$ , y el  $RMSE$  es aproximadamente el 21% del promedio del valor medido  $R_{n\pm}$ . Esta diferencia observada en el  $RMSE$  entre los valores medidos de  $R_n$  y los estimados por el  $MLP$  se puede explicar por el hecho de que el  $MLP$  aquí propuesto no utiliza la  $R_s^\downarrow$  como parámetro de entrada, parámetro que está directamente vinculado a la  $R_n$  en superficie.

Otra ventaja de utilizar  $ANNs$ , como los utilizados en este trabajo, en comparación con los  $ML$ , es que algunos de estos modelos lineales requieren, como parámetros de entrada, otros parámetros geofísicos que no se miden habitualmente.

Como consecuencia, las estimaciones que se hacen para dichos parámetros pueden conducir a un aumento en el error de estimación de  $R_n$ .

### **3.6 Estimación de la radiación neta a partir de parámetros meteorológicos**

Una vez que verificamos el potencial de las redes neuronales como herramienta para estimar la radiación neta a partir de variables agro meteorológicas e hidrológicas (Tabla 3.6), la idea es ahora reducir el número de variables a utilizar como datos de entrada en el modelo neuronal. Así pues, el modelo neuronal que se plantea en este apartado considera como variables de entrada el día, el mes, y la hora de la medición, la temperatura y la humedad relativa del aire, la presión atmosférica y la velocidad del viento, parámetros comúnmente medidos en las estaciones meteorológicas.

#### **3.6.1 Datos utilizados**

Para comprobar la validez de este planteamiento, se obtuvieron medidas de velocidad del viento, temperatura del aire, presión atmosférica, humedad relativa y radiación neta, necesarios para el desarrollo del modelo neuronal, sobre diferentes superficies y coberturas de suelo (viñas y suelo desnudo). Las medidas sobre viñas se recogieron durante la campaña de campo *FESEBAV-2007*. Las medidas relativas al suelo desnudo se recogieron en la *Valencia Anchor Station (VAS)* y son aquellas relativas a los meses de mayo, junio y julio de 2007/2008. Para recordar la metodología de adquisición de estas medidas y los sensores utilizados ver Apartado 2.4 del Capítulo 2.

#### **3.6.2 Modelo propuesto y resultados obtenidos**

La metodología utilizada para obtener el modelo neuronal propuesto en este apartado es la misma del Apartado 3.3.1.5. Aquí también se dividió el conjunto de

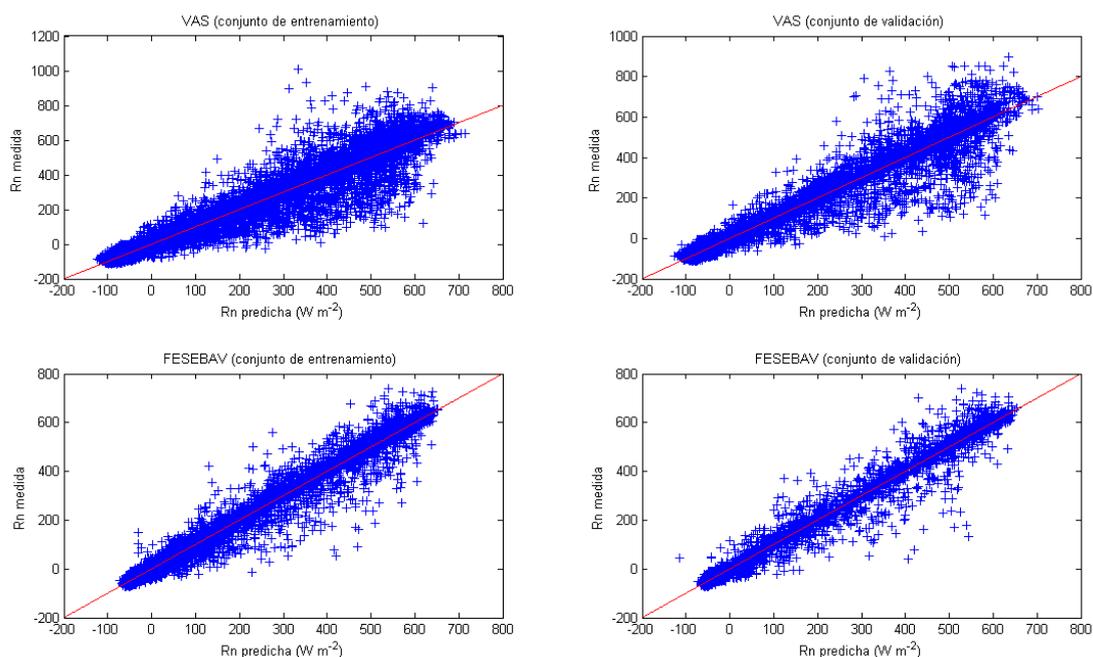
datos en dos subconjuntos: el conjunto de entrenamiento y el de validación; los porcentajes escogidos para esta distribución fueron 2/3 y 1/3 del total.

En cuanto a entradas del modelo neuronal, se escogieron los siguientes parámetros: mes, día y hora de las medidas en cuanto a información temporal y, velocidad del viento, temperatura del aire, presión atmosférica y humedad relativa en cuanto a variables meteorológicas. La salida del modelo neuronal es la radiación neta estimada. La tabla 3.11 muestra los estadísticos de los parámetros utilizados como datos de entrada en el *MLP* y de la radiación neta para los dos conjuntos analizados. En el conjunto de datos de la *VAS*, los meses de mayo y junio de 2008 fueron aquellos en los que los valores registrados de  $R_n$  eran superiores a  $800 \text{ W m}^{-2}$ , llegando incluso hasta  $1.011,15 \text{ W m}^{-2}$ , mientras que, en el conjunto de datos *FESEBAV-2007*, el valor máximo registrado de  $R_n$  fue  $741,30 \text{ W m}^{-2}$ .

**Tabla 3.11** - Estadísticos para los conjuntos de datos meteorológicos analizados.

Parámetro	Mínimo	Máximo	Media	$\sigma$	N
<i>FESEBAV-2007</i>					
Velocidad del viento ( $\text{m s}^{-1}$ )	0,0	5,1	1,2	0,7	13248
Temperatura del aire ( $^{\circ}\text{C}$ )	8,8	40,1	21,9	6,6	
Presión atmosférica (mb)	916,0	937,0	926,1	3,8	
Humedad relativa del aire (%)	6,9	99,3	54,7	25,8	
Radiación neta ( $\text{W m}^{-2}$ )	-73,3	741,3	144,9	231,2	
<i>VAS-2007 y 2008</i>					
Velocidad del viento ( $\text{m s}^{-1}$ )	0,0	8,3	1,9	1,4	23616
Temperatura del aire ( $^{\circ}\text{C}$ )	4,0	36,5	19,5	6,1	
Presión atmosférica (mb)	914,0	938,0	925,4	4,1	
Humedad relativa del aire (%)	8,0	95,0	53,9	21,8	
Radiación neta ( $\text{W m}^{-2}$ )	-114,2	1011,1	136,4	244,3	

La Figura 3.24 muestra la representación de la radiación neta estimada por el modelo neuronal frente a los valores medidos *in situ*, para los conjuntos de datos *FESEBAV-2007* y *VAS*, y considerando ambas fases de entrenamiento y validación. En la misma figura podemos ver la regresión lineal ( $y = x$ ) en los dos conjuntos de datos.



**Figura 3.24** - Representación de  $R_n$  estimada por el MLP frente a los valores medidos *in situ* y regresión lineal para ambos conjuntos de datos.

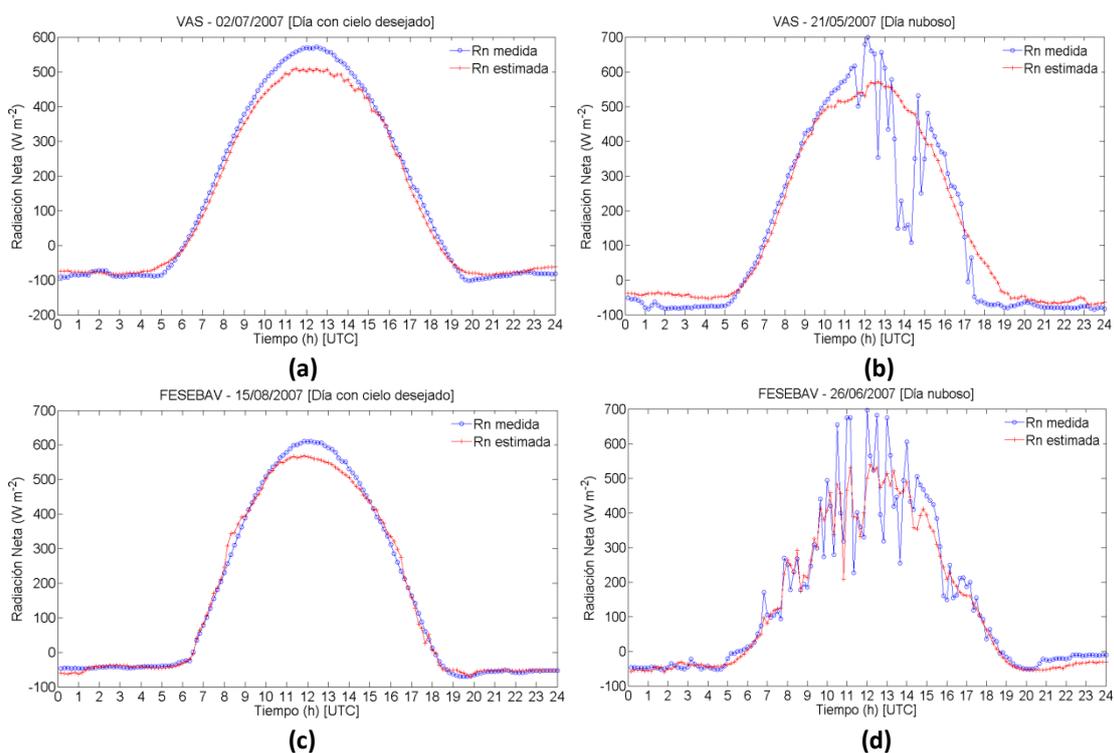
La Tabla 3.12 muestra los resultados obtenidos para los dos conjuntos considerados (*FESEBAV-2007* y *VAS-2007* y *2008*) usando el mejor modelo neuronal de cada uno de ellos. Para escoger el mejor modelo neuronal se ha usado como criterio escoger el modelo que menor *MAE* (valor medio de módulo del error) tenía en el conjunto de generalización. Se ha usado este índice porque es más robusto a los *outliers* que el clásico *RMSE*. Además de los índices mencionados se da el valor medio del error (*ME*, que da idea del posible error del modelo) y los índices del ajuste de una recta entre la señal deseada y la salida de la red, donde el parámetro *a* define la pendiente de dicho ajuste que debe ser próxima a 1, y el parámetro *b* da idea también del posible sesgo del modelo, que debe ser cercano a cero.

**Tabla 3.12** - Valores de los errores de las fases de entrenamiento y validación del modelo neuronal.

CONJUNTO	RMSE ( $Wm^{-2}$ )	MAE ( $Wm^{-2}$ )	ME ( $Wm^{-2}$ )	a	b
<i>FESEBAV-2007</i>					
<i>Entrenamiento</i> N=8832	35,56	19,46	-0,38	0,97	3,73
<i>Validación</i> N=4416	39,88	21,65	0,03	0,97	4,46
<i>VAS-2007 y 2008</i>					
<i>Entrenamiento</i> N=15744	61,36	34,55	0,65	1,00	0,30
<i>Validación</i> N= 7872	65,07	36,47	-0,26	0,99	0,46

La diferencia en los errores *RMSE* y *MAE* obtenidos para los dos conjuntos de datos (Tabla 3.12), puede deberse a la rápida y alta variación, en un corto período de tiempo, de los valores registrados de  $R_n$  que se observan en determinados días debido a la presencia de nubes, como hemos mencionado anteriormente (ver Figura 3.25), y esto se observa sobre todo en el segundo conjunto de datos (VAS). Por ejemplo, en el día 08/07/2008, a las 10:00 h (UTC) la  $R_n$  registrada fue  $142,39 \text{ W m}^{-2}$ , y a las 12:00 h (UTC)  $581,61 \text{ W m}^{-2}$ , una variación de  $439,22 \text{ W m}^{-2}$ , en un intervalo de tiempo de 1 hora. La presencia de nubes genera valores atípicos en el conjunto de datos y el modelo neuronal es sensible a estas variaciones aumentando el error en la estimación.

En la Figura 3.25 se presentan los valores de  $R_n$  medidos *in situ* y los estimados por el modelo neuronal para días con cielo despejado y con cielo nublado para los dos conjuntos.



**Figura 3.25** - Representación de los valores medidos *in situ* de  $R_n$  y predicción del modelo neuronal para días con cielo despejado: (a) 02/07/2007 y (c) 15/08/2007; y días nublados: (b) 21/05/2007 y (d) 26/06/2007.

Para los días con cielo despejado (Figuras 3.25a y c), el modelo tiende a subestimar  $R_n$  entre las 11:00 y 15:00 h (UTC), con un ajuste muy bueno en las otras horas del día. Sin embargo, para los días con cielo nublado (Figuras 3.25 c y d), el

modelo no reproduce tan bien el ciclo diurno de  $R_n$  por el problema de las nubes ya comentado anteriormente.

Para confirmar nuestra hipótesis sobre la mejor ejecución del *MLP* para días con cielo despejado, separamos el conjunto de datos en días con cielo despejado y días con nubes. Los días con cielo parcialmente nublado fueron considerados como nubosos. En la Tabla 3.13 presentamos la diferencia entre las predicciones hechas para días considerados nubosos y para días de cielo despejado. A través de los datos estadísticos se puede ver claramente que los modelos neuronales se comportan mejor a la hora de estimar  $R_n$  en condiciones de cielo despejado.

**Tabla 3.13** - Valores de los errores para días nubosos y para días despejados.

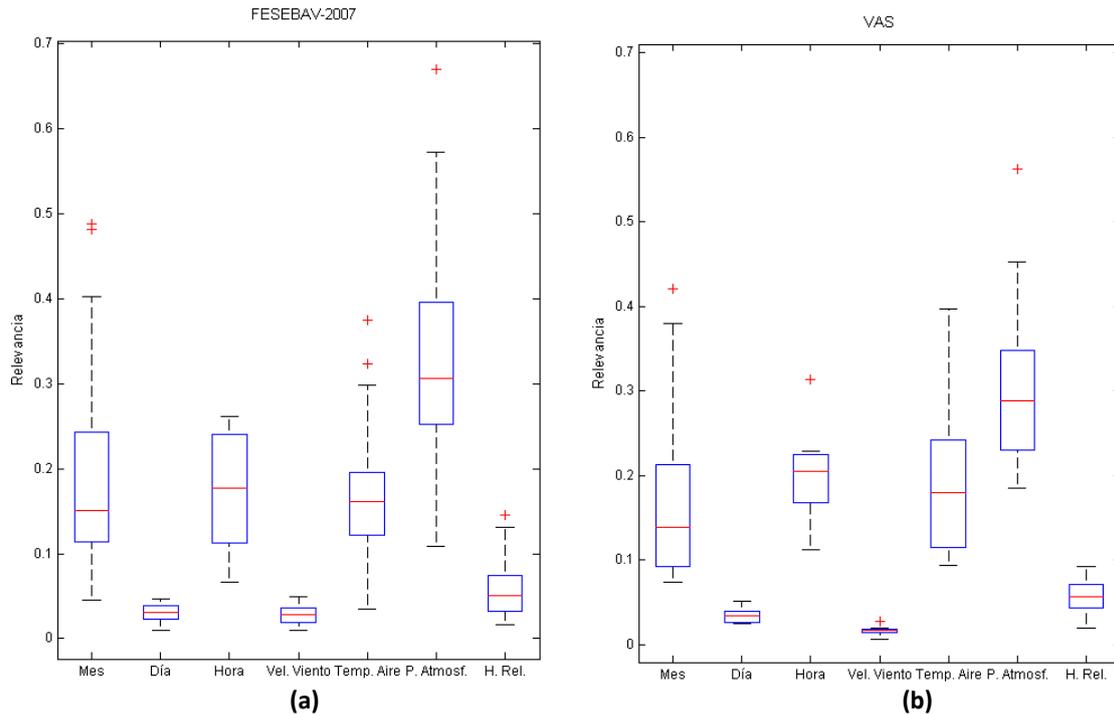
NUMERO DE DATOS	RMSE ( $W m^{-2}$ )	MAE ( $W m^{-2}$ )	ME ( $Wm^{-2}$ )	Tipo de Cielo
<i>FESEBAV-2007</i>				
N=8784	43,85	24,74	0,44	Nuboso
N=4464	17,21	11,41	-1,17	Despejado
<i>VAS-2007 y 2008</i>				
N=17712	71,46	41,64	-0,34	Nuboso
N=5904	22,38	15,84	2,41	Despejado

### 3.6.3 Análisis de sensibilidad del modelo neuronal propuesto

Después de evaluar el comportamiento de los modelos neuronales con diferentes índices de errores, el siguiente paso fue extraer conocimiento del modelo a través de un análisis de sensibilidad (Gómez *et al.*, 2006) para obtener las variables más significativas para el modelo. Este tipo de análisis tiene dos objetivos: a) evaluar la validez de las conclusiones derivadas del modelo, las cuales deben ser coherentes con la teoría física y b) obtener una nueva comprensión cualitativa del problema.

Este tipo de análisis de sensibilidad consiste en determinar la variación que se tiene en la salida del modelo al considerar, o no, una determinada variable de entrada. Si la variación es pequeña significa que la variable de entrada no es muy importante

para obtener la radiación neta (la variable de salida). Si, por el contrario, existe mucha diferencia entre las salidas considerando una entrada o anulándola significa que esa variable de entrada es importante en la determinación de la salida de la red neuronal. El procedimiento experimental ha consistido en considerar los 25 mejores modelos neuronales ordenando las entradas por orden de importancia en cada uno de ellos. Finalmente, se hace un *boxplot* de la posición de las entradas en esos 25 modelos (Figura 3.26).



**Figura 3.26.** Representación de la importancia de las entradas para el modelo neuronal. **(a)** FESEBAV-2007 y **(b)** VAS-2007 y 2008. El orden de las entradas es: mes, día, hora, velocidad del viento (Vel. Viento), temperatura del aire (Temp. Aire), presión atmosférica (P. Atmosf.) y humedad relativa del aire (H. Rel.). **Fuente:** Ferreira *et al.*, 2011a.

En la Figura 3.26 se observa que las variables más relevantes en el modelo neuronal son la presión atmosférica, la hora del día y la temperatura del aire. Sin embargo, la relevancia de una variable a veces puede estar enmascarada por variables que están correlacionadas, y la temperatura de aire y la presión atmosférica son variables correlacionadas. De todos modos, es importante destacar que la radiación neta en superficie depende de la presión atmosférica, más que de la temperatura, ya que la presión atmosférica en superficie es un parámetro que también está fuertemente correlacionado con la cobertura de nubes (baja presión indica mayor nubosidad, alta presión indica menor nubosidad), y ésta a su vez influye en gran medida en los componentes del balance de radiación en superficie. Tanto la radiación

solar como la radiación de onda larga en superficie dependen fuertemente de la fracción de cobertura de nubes (Meetschen *et al.*, 2004).

En este capítulo se ha puesto de manifiesto que la regresión lineal entre el flujo de calor en el suelo y la radiación neta presenta coeficientes de correlación altamente significativos. También se muestra que usando modelos neuronales y variables meteorológicas convencionales como datos de entrada de dichos modelos, es posible estimar la radiación neta con un error aceptable.

Según Irmak (2007), si la radiación neta en superficie pudiera estimarse con buen grado de fiabilidad y con un mínimo de datos climatológicos, esto sería una gran mejora y contribución para los ingenieros, agrónomos, climatólogos, y otros profesionales que trabajan de forma rutinaria con datos climatológicos en los Servicios Meteorológicos Nacionales. Normalmente, las estaciones meteorológicas recogen datos de precipitaciones, temperatura y humedad relativa del aire, presión atmosférica, velocidad y dirección del viento para su utilización operacional. En este sentido y de acuerdo con los resultados presentados en este trabajo, los modelos neuronales tienen la capacidad de predecir  $R_n$  con unos pocos parámetros meteorológicos como entrada a la red. Una vez operativo, el modelo neuronal puede ser utilizado por los profesionales anteriormente mencionados, pudiendo así disponer de valores de otro parámetro de alta significación climática pero de mayor dificultad en su medición operativa.

## SINERGIA ENTRE GERB Y SEVIRI PARA LA ESTIMACIÓN DE LA RADIACIÓN NETA

### 4.1 Introducción

Como se ha mencionado en el capítulo 3, el intercambio de energía entre la superficie terrestre y la atmósfera puede describirse mediante la ecuación de balance de energía en superficie dada por:

$$R_n = H + \lambda E + G \quad (4.1)$$

donde,  $R_n$  representa el *flujo de radiación neta*,  $H$  el *flujo de calor sensible*,  $\lambda E$  el *flujo de calor latente*, y  $G$  es el *flujo de calor en la superficie del suelo*, todos medidos en unidades de  $\text{W m}^{-2}$ .

En esta ecuación,  $G$  es normalmente el término más pequeño y con frecuencia se estima como una parte constante de  $R_n$ , como un término residual de la Ecuación 4.1, o se considera despreciable en escalas diarias de tiempo (Santanello y Friedl, 2003). Sin embargo, los estudios llevados a cabo por Kustas *et al.* (1993), basados en mediciones de campo, pusieron de manifiesto que  $\frac{G}{R_n}$  puede variar entre 0,05 y 0,50, dependiendo del período del día, de las propiedades térmicas del suelo, de la humedad del suelo y de las características de la vegetación (cantidad y altura).

Según Murray y Verhoef (2007), para vegetación relativamente escasa,  $G$  puede representar una proporción significativa de  $R_n$ , y durante la noche, puede llegar a ser el término más significativo del balance de energía, cuando valores pequeños de  $R_n$  y condiciones atmosféricas estables, hacen que  $H$  y  $\lambda E$  también sean de pequeña magnitud. Sin embargo, los valores de  $G$  medidos *in situ* o determinados por los

métodos generalmente aceptados son válidos sólo para zonas menores que  $1 \text{ m}^2$  (Verhoef, 2004). Además, para los estudios de balance de energía en superficie, es muy importante determinar lo más preciso posible el valor de  $R_n$  ya que su magnitud está directamente relacionada con el resto de los flujos de energía, como se puede ver en la Ecuación 4.1. Pero, a pesar de su importancia,  $R_n$  no se mide habitualmente y hay pocos datos históricos disponibles en la mayoría de las estaciones meteorológicas estándar (Sentelhas y Gillespie, 2008), como ya también se mencionó en el Capítulo 3.

Teniendo en cuenta estas cuestiones, en este capítulo estudiaremos la dinámica de  $R_n$  sobre diferentes superficies (viñas, matorral y suelo desnudo), así como la relación entre  $R_n$  y  $G$  a escala local y regional, utilizando parámetros micrometeorológicos medidos *in situ*, y la sinergia entre los sensores *GERB* y *SEVIRI* a bordo de *MSG-1* para la obtención de  $R_n$  en superficie.

La sinergia entre *GERB* y *SEVIRI* permite una mejora en la resolución espacial de los flujos radiativos obtenidos por *GERB* en el *TOA*, cuya resolución en el nadir es nominalmente del orden de  $45 \text{ km} \times 40 \text{ km}$  (*GERB footprint*). Sin embargo, en el caso de los datos de *GERB* de alta resolución (*GERB High Resolution*, Gonzalez *et al*, 2002), la resolución espacial de los flujos se ve especialmente mejorada gracias a la combinación entre los datos *GERB* en banda ancha (bien calibrados) con los datos de *SEVIRI* en bandas estrechas, con una mayor resolución espacial. De este modo, el producto de alta resolución de *GERB* posee una resolución nominal en el nadir, alrededor del Ecuador terrestre, de  $9 \text{ km} \times 9 \text{ km}$  (es decir  $3 \times 3$ , pixels de *SEVIRI*).

Pero, los productos *GERB del alta resolución*, utilizados en este trabajo, debido a las condiciones de latitud y longitud del área de estudio, presentan una resolución espacial del orden de  $12 \times 15 \text{ km}^2$ . Por lo tanto, el objetivo principal de este trabajo será proporcionar un nuevo método basado en los productos de *GERB* que permita estimar  $R_n$  en superficie, cubriendo totalmente el ciclo diurno, con muy alta resolución temporal, y utilizando la sinergia entre *GERB* y *SEVIRI* que permite proporcionar los flujos de *GERB* en el *TOA* con una resolución espacial de  $12 \times 15 \text{ km}^2$ .

Para alcanzar el objetivo propuesto se utilizará la metodología de las redes neuronales artificiales para relacionar los flujos en banda ancha en el *TOA* (onda corta y onda larga), medidos cada 15 minutos por *GERB*, con las medidas de  $R_n$  obtenidas en la superficie terrestre. Además, como forma de comparar el desempeño del modelo neuronal propuesto se desarrolló un modelo multivariante de regresión lineal.

En las secciones siguientes se describe el modelo neuronal propuesto, *MLP*, conjuntamente con las variables de entrada y la variable de salida,  $R_n$  medida en superficie, las cuales se utilizan para las fases de entrenamiento y de validación del modelo.

#### 4.2 Estimación de la temperatura de la superficie con *SEVIRI*

Los modelos lineales presentados en el capítulo 3 (Tabla 3.5) son válidos para las zonas específicas donde se recogieron los datos, pero normalmente estamos interesados en estimar  $R_n$  y  $G$  no sólo a escala local, sino también a escala regional. Para alcanzar este objetivo, es necesario utilizar una metodología alternativa, por ejemplo, una metodología que haga posible el uso de datos de satélite. Esta metodología fue propuesta por Santanello y Friedel (2003) a partir de la estimación de

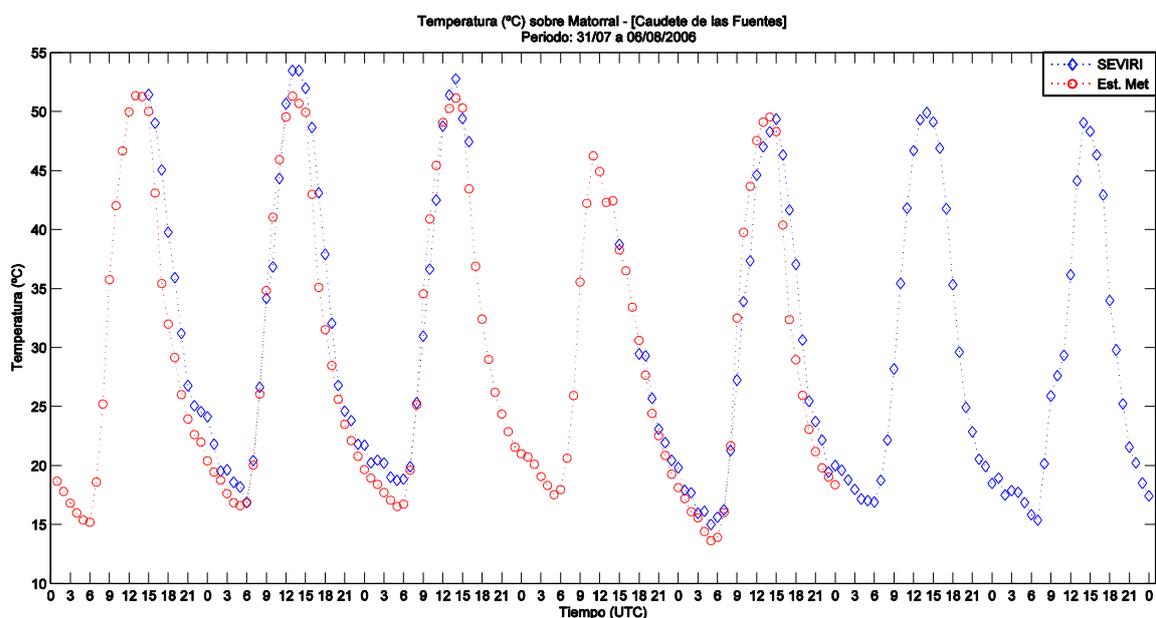
$$\frac{G}{R_n} = A \cos \left( \frac{2 \pi (t+10800)}{B} \right) \quad (4.2)$$

donde  $A$  representa el valor máximo de  $\frac{G}{R_n}$  y  $B$  es una variable que depende de  $\Delta T$  (temperatura máxima - temperatura mínima) y  $t$  es el tiempo (s).  $A$  y  $B$  se asignan en función del tipo de suelo, de los regímenes de humedad del suelo, y de la dinámica estacional del índice de área foliar, *LAI*. En este trabajo supondremos  $A = 0,0074 \Delta T + 0,088$  y  $B = 1729 \Delta T + 65013$ .

Los datos de temperatura de la superficie terrestre (*LST*) que se utilizan en la Ecuación 4.2, se pueden obtener directamente con medidas de campo (nivel local) o con *SEVIRI* (escala regional), proporcionando estimaciones de *LST* con una frecuencia

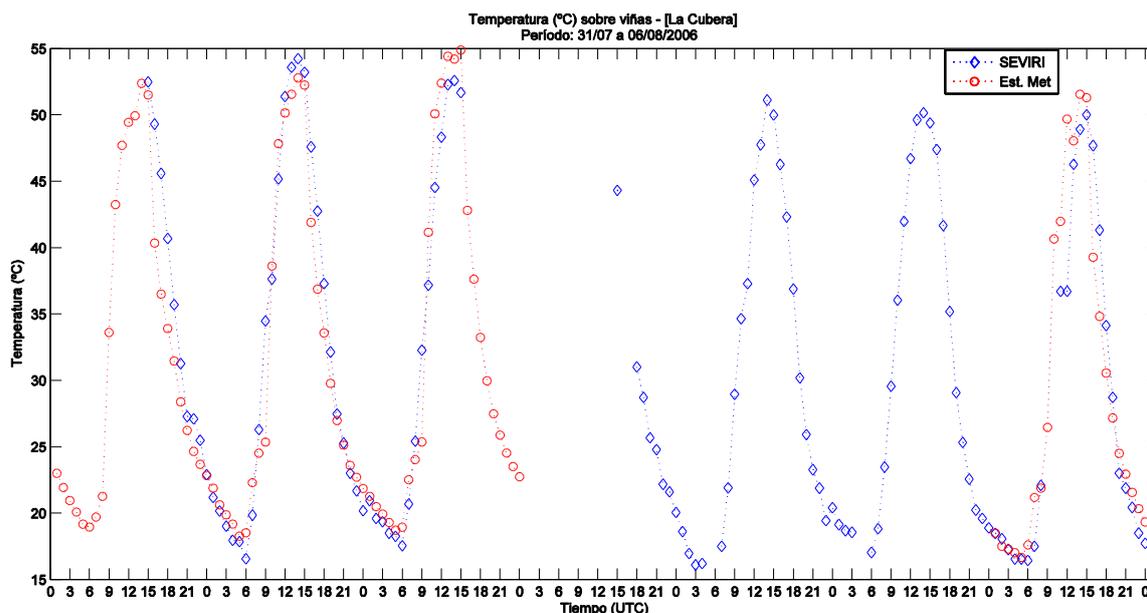
temporal de 15 minutos y una resolución espacial de 3,1 km, cubriendo totalmente el ciclo diurno de *LST*. Los detalles sobre la metodología utilizada para estimar *LST* a partir de *SEVIRI* se encuentran en la página web de *LandSAF-LSA SAF "Land Surface Analysis Satellite Applications Facility"* (<http://landsaf.meteo.pt/>) en el apartado "*Land Surface Temperature*".

Para utilizar la metodología propuesta por dichos investigadores, se desarrolló inicialmente un estudio de caso utilizando la temperatura de la superficie medida sobre las viñas y sobre matorral durante la campaña de campo de 2006 denominada *IV Campaña SCALES* (para más detalles ver el apartado 2.3.1 en el capítulo 2), juntamente con los datos de *SEVIRI*. La comparación entre las medidas de campo y de *SEVIRI* se presenta en la Figura 4.1, y los estadísticos en la Tabla 4.1. Como se observa en dicha Figura 4.1, durante la campaña (31 de julio a 06 de agosto de 2006), hubo días en que las imágenes *Meteosat* no cubrían todo el ciclo diurno, y también hubo días que, por fallo en el *datalogger*, no fue posible recoger datos de campo. Por lo tanto, los estadísticos presentados en la Tabla 4.1 se calcularon cuando hubo datos de campo y de satélites disponibles simultáneamente.



(a)

Figura 4.1 - Comparación entre las medidas de *LST* obtenidas durante la campaña de campo *IV Campaña SCALES 2006* sobre (a) matorral y las estimaciones a partir de *SEVIRI*. En la leyenda: Est. Met = Estación Meteorológica.



(b)

**Figura 4.1 (continuación)** - Comparación entre las medidas de *LST* obtenidas durante la campaña de campo IV Campaña SCALES 2006 sobre **(b)** viñas y las estimaciones a partir de *SEVIRI*. En la leyenda: Est. Met = Estación Meteorológica.

Para leer las imágenes *Meteosat* en el formato *HDF* (*Hierarchical Data Format*) y obtener el píxel más cercano a las medidas de campo, se desarrolló un programa computacional específico. Además, para conseguir la misma resolución temporal, los datos de la estación meteorológica (cada 10 minutos), se remuestrearon a la escala de los datos de *SEVIRI*, o sea, se interpolaron linealmente a la hora de la adquisición de las imágenes del satélite (cada 15 minutos).

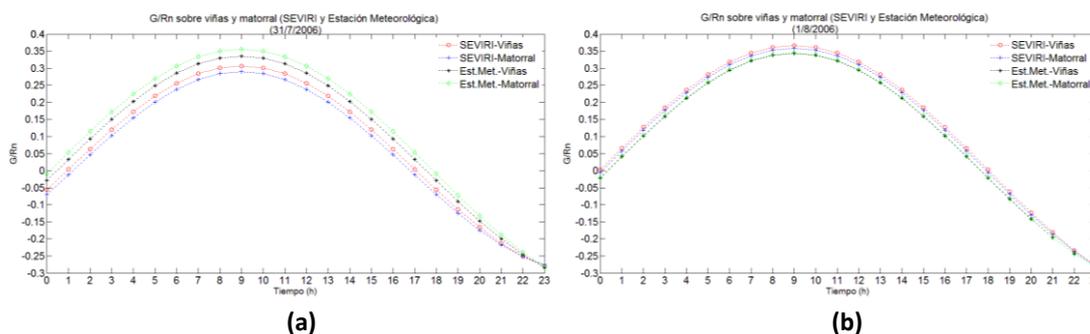
**Tabla 4.1** - Estadísticos de la comparación entre la *LST* de *SEVIRI* y de las medidas en campo.

	FECHA	SEVIRI		Estación Meteorológica		RMSE	R <sup>2</sup>
	día	media	std	media	std		
Temperatura (°C) Viña	31/07/2006	35,8	10,1	32,0	8,5	5,0	0,96
	01/08/2006	31,9	12,9	31,1	11,9	2,9	0,98
	02/08/2006	31,9	13,8	33,2	15,1	3,0	0,98
	06/08/2006	28,0	12,0	28,7	12,3	4,1	0,94
Temperatura (°C) Matorral	31/07/2006	35,3	10,0	30,5	9,3	5,5	0,97
	01/08/2006	32,0	12,6	30,2	12,3	3,0	0,98
	02/08/2006	32,7	13,4	32,2	14,1	2,3	0,99
	03/08/2006	26,1	5,9	25,2	6,3	1,2	0,99
	04/08/2006	28,8	11,9	27,8	12,6	3,9	0,95

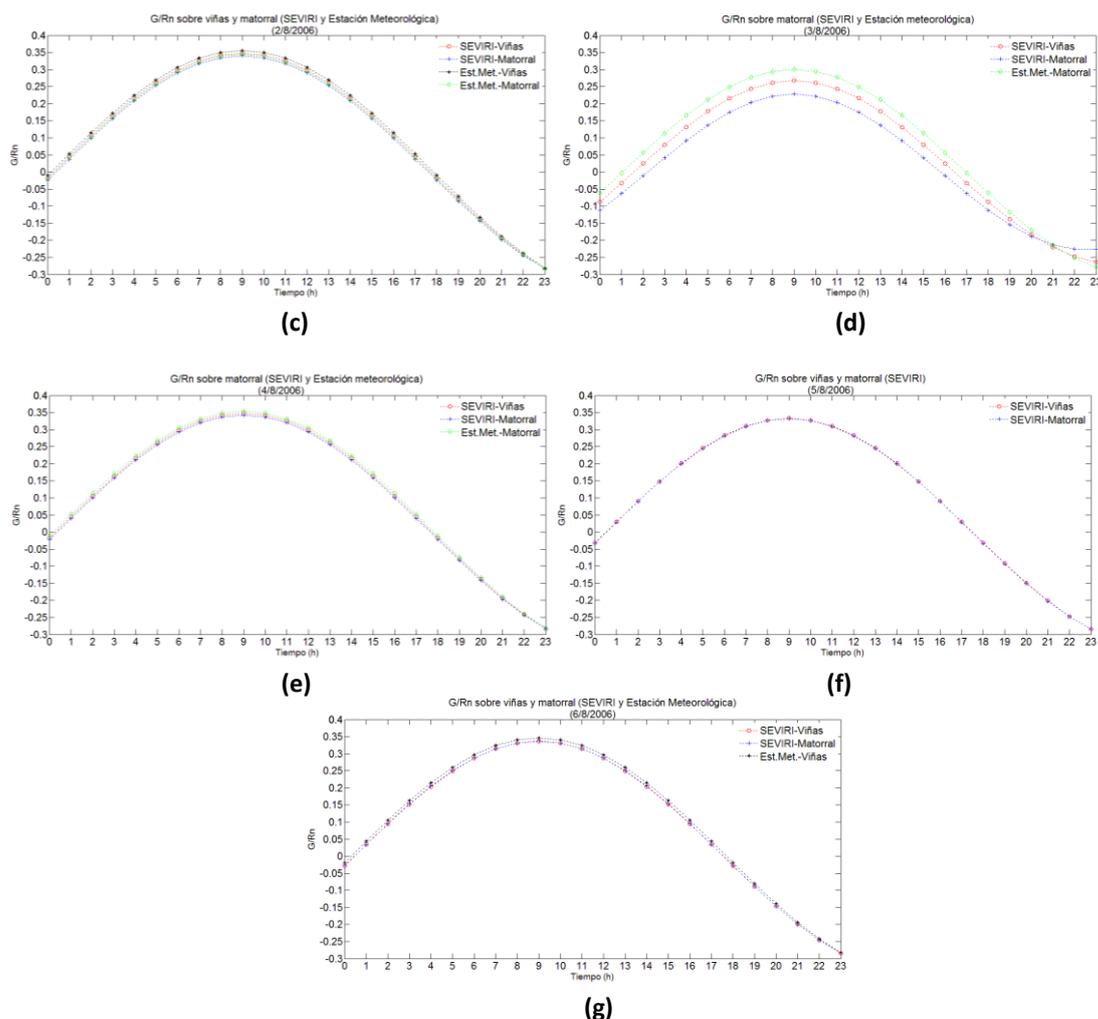
Como se puede observar en la Tabla 4.1, la correlación entre las mediciones *in situ* y las estimaciones de *SEVIRI* presentan muy buena concordancia, con un coeficiente  $R^2$  variando de 0,94 a 0,99, y el *RMSE* variando de 1,2 a 5,5 °C. Estas buenas correlaciones son consecuencia de las buenas condiciones de homogeneidad de la zona. Los píxeles de *SEVIRI* elegidos para la comparación se corresponden respectivamente con zonas mayoritariamente de viñas y de matorral, como puede verse en la Figura 2.3 del Capítulo 2.

Una vez comprobadas las buenas correlaciones entre las medidas de campo sobre viñas y matorral y las estimaciones de *SEVIRI*, y admitiendo por tanto que la *LST* obtenida desde satélite es representativa de la temperatura de la superficie, se aplicó entonces la ecuación 4.2 para estimar  $\frac{G}{R_n}$  a escala local y regional, Figuras 4.2 y 4.3, respectivamente.

A través de las Figuras 4.2a a 4.2g, donde hubo medidas simultáneas de *SEVIRI* y de la estación meteorológica, se puede ver que  $\frac{G}{R_n}$ , presenta curvas muy semejantes. La Figura 4.2f, día 05/08/2006, no hubo medidas de campo por los motivos ya mencionados, pero  $\frac{G}{R_n}$  pudo estimarse a partir de los datos de *SEVIRI*, y puede considerarse representativo para este día debido a las buenas correlaciones estadísticas presentadas en la Tabla 4.1.



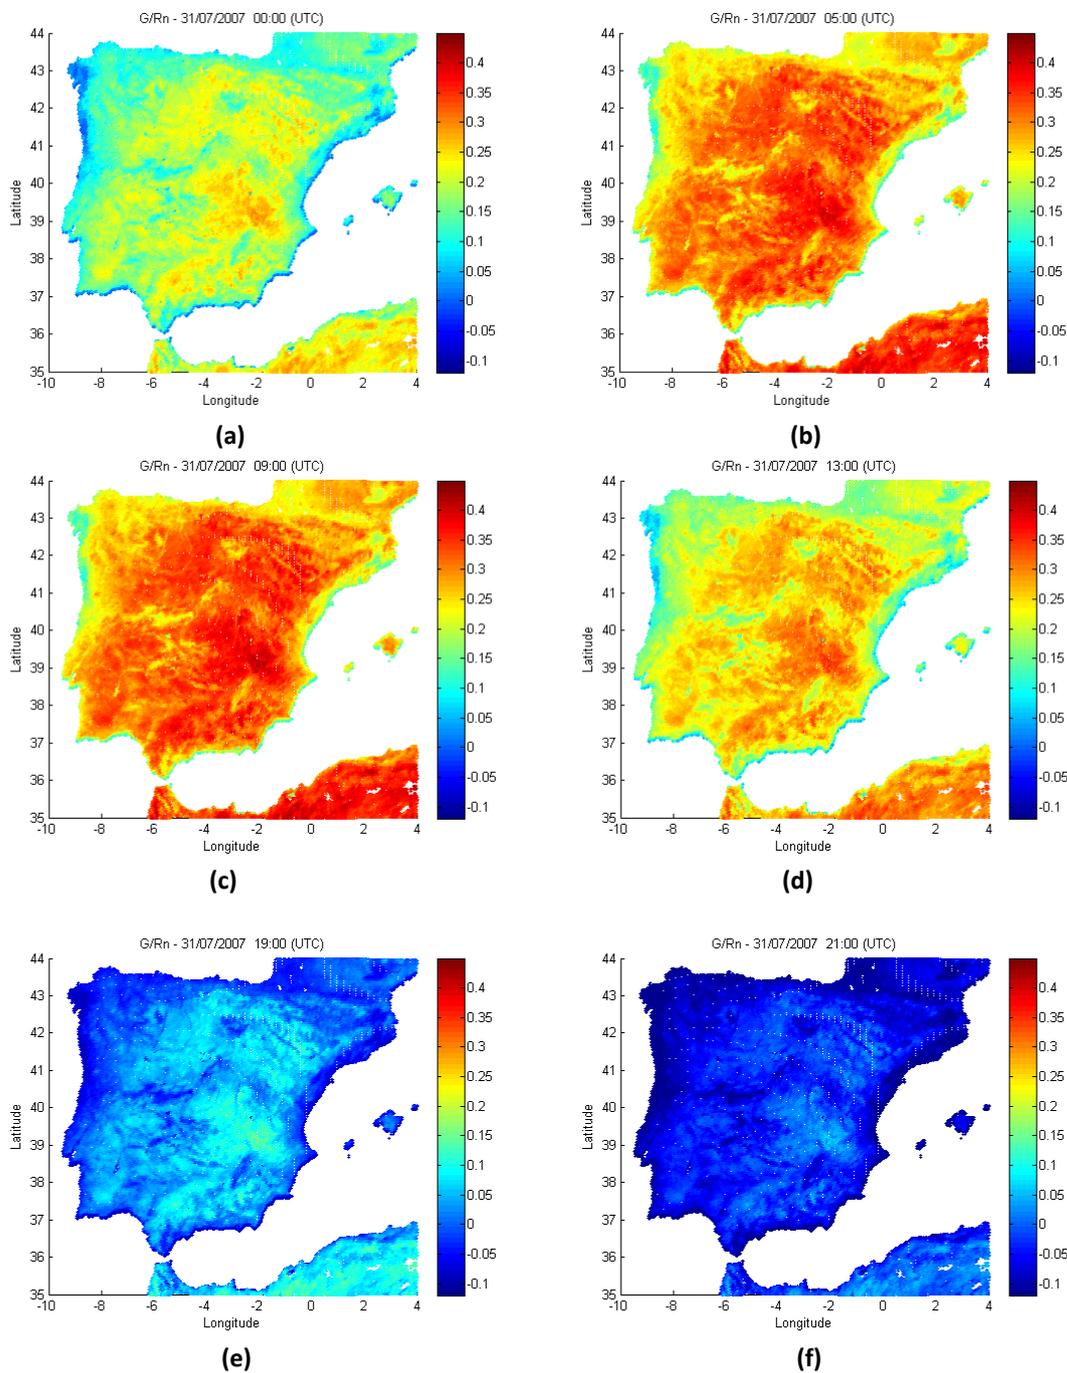
**Figura 4.2** -  $\frac{G}{R_n}$  sobre viñas y matorral estimados a partir de la Ecuación 4.2 utilizando la temperatura de la superficie estimada con *SEVIRI* y las medidas de las estaciones meteorológicas durante la *Campaña SCALES 2006*: **(a)** día 31/07/2006 y **(b)** día 01/08/2006. En la leyenda de las figuras Est. Met. = Estación Meteorológica.



**Figura 4.2 - (continuación)**  $\frac{G}{R_n}$  sobre viñedos y matorral estimados a partir de la Ecuación 4.2 utilizando la temperatura de la superficie estimada con *SEVIRI* y las medidas de las estaciones meteorológicas durante la *Campaña SCALES 2006*: **(c)** día 02/08/2006, **(d)** día 03/08/2006, **(e)** día 04/08/2006, **(f)** día 05/08/2006, y **(g)** día 06/08/2006. En la leyenda de las figuras Est. Met. = Estación Meteorológica.

La estimación de  $\frac{G}{R_n}$  sobre el cultivo del viñedo y matorral mediante la metodología propuesta por Santanello y Friedel (2003), ha demostrado que dicha relación puede variar aproximadamente entre -0,30 y 0,37, dependiendo de la hora del día, alcanzando valores máximos a mediados de la mañana y decreciendo por la tarde. La magnitud de  $\frac{G}{R_n}$  cambia de signo sobre las 18:00 UTC, y los valores mínimos se alcanzan alrededor de las 23:00 UTC (Figura 4.2). Esto se puede explicar, la variación de  $G$  con  $R_n$ , por el hecho de que la superficie del suelo se calienta en las horas de la mañana, cuando empieza la insolación, habiendo como consecuencia más energía radiante disponible para transformarse en  $G$ . Por otro lado, por la tarde y por la noche, durante la fase de enfriamiento, la cantidad de energía radiante disponible para transformarse en  $G$  es menor en comparación con la fase de calentamiento.

Las variaciones diurnas de la relación  $\frac{G}{R_n}$  a escala regional, entre las longitudes comprendidas entre -10° W y 4° E, y latitudes comprendidas entre 35° y 44° N, para el día 31 de julio de 2007, se muestran en la Figura 4.3.



**Figura 4.3** -  $\frac{G}{R_n}$  generado a partir de las imágenes del sensor *SEVIRI* de *Meteosat* para el día 31/07/2007: (a) 00:00 UTC; (b) 05:00 UTC, (c) 09:00 UTC, (d) 13:00 UTC, (e) 19:00 UTC y (f) 21:00 UTC.

Para el inicio de la mañana y durante el día,  $\frac{G}{R_n}$  presenta valores entre 0,1 y 0,4 (Figuras 4.3 b, c y d), aproximadamente, y para el final de la tarde y por la noche, los valores son entre aproximadamente -0,05 y 0,25 (Figuras 4.3a, e y f). Obsérvese

también que los valores de  $\frac{G}{R_n}$  por la noche varían gradualmente de negativo a positivo a lo largo del tiempo.

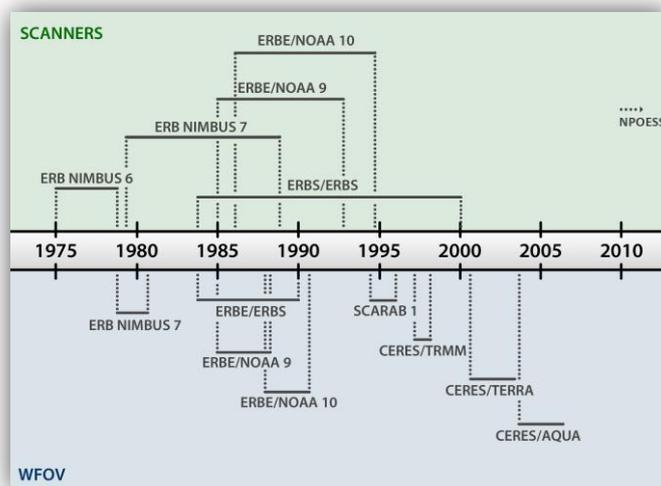
Como consecuencia de lo anterior, se puede ver que la metodología desarrollada por Santanello y Friedel (2003) es adecuada para la estimación de  $G$  a escala regional, una vez que  $R_n$  puede obtenerse a partir de datos de teledetección.

### 4.3 Radiación neta en el techo de la atmósfera con *GERB*

Muchos de los componentes de los balances de radiación y de energía de la superficie terrestre no se miden de forma rutinaria debido a que los instrumentos necesarios para hacerlo necesitan un mantenimiento continuo en el campo, calibración periódica y, generalmente, son relativamente caros. Sin embargo, son esenciales para la evaluación y validación de los componentes del balance de radiación en superficie obtenidos desde satélite, ya que las estimaciones desde satélite de los balances de radiación en superficie y en el techo de la atmósfera (*TOA*) son fundamentales para una mejor comprensión de las interacciones existentes en el sistema Tierra-Atmósfera. Los métodos indirectos para la obtención de  $R_n$  en superficie a partir de las observaciones disponibles desde satélite siguen siendo uno de los desafíos pendientes en el campo de la radiación en el sistema Tierra-Atmósfera.

A lo largo de los últimos años (Figura 4.4) se han desarrollado misiones espaciales dirigidas a esta aplicación tales como *ERB* (*Earth Radiation Budget*) a bordo de *NIMBUS-6* y *7*, *ERBE* (*Earth Radiation Budget Experiment*) a bordo de *NOAA-9* y *10*, *ScaRaB* (*Scanner for Radiation Budget*) 1 y 2, respectivamente a bordo de los satélites *Meteor-3/7* y *Resurs-01/4*, *CERES* (*Clouds and the Earth's Radiant Energy System*) a bordo de *TRMM*, *Terra* y *Aqua* de *NASA* y *GERB* (*Geostationary Earth Radiation Budget*) de *EUMETSAT*. Todas estas misiones, excepto *GERB*, son satélites de órbita polar donde la observación sobre una misma zona sólo se realiza dos veces al día. Sin embargo, *GERB* es el primer instrumento diseñado exclusivamente para estimar el

balance de radiación de la Tierra desde un satélite en órbita geoestacionaria (Figura. I1 – Apéndice I).



**Figura 4.4** - Desarrollo temporal de las series de datos de radiación. **Fuente:** Adaptado de Smith *et al.*, 2004.

*GERB* fue lanzado al espacio en agosto de 2002 a bordo del primer satélite de la Segunda Generación de *Meteosat* (*Meteosat Second Generation-MSG*), posteriormente denominado *Meteosat 8*, y empezó a hacer medidas dedicadas, con alta resolución temporal (15 min) y con una adecuada resolución espacial (45 km x 40 km) del balance radiativo del sistema Tierra-Atmósfera para estudios climáticos y de física de la atmósfera (Harries *et al.*, 2005).

Otro instrumento a bordo del satélite *MSG* es el *Spinning Enhanced Visible and Infrared Imager (SEVIRI)*, Figura. I2 (Apéndice I), el cual proporciona, en tiempo casi real, datos en 12 canales de banda estrecha cada 15 minutos. El sensor *SEVIRI* se utiliza también como instrumento auxiliar para el procesamiento de los datos *GERB*. *SEVIRI* se utiliza tanto para la identificación de la escena dentro del *footprint* de *GERB* como para mejorar la resolución espacial de los productos *GERB* (Dewitte *et al.*, 2008).

El instrumento *GERB* mide, por una parte, el espectro total de radiación de la Tierra y, por otra, en una banda más estrecha a través de un filtro de cuarzo de onda corta (*SW*), la radiación solar de longitudes de onda inferiores a 4,0  $\mu\text{m}$ . Las medidas de onda larga (*LW*) se obtienen mediante la sustracción de las medidas adyacentes

*TOTAL* y *SW* durante el procesamiento en tierra (Harries *et al.*, 2005). Con un pixel de tamaño nominal de aproximadamente 45 km x 40 km (N x S x E x W) en el nadir se obtiene una precisión absoluta superior a  $2,4 \text{ W m}^{-2} \text{ sr}^{-1}$  (<1%) en el *SW* y superior a  $0,4 \text{ W m}^{-2} \text{ sr}^{-1}$  en el *LW*. El co-registrado con respecto a *SEVIRI* es 3 km en el punto subsatélite (Schmetz *et al.*, 2002).

De acuerdo con Dewitte *et al.* (2008), la radiancia “total” (*TOT*),  $L_{TOT}$ , se mide en el intervalo espectral de 0,3 a 100  $\mu\text{m}$  y la radiancia de “onda corta”,  $L_{SW}$ , se mide en el intervalo espectral 0,3 - 4  $\mu\text{m}$ .

$$L_{TOT} = \int \phi_{TOT}(\lambda) L(\lambda) d\lambda \quad (4.3)$$

$$L_{SW} = \int \phi_{SW}(\lambda) L(\lambda) d\lambda \quad (4.4)$$

donde  $L(\lambda)$  es la distribución espectral de la radiación observada, y  $\phi_{TOT}(\lambda)$  y  $\phi_{SW}(\lambda)$  son las funciones de respuesta espectral del instrumento en los canales *TOT* y *SW*, respectivamente. La radiancia de onda larga *LW* se obtiene, como se mencionó anteriormente, por sustracción de la onda corta de la radiación total de acuerdo con la Ecuación 4.5.

$$L_{LW} = L_{TOT} - A \cdot L_{SW} \quad (4.5)$$

donde  $A$  es un factor definido como

$$A = \frac{\int_{L_{5800K}} \Phi_{TOT}(\lambda) d\lambda}{\int_{L_{5800K}} \Phi_{SW}(\lambda) d\lambda} \quad (4.6)$$

Como se indicó al principio de este capítulo, el objetivo es relacionar los flujos de banda ancha en el *TOA*, estimados con *GERB*, con las medidas *in situ* de  $R_n$ , utilizando modelos neuronales. Por esta razón, estamos interesados en los flujos radiativos netos en el *TOA* y no en las radiancias en el *TOA*. Estos flujos se calculan a partir de las medidas del sensor *GERB*, de las radiancias de onda corta y de onda larga salientes, usando modelos empíricos o teóricos de la anisotropía de la radiación, los

cuales se llaman (ADMs) *modelos de distribución angular* (Dewitte *et al.*, 2008; Viollier *et al.*, 2009; y Domenech *et al.*, 2011).

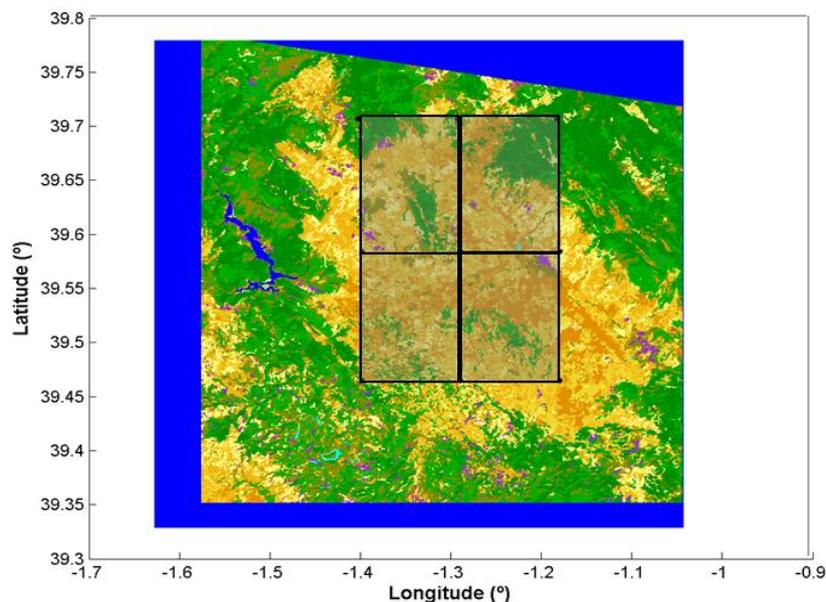
En las secciones siguientes se describe el modelo neuronal propuesto, *MLP*, conjuntamente con las variables de entrada y la variable de salida, obtenidas a partir de los datos de superficie y de *GERB* y *SEVIRI* en el *TOA*.

#### **4.4 Estimación de la radiación neta en superficie a partir de *GERB* utilizando redes neuronales**

El modelo neuronal utilizado para la estimación de  $R_n$  en superficie a partir de *GERB* es el *Multi-Layer Perceptron (MLP)*, ya descrito con detalle en el Capítulo 3 (apartado 3.3.1.1).

##### **4.4.1 Datos utilizados en las fases de entrenamiento y validación del *MLP***

Con el fin de obtener un conjunto de datos  $R_n$  en superficie, para diferentes tipos de usos del suelo, dentro del pixel de *GERB* (Figura 4.5), se utilizaron, para el suelo desnudo las medidas de la *VAS* durante el período comprendido entre el 31 de julio y 06 de agosto de 2006, y entre el 19 de junio y 18 de agosto de 2007. Las medidas de  $R_n$  sobre viñas y matorral se obtuvieron en las estaciones móviles del *Grupo de Climatología desde Satélites* de La Universidad de Valencia durante la *IV Campaña SCALES de 2006* y la *Campaña FESEBAV 2007*, respectivamente. Estos datos se utilizaron como datos de salida del *MLP*.



**Figura 4.5** - Imagen *LANDSAT 5* de 8 de julio de 2003 con los 4 *footprints* de alta resolución de *GERB* sobre el área de estudio (Valencia Anchor Station - 50 x 50 km<sup>2</sup>). Los usos y clasificación del suelo de esta área se mostraron en la Figura 2.3 del Capítulo 2.

Las simulaciones se han realizado a partir de los datos obtenidos de las imágenes *GERB* generadas cada 15 minutos, sobre los 4 *footprints* seleccionados que cubren el área de estudio (Figura 4.5). Las 12606 imágenes de alta resolución espacial (12 x 15 km<sup>2</sup>), generadas a partir de la sinergia *GERB - SEVIRI*, obtenidas del *RMIB*, en formato *HDF*, y utilizadas en este trabajo, se procesaron utilizando un programa desarrollado específicamente con esta finalidad.

Los datos de *GERB* utilizados como datos de entrada del *MLP* se obtuvieron a partir de los flujos de *GERB* en banda ancha, respectivamente, de onda corta y onda larga. Para el análisis de *GERB*, que se propone en esta tesis, el tipo de datos seleccionados son independientes de la *Point Spread Function (PSF)* del instrumento, siendo sólo necesario tener en cuenta las dimensiones de los *footprints*. La *PSF*, función de dispersión puntual, traducida al castellano, es una medida de la fidelidad espacial del sistema sensor a bordo del satélite.

Con el fin de tener la misma resolución temporal, los datos de la *VAS* y de las estaciones móviles se interpolaron linealmente a la hora de la adquisición de las imágenes de *GERB* de un modo similar a como se explicó anteriormente para *SEVIRI* (apartado 4.2).

#### 4.4.2 Aplicación del Modelo MLP

Tratándose de flujos de radiación, es conveniente desarrollar el estudio, en primer lugar, separadamente para condiciones de cielo despejado y de cielo nublado y después, para el caso de cielo bajo cualquier condición de nubosidad, desde aquí en adelante denominado como cielo con nubosidad variable.

Por tanto, para la fase de entrenamiento y validación del MLP, se considerarán todas las condiciones del cielo, es decir, días nublados, días despejados y cielo con nubosidad variable. Se seleccionaron tres variables de entrada para el modelo neuronal: el ángulo solar cenital ( $SZA$ ), el flujo de onda corta ( $SWF$ ) y el flujo de onda larga ( $LWF$ ), flujos que se corresponden con las densidades de flujo radiativo de la energía solar reflejada y emitida en el TOA. Como variable de salida se utilizó  $R_n$  medida sobre viñas, matorral y suelo desnudo. Las Tablas 4.2, 4.3 y 4.4 presentan los estadísticos de los parámetros utilizados en el MLP, para las tres diferentes coberturas del suelo citadas anteriormente.

**Tabla 4.2** - Valores estadísticos de los parámetros físicos utilizados como datos de entrada ( $SWF$ ,  $LWF$ ) y salida ( $R_n$ ) en el modelo MLP. Los números de patrones utilizados para el conjunto de datos denominados cielo con nubosidad variable, cielo nublado y cielo despejado, fueron, sobre suelo desnudo, 6399, 4245 y 2154 respectivamente.

Parámetros de entrada/salida del MLP		SWF	LWF	$R_n$
Estadísticos	Condiciones del Cielo	Suelo Desnudo		
Mínimo	Despejado	0	203,00	-111,5
	Nublado	0	125,56	-113,0
	Variable	0	125,56	-113,0
Máximo	Despejado	274,25	350,69	594,0
	Nublado	715,81	344,69	713,5
	Variable	715,81	350,69	713,5
Media	Despejado	89,87	296,52	119,1
	Nublado	110,72	278,93	116,8
	Variable	103,70	284,85	117,6
Desviación estándar	Despejado	95,65	21,23	230,4
	Nublado	126,19	26,41	220,7
	Variable	117,22	26,14	224,0

**Tabla 4.3** - Valores estadísticos de los parámetros físicos utilizados como datos de entrada (*SWF*, *LWF*) y salida ( $R_n$ ) en el modelo *MLP*. Los números de patrones utilizados para el conjunto de datos denominados cielo con nubosidad variable, cielo nublado y cielo despejado, fueron, sobre las viñas, 5735, 3862 y 1873 respectivamente.

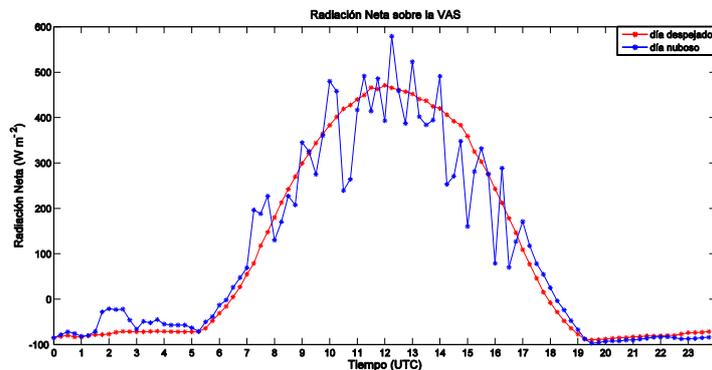
Parámetros de entrada/salida del <i>MLP</i>		SWF	LWF	$R_n$
<i>Estadísticos</i>	<i>Condiciones del Cielo</i>	<i>Viñas</i>		
Mínimo	Despejado	0	196,37	-70,4
	Nublado	0	124,25	-73,1
	Variable	0	124,25	-73,1
Máximo	Despejado	252,50	352,87	645,6
	Nublado	581,62	337,50	725,3
	Variable	581,62	352,87	725,3
Media	Despejado	87,71	297,93	163,5
	Nublado	107,71	278,47	153,3
	Variable	101,18	284,82	156,6
Desviación estándar	Despejado	93,77	21,64	249,2
	Nublado	121,29	26,63	236,1
	Variable	113,42	26,72	240,5

**Tabla 4.4** - Valores estadísticos de los parámetros físicos utilizados como datos de entrada (*SWF*, *LWF*) y salida ( $R_n$ ) en el modelo *MLP*. Los números de patrones utilizados para el conjunto de datos denominados cielo con nubosidad variable, cielo nublado y cielo despejado, fueron, sobre matorral, 472, 288 y 184 respectivamente.

Parámetros de entrada/salida del <i>MLP</i>		SWF	LWF	$R_n$
<i>Estadísticos</i>	<i>Condiciones del Cielo</i>	<i>Matorral</i>		
Mínimo	Despejado	0	275,62	-78,3
	Nublado	0	213,00	-69,9
	Variable	0	213,00	-78,3
Máximo	Despejado	267,75	339,25	625,2
	Nublado	743,37	330,00	608,1
	Variable	743,37	339,25	625,2
Media	Despejado	93,38	299,59	173,8
	Nublado	115,62	286,10	151,4
	Variable	106,95	291,36	160,2
Desviación estándar	Despejado	102,37	18,59	263,8
	Nublado	145,99	21,03	239,7
	Variable	131,06	21,15	249,3

La separación entre días nublados y despejados se realizó porque la radiación en superficie se ve afectada lógicamente por la cobertura de nubes. En la Figura 4.5 se presentan dos días típicos: uno nublado y otro despejado. Como puede verse, el ciclo diurno de  $R_n$  en días de cielo despejado presenta una forma regular, pero es bastante irregular en los días nublados. La magnitud de  $R_n$  varía durante el día porque el flujo

neto de onda corta ( $R_s^\downarrow - R_s^\uparrow$ ) y de onda larga ( $R_l^\downarrow - R_l^\uparrow$ ) varía, también, en función de la cantidad y altura de las nubes



**Figura 4.6** - Ciclo diario de la radiación neta medida en la VAS en dos días diferentes: 22 de julio de 2007 – día nublado y 02 de agosto de 2007 – día despejado.

Para cada superficie, se seleccionó el modelo neuronal que presentaba el error medio absoluto (*MAE*) más bajo en el conjunto de validación de los datos. Este índice se utiliza en lugar de la raíz del error cuadrático medio (*RMSE*), ya que es más robusto frente a los valores atípicos. La topología de la mejor red contaba con 3 entradas, 10 neuronas en la primera capa oculta y 3 en la segunda.

#### 4.4.3 Estimación de la radiación neta en superficie a partir de GERB utilizando modelos lineales: Resultados y discusiones

Con el fin de evaluar los modelos neuronales propuestos, se desarrollaron también modelos multivariantes de regresión lineal (*MLR*), con las mismas variables de entrenamiento establecidas para el modelo neuronal y aplicados también a viñas, matorral y suelo desnudo. Estas variables son el ángulo solar cenital (*SZA*), y los flujos de onda corta (*SWF*) y de onda larga (*LWF*) en el *TOA* – ver Ítem 4.4.2.

Para el modelo denominado *MLR* se utilizó como datos de entrada valores correspondientes al flujo de onda corta  $SWF > 0$  (valores durante el día). Para el modelo denominado *MLR1* se utilizó como datos de entrada valores correspondientes al flujo  $SWF \geq 0$  (ciclo diario, valores durante el día y durante la noche). Dichos modelos se muestran en las Tabla 4.5 y 4.6.

**Tabla 4.5** - Modelos multivariantes de regresión lineal obtenidos para viñas, suelo desnudo y matorral, considerando valores para  $SWF > 0$  para condiciones de cielo con nubosidad variable, nuboso y despejado, con sus respectivos  $R^2$  y N (número de patrones utilizados).

<b>MLR: Modelo Multivariado de Regresión Lineal</b>							
Usos del suelo	Condiciones del cielo	$R_n = \beta_0 + \beta_1 SZA + \beta_2 SW + \beta_3 LW$				Estadísticos $R^2$	N
		$\beta_0$	$\beta_1$	$\beta_2$	$\beta_3$		
Viñas	Variable	344,46	-210,27	-42,88	16,37	0,89	1978
	Nuboso	335,79	-202,79	-46,33	20,52	0,86	1341
	Despejado	367,61	-137,12	62,19	-3,96	0,97	650
Suelo Desnudo	Variable	295,46	-196,19	-51,64	2,67	0,87	2201
	Nuboso	288,20	-200,12	-57,65	0,78	0,84	1449
	Despejado	307,79	-154,98	9,16	7,29	0,96	728
Matorral	Variable	367,39	-126,37	18,79	91,75	0,93	158
	Nuboso	350,19	-106,74	25,66	112,69	0,93	96
	Despejado	410,71	64,61	213,14	39,72	0,98	57

**Tabla 4.6** – Modelos multivariantes de regresión lineal obtenidos para viñas, suelo desnudo y matorral, considerando valores para  $SWF \geq 0$  para condiciones de cielo con nubosidad variable, nuboso y despejado, con sus respectivos  $R^2$  y N (número de patrones utilizados).

<b>MLR1: Modelo Multivariado de Regresión Lineal</b>							
Uso del suelo	Condiciones del cielo	$R_n = \beta_0 + \beta_1 SZA + \beta_2 SW + \beta_3 LW$				Estadísticos $R^2$	N
		$\beta_0$	$\beta_1$	$\beta_2$	$\beta_3$		
Viñas	Variable	158,61	-154,11	51,10	50,16	0,88	3823
	Nuboso	156,72	-169,07	32,83	50,52	0,87	2574
	Despejado	169,85	-36,03	201,48	11,03	0,96	1248
Suelo Desnudo	Variable	119,28	-155,40	37,43	38,43	0,88	4266
	Nuboso	116,13	-165,53	26,54	35,62	0,85	2830
	Despejado	117,55	-38,16	174,26	15,34	0,96	1436
MATORRAL	Variable	160,57	-68,52	110,30	119,41	0,95	314
	Nuboso	150,96	-56,13	118,78	133,68	0,95	192
	Despejado	162,78	-13,06	207,10	47,90	0,99	122

Aunque los coeficientes de determinación sean muy próximos, los índices de error entre el valor observado y el valor previsto por los modelos *MLR* y *MRL1* poseen diferencias bastantes significativas, como se verá en las discusiones a continuación.

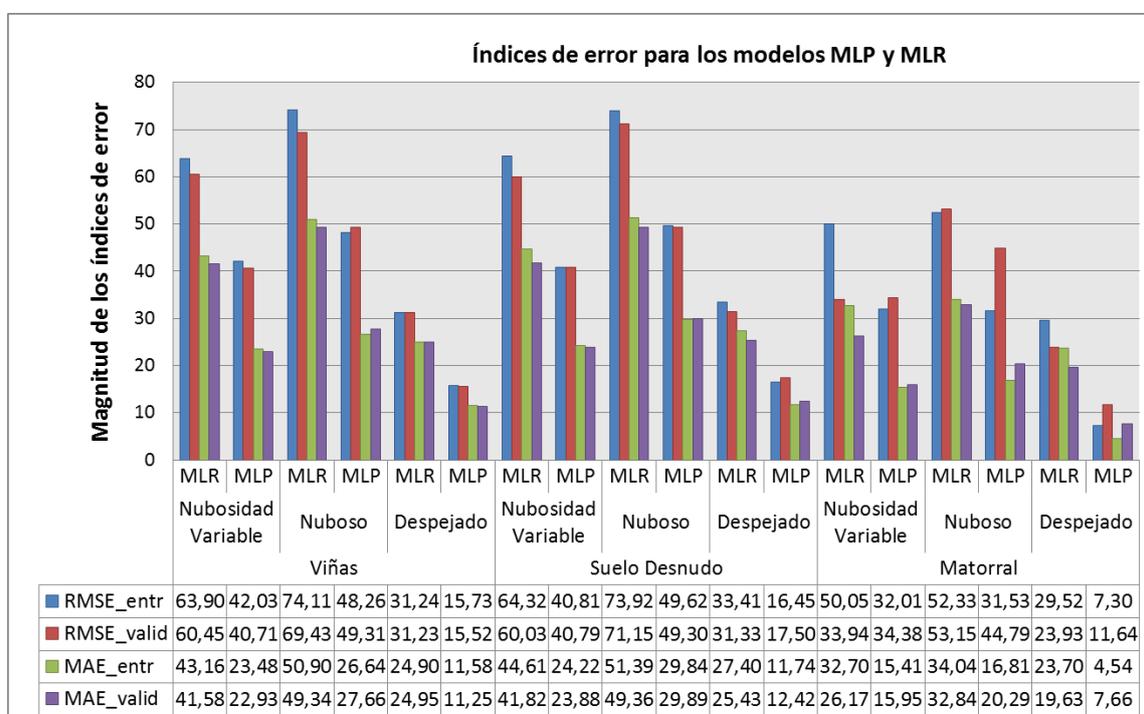
En la Tabla 4.7 se muestran los índices de error obtenidos, tanto para los *MLP* como para los *MLR*, la desviación estándar de los resultados de los modelos en las fases de entrenamiento y validación, y el coeficiente de determinación  $R^2$ .

**Tabla 4.7** - Índices de error para los conjuntos de datos de entrenamiento / validación del *MLP* y *MLR* para las viñas, suelo desnudo y matorral, considerando condiciones de cielo con nubosidad variable, nuboso y despejado.

Condiciones del Cielo /		Conjunto de Entrenamiento/Validación					
		Modelo	RMSE (W m <sup>-2</sup> )	MAE (W m <sup>-2</sup> )	ME (W m <sup>-2</sup> )	Std (W m <sup>-2</sup> )	R <sup>2</sup>
Viñas	Variable	MLR	63,90/60,45	43,16/41,58	-0,00/0,50	202,05/202,17	0,89/0,90
		MLP	42,03/40,71	23,48/22,93	-0,31/-0,05	241,44/238,65	0,96/0,96
	Nuboso	MLR	74,11/69,43	50,90/49,34	-0,00/1,55	201,69/205,35	0,86/0,88
		MLP	48,26/49,31	26,64/27,66	0,98/2,43	237,13/234,00	0,96/0,96
	Despejado	MLR	31,24/31,23	24,90/24,95	0,00/0,29	198,36/200,05	0,97/0,98
		MLP	15,73/15,52	11,58/11,25	0,17/0,14	251,22/245,00	0,98/0,98
Suelo Desnudo	Variable	MLR	64,32/60,03	44,61/41,82	0,00/2,61	179,42/186,62	0,87/0,90
		MLP	40,81/40,79	24,22/23,88	0,04/2,11	223,54/224,95	0,96/0,96
	Nuboso	MLR	73,92/71,15	51,39/49,36	-0,00/-3,06	185,11/182,81	0,84/0,85
		MLP	49,62/49,30	29,84/29,89	0,06/-1,25	221,17/219,87	0,94/0,94
	Despejado	MLR	33,41/31,33	27,40/25,43	0,00/-0,94	172,71/183,02	0,96/0,96
		MLP	16,45/17,50	11,74/12,42	0,79/0,64	229,06/233,16	0,98/0,98
Matorral	Variable	MLR	50,05/33,94	32,70/26,17	-0,00/-0,21	190,63/203,08	0,93/0,98
		MLP	32,01/34,38	15,41/15,95	0,83/0,32	248,77/251,24	0,98/0,98
	Nuboso	MLR	52,33/53,15	34,04/32,84	-0,00/7,64	184,65/210,82	0,93/0,94
		MLP	31,53/44,79	16,81/20,29	-1,98/0,83	238,83/242,71	0,98/0,96
	Despejado	MLR	29,52/23,93	23,70/19,63	0,00/-8,18	187,47/200,94	0,98/0,98
		MLP	7,30/11,64	4,54/7,66	-0,57/-2,25	265,98/260,15	0,98/0,98

Los índices de error para las fases de entrenamiento y validación del *MLP* y *MLR*, así como el  $R^2$ , son prácticamente los mismos. Pero nótese que estos índices en su gran mayoría, presentan valores más bajos en la fase de validación. Debe resaltarse, además, que la medida más importante es la correspondiente a la fase de validación porque esa medida corresponde al comportamiento del modelo una vez que éste ha sido entrenado.

Con el fin de permitir una mejor comparación entre los índices de error presentados en la Tabla 4.7, los valores del *RMSE* y *MAE* se presentan en forma gráfica en la Figura 4.7.



**Figura 4.7** - Índices de error para los conjuntos de datos de entrenamiento (entr) / validación (valid) del *MLP* y *MLR* para las viñas, vuelo desnudo y matorral, considerando condiciones de cielo con nubosidad variable, nuboso y despejado. Todos los valores están en unidades de  $W m^{-2}$ .

De acuerdo con la Tabla 4.7 y Figura 4.7, el modelo *MLP* para los días despejados produce resultados significativamente mejores que el modelo *MLR* teniendo en cuenta tanto las fases de entrenamiento y validación. Ahora, cuando nos fijamos en los índices de error para los días nubosos, estos aumentan de manera significativa tanto para los *MLP* como para los *MLR*, si se compara con los obtenidos para los días despejados, aunque los índices de error para los *MLR* presentan valores más elevados cuando se comparan con los obtenidos para los *MLP*. Pero en general, de

acuerdo con los índices de error y los coeficientes de determinación obtenidos, los resultados generados por los modelos neuronales son mejores que los obtenidos con los modelos lineales. Esto tiene una explicación física lógica: las medidas de radiancia del sistema Tierra-Atmosfera adquiridas en el TOA por GERB se utilizaron como parámetros de entrada para estimar  $R_n$  en superficie. Sin embargo, la radiación solar que llega a la superficie de la Tierra interactúa con la atmósfera de una forma no lineal, de modo que  $R_n$  en superficie es una función no lineal de las radiaciones de onda corta y onda larga. De acuerdo con Krzyscin (2003), debido a la dispersión múltiple de la radiación solar por las nubes situadas a diferentes niveles (bajo, medio y alto), la radiación solar medida a nivel del suelo no depende linealmente de la cantidad de nubes en cada nivel de las nubes.

Los resultados obtenidos en este estudio están en concordancia con los obtenidos por Pinker *et al.* (1985), Pinker y Tarpley (1988), y Bisht y Bras (2010), que muestran que las observaciones en el TOA hechas por satélite sirven como predictor de  $R_n$  en superficie. Bisht y Bras (2010), por ejemplo, utilizando el *Moderate Resolution Imaging Spectroradiometer (MODIS)* a bordo de los satélites *Aqua* y *Terra* de NASA, obtuvieron las siguientes estadísticas para días nublados y despejados (Tabla 4.8):

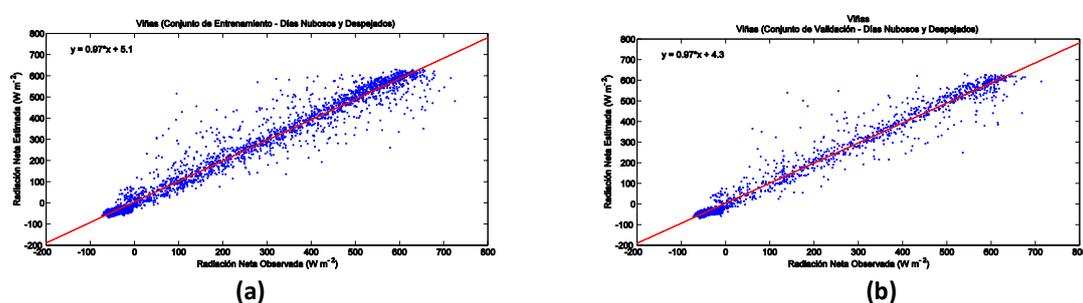
**Tabla 4.8** - Índices de error para los datos MODIS considerando diferentes condiciones del cielo.

$R_n$	Sesgo ( $W m^{-2}$ )		RMSE ( $W m^{-2}$ )		$R^2$	
	Nuboso	Despejado	Nuboso	Despejado	Nuboso	Despejado
Instantánea	35,16	23,08	50,58	39,34	0,95	0,96
Media Diaria	34,00	11,27	37,72	31,98	0,93	0,93

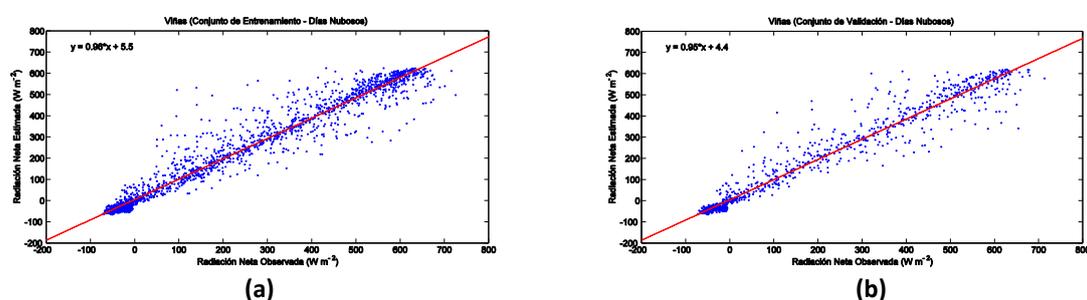
Los valores de  $R_n$  estimados en este trabajo, utilizando modelos neuronales y la sinergia entre GERB y SEVIRI, se muestran comparables a los obtenidos por Bisht y Bras (2010), destacando que las magnitudes de los índices de error obtenidos con el MLP, al considerar los días despejados, fueron significativamente más bajos. La ventaja de la metodología que aquí se presenta es que ésta puede aplicarse para generar y estudiar con más detalles la dinámica del ciclo diario completo de  $R_n$  en superficie y no sólo para medidas instantáneas o promedios diarios de  $R_n$ , obtenidos exclusivamente a

partir de datos de satélites de órbita polar que originan imágenes sobre una misma área dos veces al día.

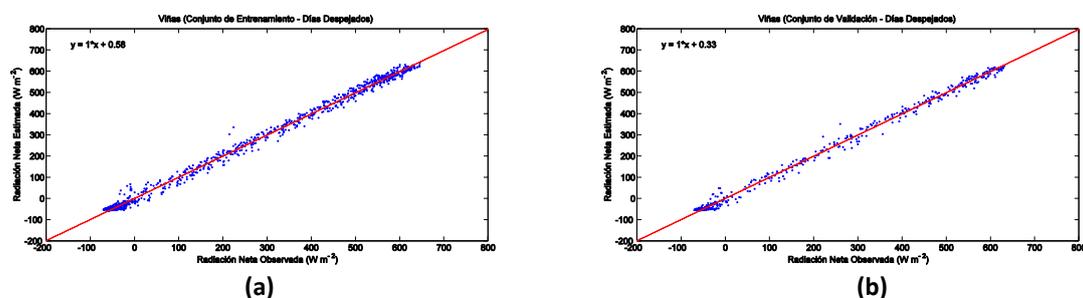
En las Figuras 4.8 a 4.25 se muestran los resultados de las comparaciones entre  $R_n$ , estimada por *MLP* y *MLR*, frente a  $R_n$  medida en el campo para el conjunto de entrenamiento y validación, considerando días con nubosidad variable, días nubosos y días despejados, para viñas, suelo desnudo y matorral. En la columna de la izquierda se representada el conjunto de entrenamiento y en la de la derecha el conjunto de validación.



**Figura 4.8** - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $\text{W m}^{-2}$ ), y la salida de la red ( $\text{W m}^{-2}$ ), para *cielo con nubosidad variable*. Modelo utilizado: *MLP*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *viñas*.



**Figura 4.9** - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $\text{W m}^{-2}$ ), y la salida de la red ( $\text{W m}^{-2}$ ), para *cielo nuboso*. Modelo utilizado: *MLP*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *viñas*.



**Figura 4.10** - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $\text{W m}^{-2}$ ), y la salida de la red ( $\text{W m}^{-2}$ ), para *cielo despejado*. Modelo utilizado: *MLP*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *viñas*.

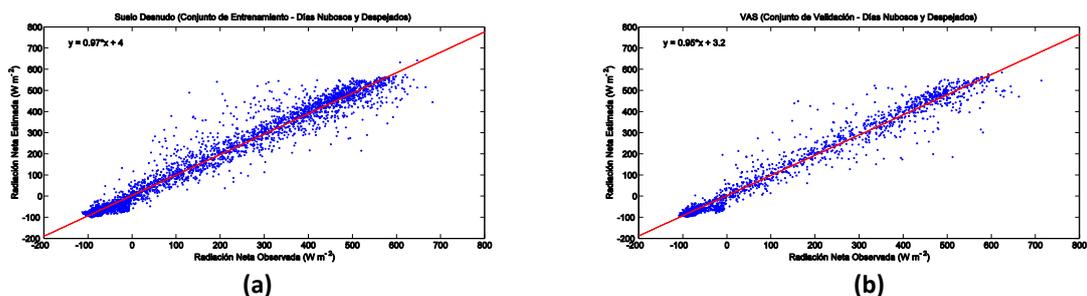


Figura 4.11 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo con nubosidad variable*. Modelo utilizado: MLP. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *suelo desnudo*.

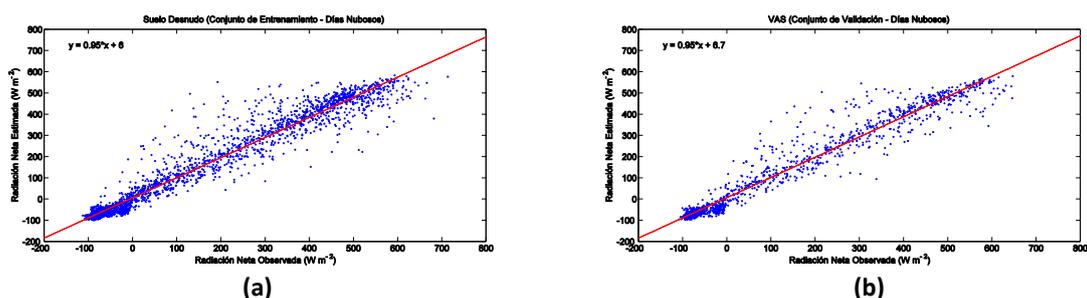


Figura 4.12 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo nuboso*. Modelo utilizado: MLP. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *suelo desnudo*.

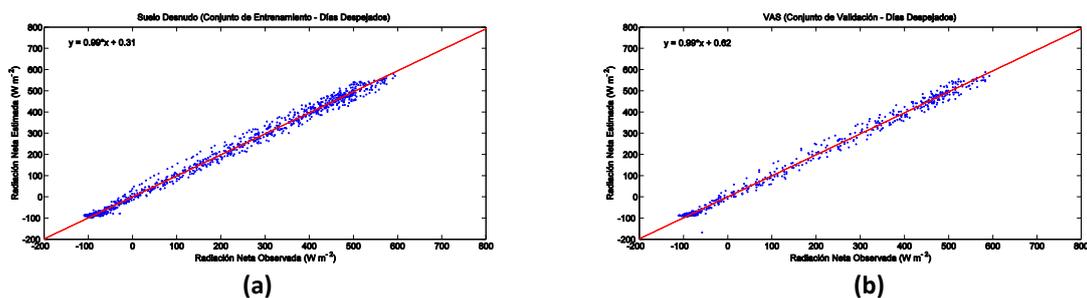


Figura 4.13 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo despejado*. Modelo utilizado: MLP. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *suelo desnudo*.

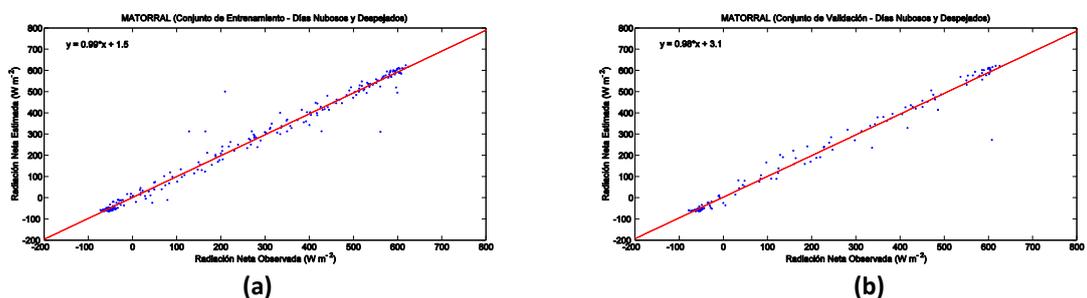
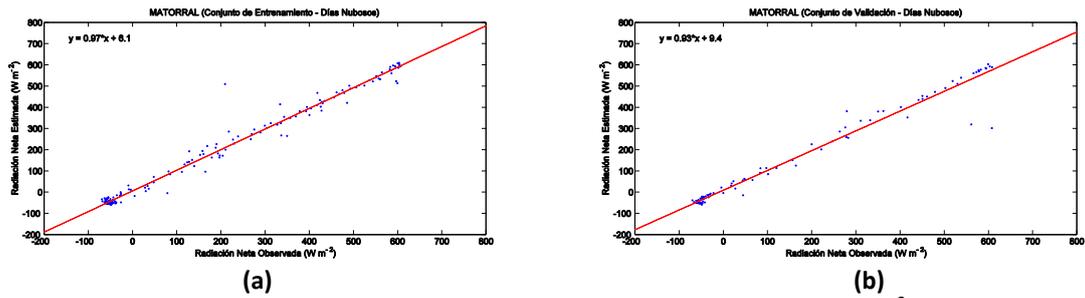
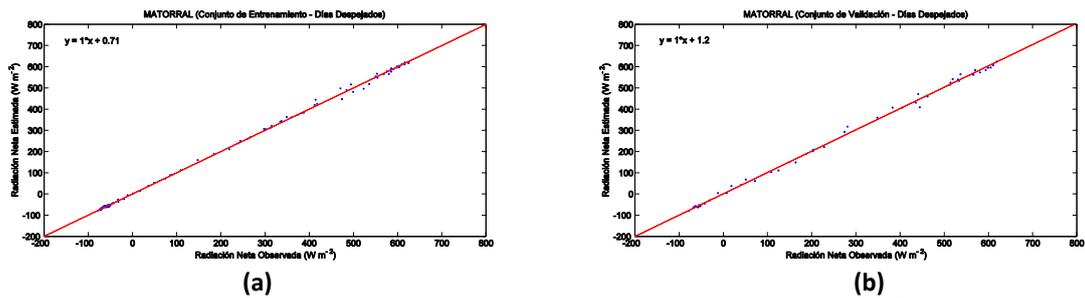


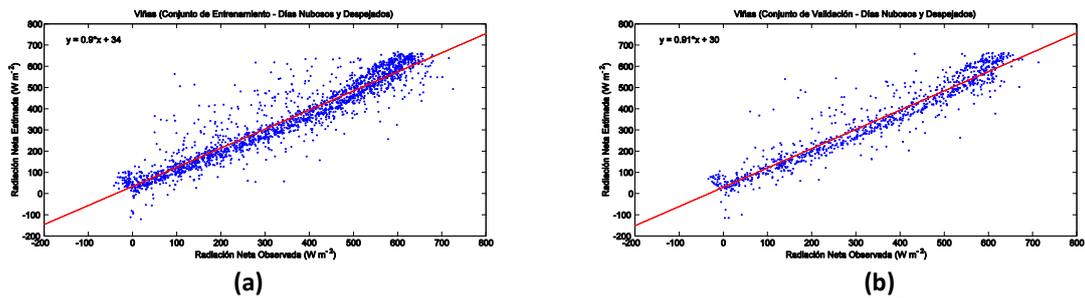
Figura 4.14 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo con nubosidad variable*. Modelo utilizado: MLP. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *matorral*.



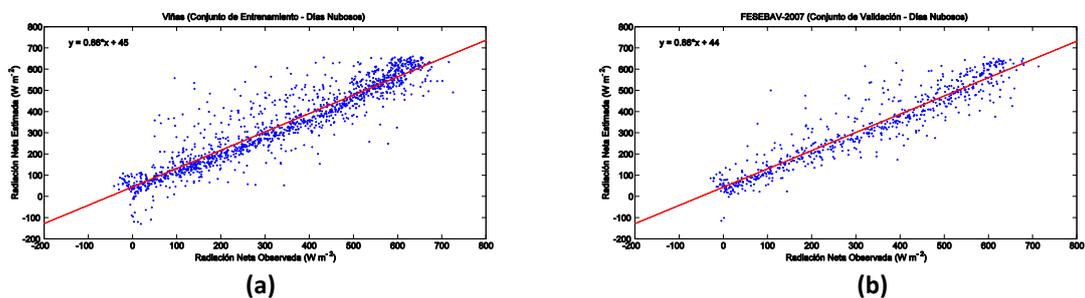
**Figura 4.15** - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo nublado*. Modelo utilizado: *MLP*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *matorral*.



**Figura 4.16** - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo despejado*. Modelo utilizado: *MLP*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *matorral*.



**Figura 4.17** - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo con nubosidad variable*. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) Conjunto de validación. Tipo de superficie: *viñas*.



**Figura 4.18** - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo nublado*. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) Conjunto de validación. Tipo de superficie: *viñas*.

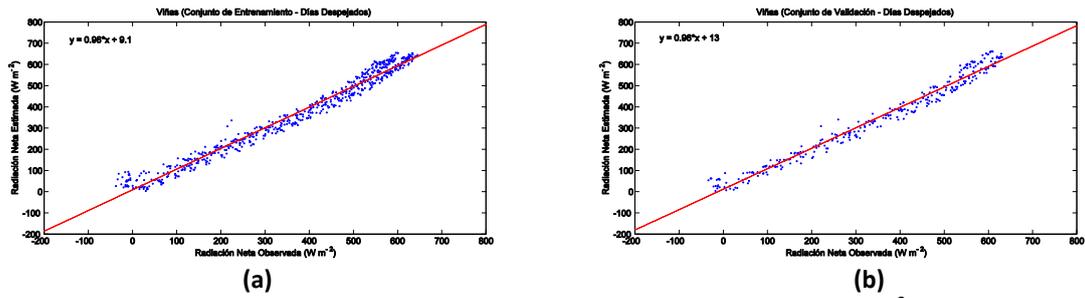


Figura 4.19 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo despejado*. Modelo utilizado: MLR. (a) conjunto de Entrenamiento y (b) conjunto de Validación. Tipo de superficie: *viñas*.

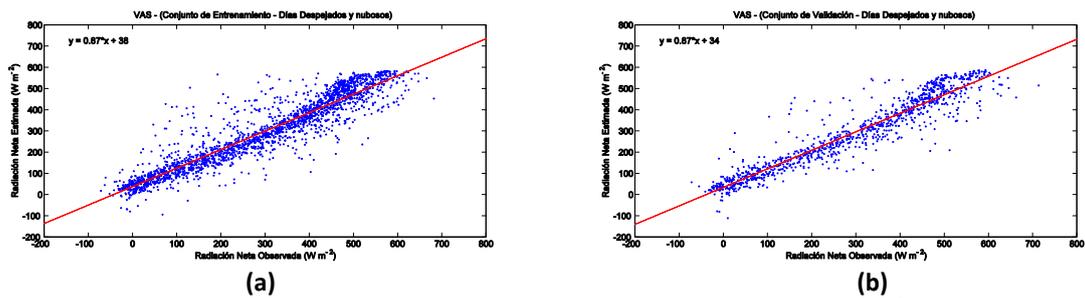


Figura 4.20 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo con nubosidad variable*. Modelo utilizado: MLR. (a) conjunto de entrenamiento y (b) Conjunto de validación. Tipo de superficie: *suelo desnudo*.

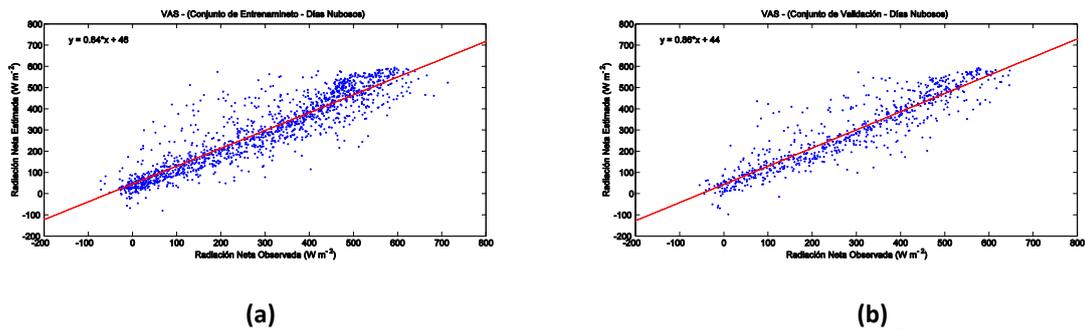


Figura 4.21 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo nublado*. Modelo utilizado: MLR. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *suelo desnudo*.

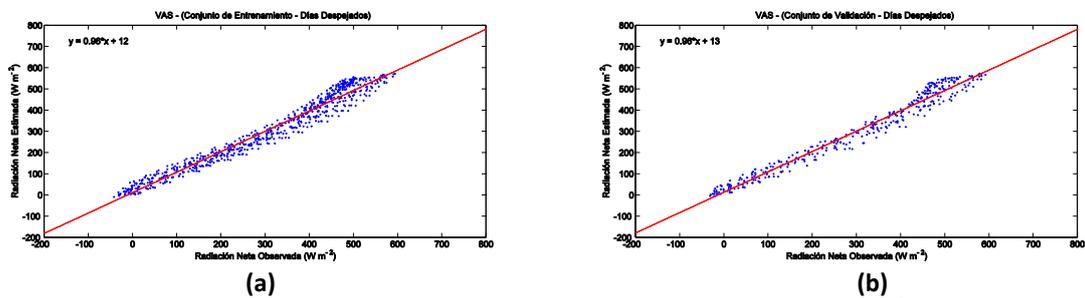


Figura 4.22 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $W m^{-2}$ ), y la salida de la red ( $W m^{-2}$ ), para *cielo despejado*. Modelo utilizado: MLR. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *suelo desnudo*.

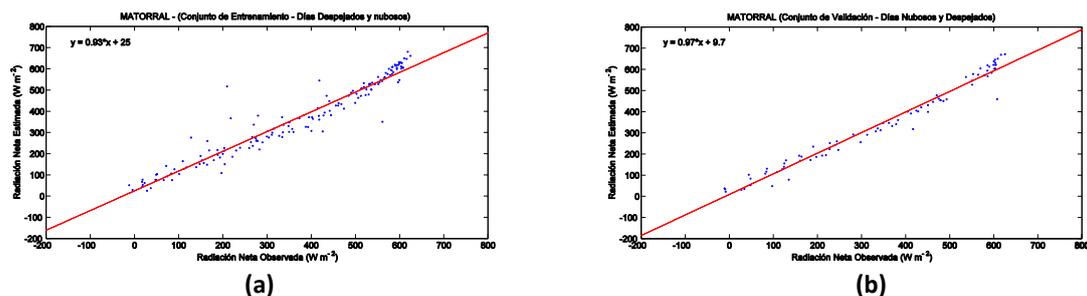


Figura 4.23 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $\text{W m}^{-2}$ ), y la salida de la red ( $\text{W m}^{-2}$ ), para *cielo con nubosidad variable*. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *matorral*.

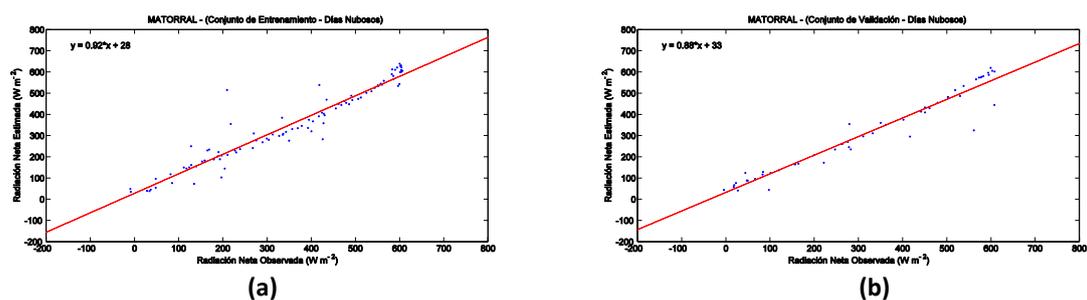


Figura 4.24 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $\text{W m}^{-2}$ ), y la salida de la red ( $\text{W m}^{-2}$ ), para *cielo nuboso*. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *matorral*.

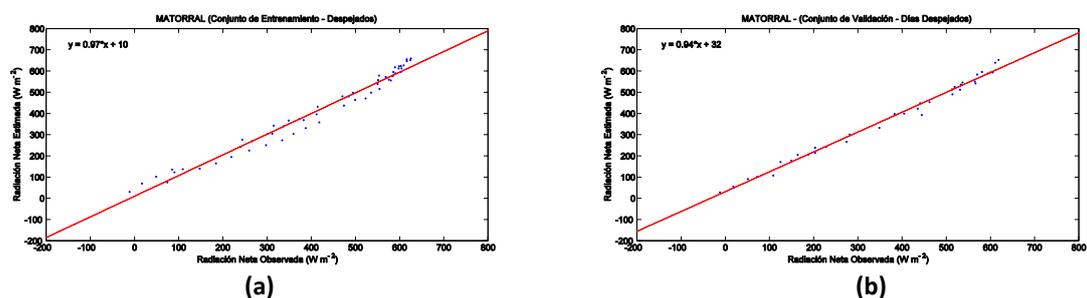


Figura 4.25 - Comparación entre la señal deseada, el valor de  $R_n$  en superficie ( $\text{W m}^{-2}$ ), y la salida de la red ( $\text{W m}^{-2}$ ), para *cielo despejado*. Modelo utilizado: *MLR*. (a) conjunto de entrenamiento y (b) conjunto de validación. Tipo de superficie: *matorral*.

Con el fin de facilitar el análisis y las comparaciones, las ecuaciones de los modelos de ajuste lineal del tipo  $y = ax + b$ , para los conjuntos de entrenamiento y validación presentados en las Figuras 4.8 a 4.25 se encuentran detalladas en la Tabla 4.9.

A través de las Figuras 4.8 a 4.25 se puede ver que los valores obtenidos por los modelos neuronales y lineales se acercan a las mediciones *in situ*. Para un ajuste lineal del tipo  $y = ax + b$ , para los conjuntos de entrenamiento y validación, todos los valores obtenidos para  $a$  son cercanos a 1 y los de  $b$  se acercan a 0 (ver ecuaciones en las

Figuras 4.8 a 4.25 o en la Tabla 4.9), lo que indica que hay un buen ajuste entre los valores estimados y los observados, principalmente en los días despejados, y también cuando se consideran los resultados de los MLP (Figuras 4.10 a y b, 4.13a y b, 4.16 a y b).

**Tabla 4.9** - Ajuste lineal del tipo  $y = ax + b$ , para los conjuntos de entrenamiento y validación de los modelos MLP y MLR.

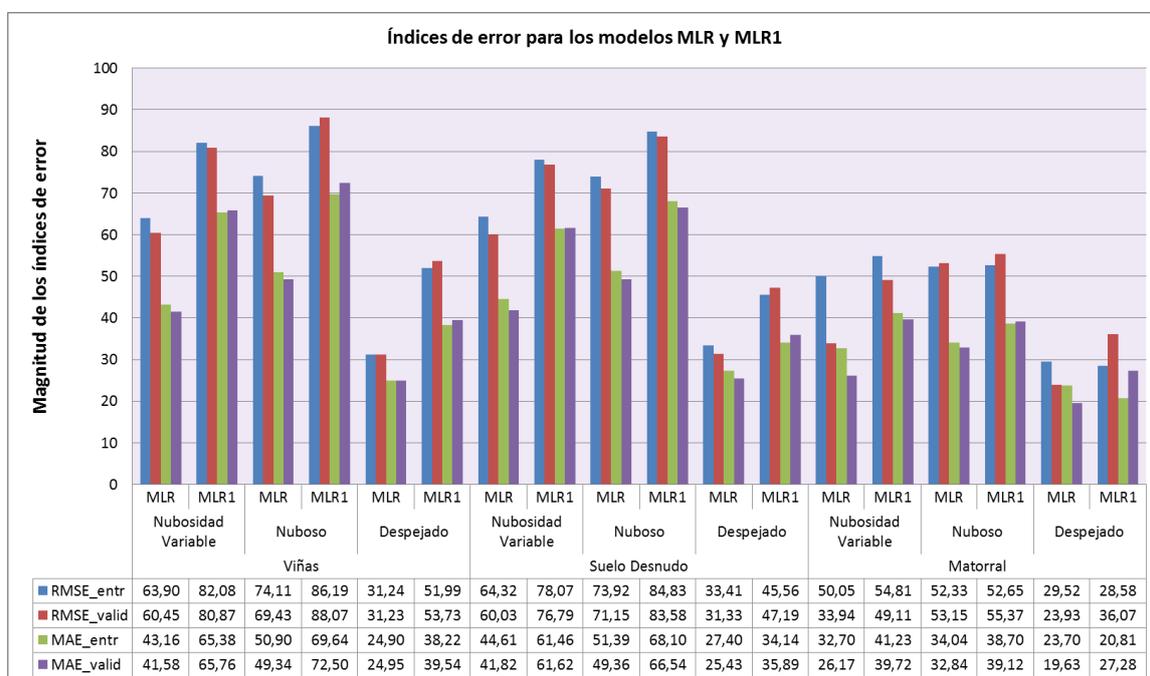
Modelo	Entrenamiento	Validación	Figuras	Condiciones del cielo
<b>VIÑAS</b>				
MLP	$y = 0,97x + 5,1$	$y = 0,97x + 4,3$	4.8a y b	Variable
MLR	$y = 0,90x + 34,0$	$y = 0,91x + 30,0$	4.17a y b	
MLP	$y = 0,96x + 5,5$	$y = 0,95x + 4,4$	4.9a y b	Nuboso
MLR	$y = 0,86x + 45,0$	$y = 0,86x + 44,0$	4.18a y b	
MLP	$y = 1,0x + 0,58$	$y = 1,0x + 0,33$	4.10a y b	Despejado
MLR	$y = 0,96x + 91$	$y = 0,96x + 13,0$	4.19a y b	
<b>SUELO DESNUDO</b>				
MLP	$y = 0,97x + 4,0$	$y = 0,95x + 3,2$	4.11a y b	Variable
MLR	$y = 0,87x + 38,0$	$y = 0,87x + 34,0$	4.20a y b	
MLP	$y = 0,95x + 6,0$	$y = 0,95x + 6,7$	4.12a y b	Nuboso
MLR	$y = 0,84x + 48,0$	$y = 0,86x + 44,0$	4.21a y b	
MLP	$y = 0,99x + 0,31$	$y = 0,99x + 0,62$	4.13a y b	Despejado
MLR	$y = 0,96x + 12,0$	$y = 0,96x + 13,0$	4.22a y b	
<b>MATORRAL</b>				
MLP	$y = 0,99x + 1,5$	$y = 0,98x + 3,1$	4.14a y b	Variable
MLR	$y = 0,93x + 25$	$y = 0,97x + 9,7$	4.23a y b	
MLP	$y = 0,97x + 6,1$	$y = 0,93x + 9,4$	4.15a y b	Nuboso
MLR	$y = 0,92x + 26$	$y = 0,88x + 33$	4.24a y b	
MLP	$y = 1,0x + 0,71$	$y = 1,0x + 1,2$	4.16a y b	Despejado
MLR	$y = 0,97x + 10$	$y = 0,94x + 32$	4.25a y b	

Para los conjuntos de entrenamiento y validación, todos los  $R^2$  obtenidos, tanto para los modelos lineales como para los modelos neuronales variaron entre 0,84 y 0,98 (Tabla 4.7), teniendo en cuenta un  $\alpha = 0,05$  (nivel de significación). Aunque los valores de  $R^2$  obtenidos tanto para los MLP como para los MLR fueron altos, los índices de

error presentados por los *MLP* son significativamente inferiores como se discutió anteriormente.

A pesar del buen ajuste presentado entre el valor observado y el valor previsto por los *MLR* hay que tener en cuenta que no es posible generar el ciclo diurno completo de  $R_n$  con un buen grado de precisión utilizando dichos modelos. Esto es así porque uno de los parámetros utilizados como dato de entrada en el *MLR* ( $R_n = \beta_0 + \beta_1 SZA + \beta_2 SW + \beta_3 LW$ ) es la onda corta (*SW*) medida en el *TOA* con *GERB* que, para ángulos solares cenitales (*SZA*) superiores a 80 grados se considerada igual a cero. De acuerdo con el “*RMIB GERB Products User Guide – Version 2.2, sesión 4.30*” el flujo solar presenta error si el ángulo de visión cenital o el ángulo solar cenital es superior a 80 grados.

Cuando se consideran los modelo *MLR1* ( $SWF = 0$ ; periodo nocturno) los índices de error crecen significativamente cuando se comparan con los modelos *MLR* utilizados para estimar  $R_n$  solamente durante el día (ver Figura 4.26).



**Figura 4.26** - Índices de error para los conjuntos de datos de entrenamiento (entr) / validación (valid) del *MLR* y *MLR1* para viñas, suelo desnudo y matorral, considerando condiciones de cielo con nubosidad variable, nuboso y despejado. Todos los valores están en  $W m^{-2}$ .

Por la noche, los modelos consideran solamente la componente de onda larga, que es lógicamente la única presente durante el período nocturno. Además, los modelos *MLR1* no contienen ninguna corrección para los factores que afectan a la radiación de onda larga saliente tales como la temperatura de la superficie y los perfiles verticales de temperatura o de vapor de agua atmosférico, como ya se mencionó en el capítulo 3. En la figura 4.27 podemos apreciar  $R_n$  observada en la estación y  $R_n$  estimada por el modelo *MLR1* que presenta, para cielo con nubosidad variable, por la noche, y para los primeros veinticuatro días de agosto (durante el día), una subestimación de  $R_n$ . Pero cuando se compara los ajustes entre  $R_n$  observada en la estación y  $R_n$  estimada por el modelo *MLR1* con los ajustes proporcionados por el modelo *MLP* se verifica que el *MLP* presenta un ajuste mucho mejor (ver Figura 4.34). Los índices de error presentados por los *MLP*, para suelo desnudo, se muestran en la Tabla (4.7).

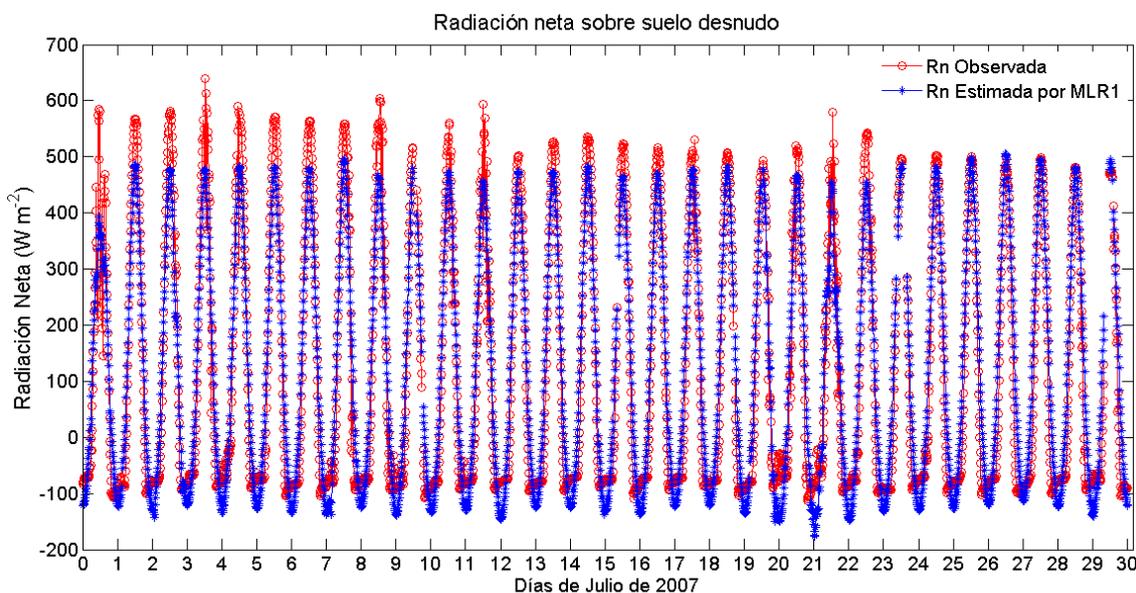


Figura 4.27 -  $R_n$  observada y estimada por *MLR1* sobre suelo desnudo para el mes de julio de 2007.

Dentro de los conjuntos de datos presentados, analizados y modelizados en esta tesis escogemos, como referencia de comparación con el modelo neuronal *MLP*, el modelo multivariante de regresión lineal *MLR* por presentar menores índices de error que el *MLR1*. A título de ejemplo, se ha elegido el mes de julio de 2007 para mostrar gráficamente, figuras que siguen, la comparación entre la  $R_n$  observada por la estación meteorológica y la  $R_n$  estimada por los modelos multivariante de regresión

lineal y neuronales, considerando días nublados y despejados sobre viñas y suelo desnudo.

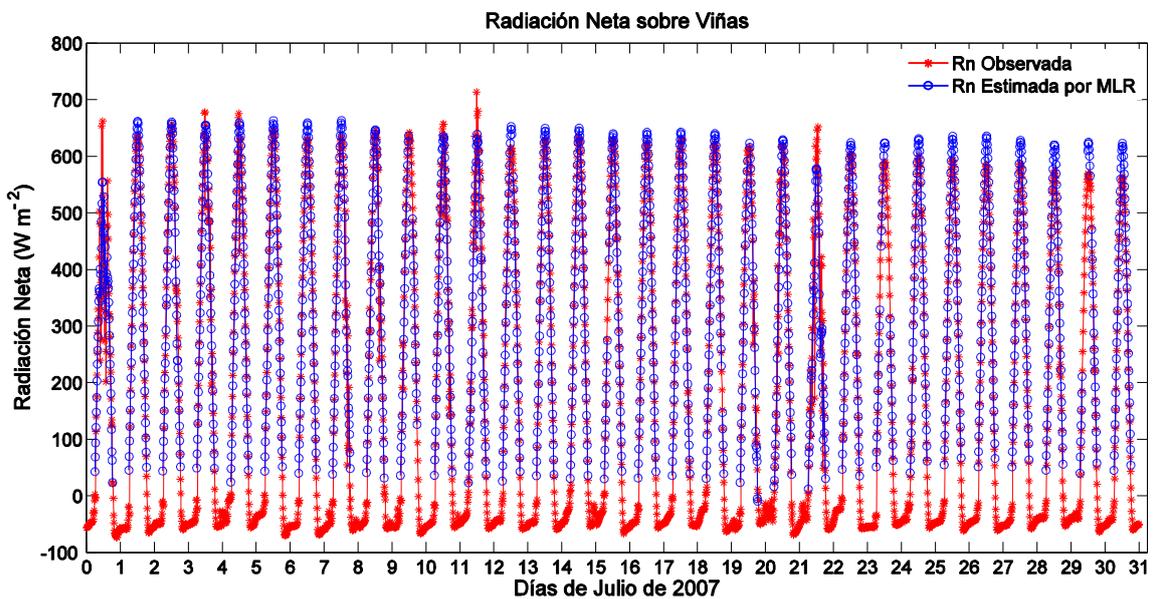


Figura 4.28 -  $R_n$  observada y estimada por *MLR* sobre viñas para el mes de julio de 2007.

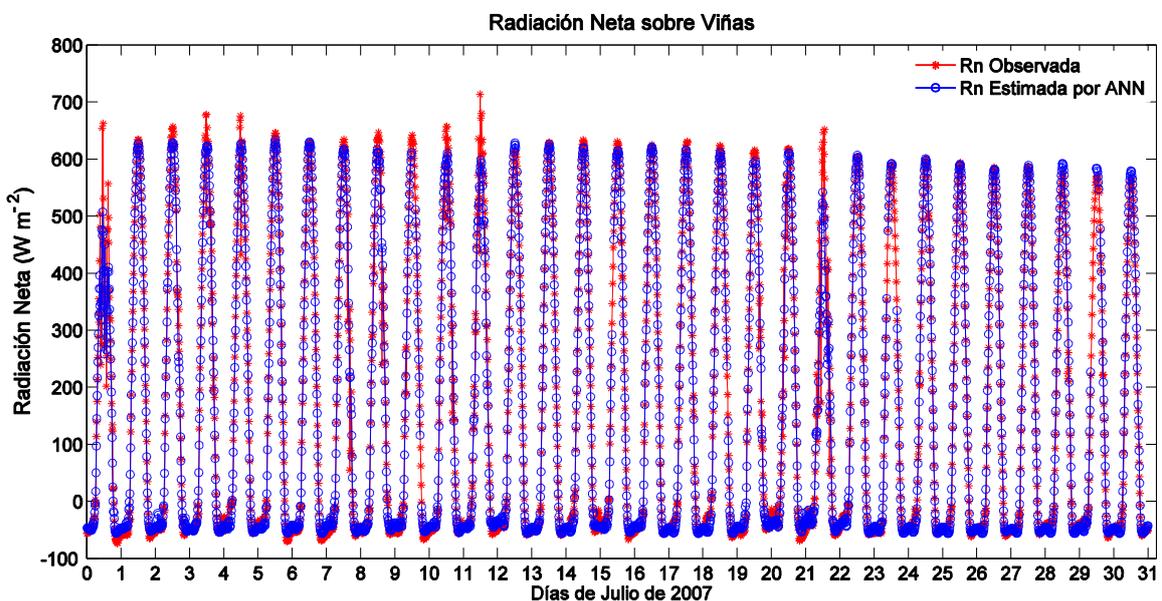


Figura 4.29 -  $R_n$  observada y estimada por *MLP* sobre viñas para el mes de julio de 2007.

La Figura 4.30 presenta la  $R_n$  observada y estimada por *MLR* y *MLP* sobre viñas para los días 11, 12, 13 y 14 de julio de 2007, extraída de la serie de datos presentada en las Figuras 4.28 y 4.29. Obsérvese que para el 11 y el 12 tanto el *MLP* como el *MLR* presentan problemas para ajustarse a los valores observados de  $R_n$  cuando en determinado período del día el cielo queda cubierto de nubes. En los días despejados

(13 y 14) tanto el *MLP* como el *MLR* presentan buen ajuste frente a los valores observados de  $R_n$ , destacando el hecho de que, además de sobre-estimar la  $R_n$  alrededor del medio día, la  $R_n$  estimada por *MLR* (color azul en la Figura 4.30) no cubre todo el ciclo diurno de la misma.

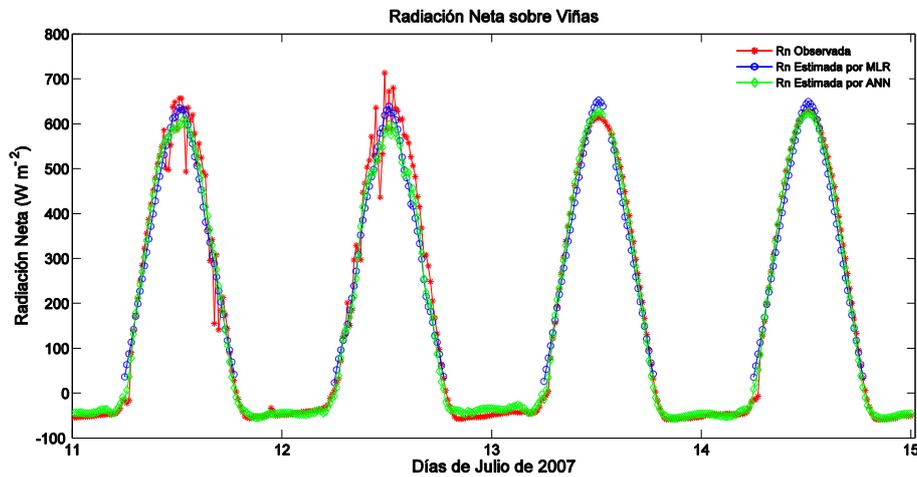


Figura 4.30 -  $R_n$  estimada por *MLR* y *MLP* sobre viñas para los días 11, 12, 13 y 14 de julio de 2007.

La Figura 4.31 presenta la  $R_n$  observada y estimada por *MLR* y *MLP*, sobre viñas para los días 8, 9, 10, 11 y 12 de julio de 2007, donde para el desarrollo de dichos modelos sólo se consideraron días nublados dentro de la serie de datos. Se verifica aquí también, que tanto el *MLP* como el *MLR* presentan buen ajuste frente a los valores observados de  $R_n$ , y que el *MLR* sobre-estima  $R_n$  alrededor del medio día (color azul en la Figura 4.31) y no cubre todo el ciclo diurno de  $R_n$ .

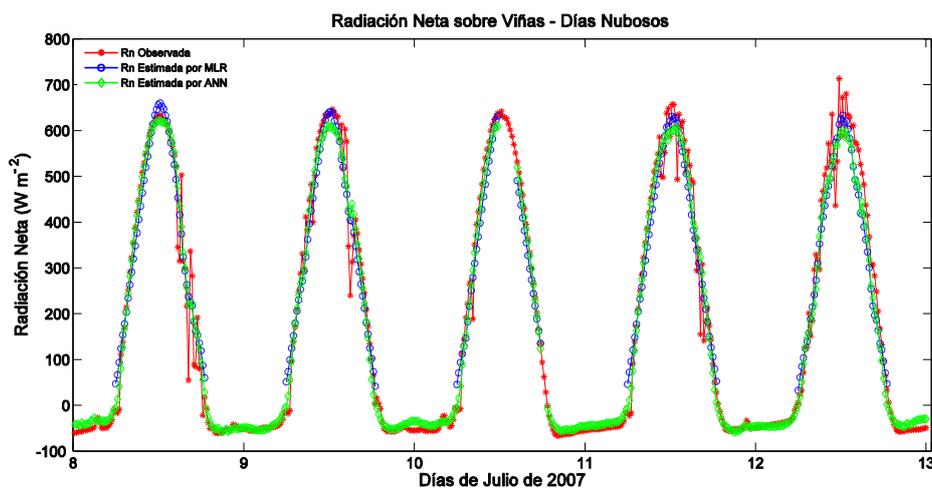


Figura 4.31 -  $R_n$  estimada por *MLR* y *MLP* sobre viñas para los días 8, 9, 10, 11 y 12 de julio de 2007.

La Figura 4.32 presenta la  $R_n$  observada y estimada por *MLR* y *MLP*, sobre viñas para los días 26, 27 y 28 de julio de 2007, donde para el desarrollo de dichos modelos

sólo se consideraron días despejados, dentro de la serie de datos. Se verifica aquí también, que tanto el *MLP* como el *MLR* presentan buen ajuste frente a los valores observados de  $R_n$ , y que el *MLR* sobre-estima  $R_n$  alrededor del medio día (color azul en la Figura 4.32) y no cubre todo el ciclo diurno de  $R_n$ .

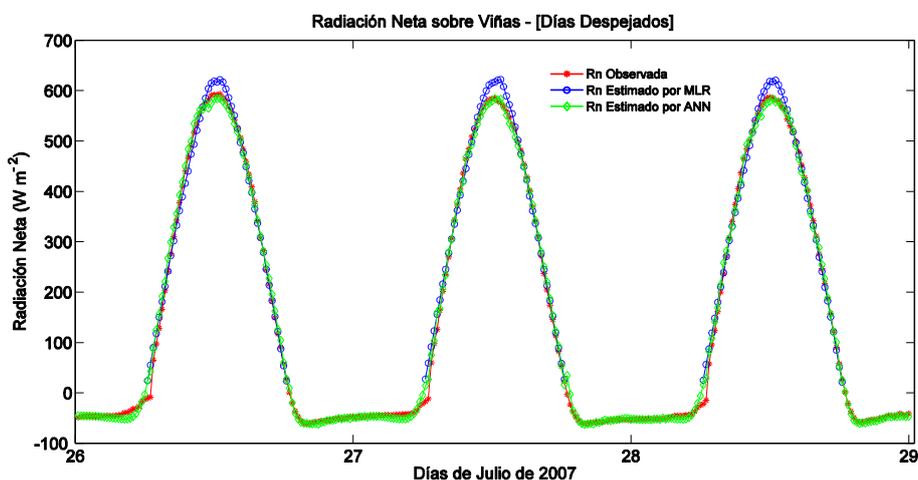


Figura 4.32 - Comparación *MLR* x *MLP* para días despejados: 26, 27, 28 de julio de 2007.

Las Figuras 4.33 y 4.34 presentan la  $R_n$  observada y estimada por *MLR* y *MLP* sobre suelo desnudo para julio de 2007 y caben los mismos comentarios ya hechos para las figuras anteriores 4.30, 4.31 y 4.32.

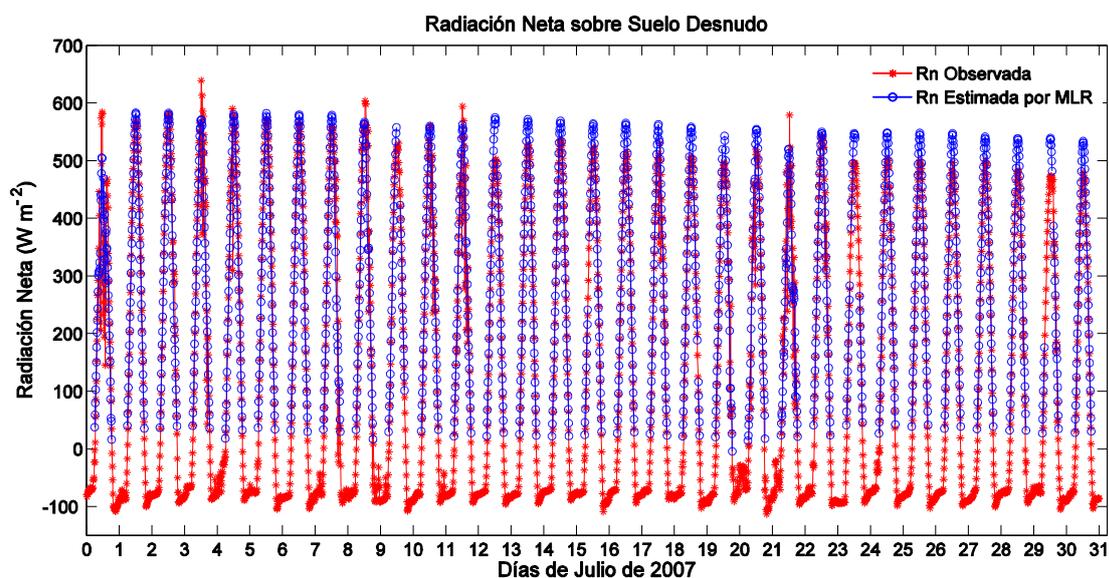


Figura 4.33 -  $R_n$  observada x estimada por *MLR* sobre suelo desnudo para el mes de julio de 2007.

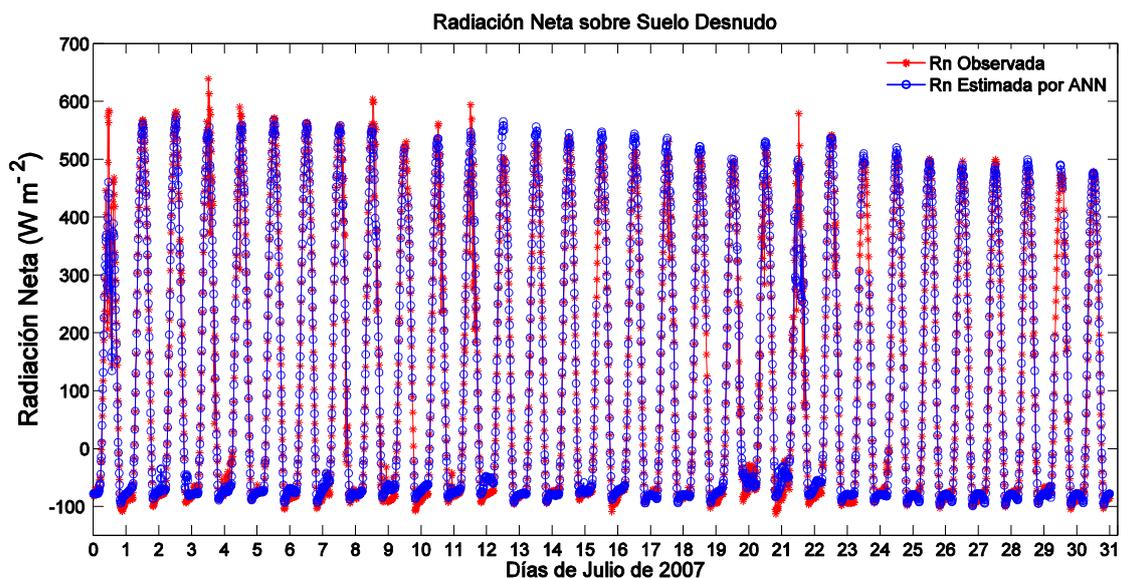


Figura 4.34 -  $R_n$  observada x estimada por MLP sobre suelo desnudo para el mes de julio de 2007.

Se puede ver que a pesar de la dificultad en la predicción de  $R_n$  en superficie para días nublados, como se mencionó anteriormente, la red es capaz de modelizar  $R_n$  con un buen grado de exactitud a partir de datos GERB.

Estos resultados muestran que la sinergia entre los sensores GERB y SEVIRI, asociada a la capacidad de los modelos neuronales para establecer relaciones entre medidas de parámetros meteorológicos medidos en superficie, sobre cualquier condiciones del cielo, y los flujos radiativos en el TOA, son herramientas poderosas para estimar una de las variables fundamentales en la evolución del clima tanto a nivel local como regional y global,  $R_n$ . Además, estos resultados abren una importante línea de investigación para ser explotada, es decir, la posibilidad de utilizar modelos de redes neuronales para mejorar el conocimiento del clima y los estudios del balance de energía en superficie a partir de observaciones hechas por satélites en el TOA.

## CONCLUSIONES Y TRABAJOS FUTUROS

En este apartado se presentan las conclusiones técnicas principales del trabajo realizado, así como algunas recomendaciones para trabajos futuros.

### 5.1 Principales conclusiones técnicas extraídas del trabajo

1. Para estudiar la dinámica de la radiación neta en superficie ( $R_n$ ) se han desarrollado modelos lineales y modelos neuronales artificiales (ANNs). Los buenos resultados obtenidos demuestran que los ANNs son herramientas muy útiles para estimar  $R_n$  en superficie a partir de parámetros meteorológicos, principalmente en zonas donde los flujos relacionados con la radiación no se miden de manera rutinaria. También se han desarrollado ANNs específicos para obtener la radiación neta en superficie a partir de las medidas de satélite en el techo de la atmósfera. El desarrollo de los modelos neuronales en este contexto constituye una metodología original cuya potencialidad se ha puesto de manifiesto en esta Tesis Doctoral y en las publicaciones científicas conseguidas.

2. Para visualizar y analizar de forma cualitativa las relaciones entre las variables meteorológicas medidas *in situ* y  $R_n$  se ha utilizado el SOM (*Self Organizing Map*). Se ha demostrado que el SOM es una poderosa herramienta para seleccionar visualmente las variables de entrada más significativas para los modelos desarrollados en este trabajo. Además permite, determinar el número de comportamientos diferentes que se tienen en los datos mediante un análisis de agrupamientos.

3. Los análisis del modelo neuronal propuesto han demostrado que es posible estimar  $R_n$  a partir de datos meteorológicos (precipitación, temperatura del aire, humedad relativa del aire, presión atmosférica, velocidad y dirección del viento) medidos en estaciones meteorológicas convencionales, siendo la presión atmosférica y la temperatura del aire las variables de entrada más relevantes en el modelo neuronal.

4. Los modelos lineales más utilizados para estimar  $R_n$  en superficie utilizan para su desarrollo la radiación solar incidente y el albedo, no pudiéndose por tanto aplicar durante los períodos nocturnos. El valor de  $R_n$  que proporcionan no es correcto porque no tienen en cuenta la componente de onda larga de la radiación neta que, obviamente, es más significativa durante la noche.

5. Los modelos neuronales tienen la capacidad de predecir  $R_n$  con unos pocos parámetros meteorológicos. Como no utilizan la radiación solar y el albedo como dato de entrada, dichos modelos permiten estimar el ciclo diurno completo de  $R_n$ , con errores entre  $\pm 5$  y  $30 \text{ W m}^{-2}$ . Por lo tanto, una vez entrenado, el modelo neuronal puede utilizarse para estimar este parámetro ( $R_n$ ) de alta significación climática pero con una alta dificultad de medida.

6. Se han desarrollado modelos lineales para estimar el flujo de calor en suelo ( $G$ ) a partir de  $R_n$ , en cultivos de viñas, para dos localidades diferentes. Estos modelos presentaran un alto coeficiente de correlación ( $R^2 = 0,78$  y  $0,89$ ) y, en promedio, proporcionan valores de  $G$  que representan alrededor del 18% de  $R_n$ . También hemos verificado que tanto el flujo de radiación como el de calor en el suelo están dominados por el ciclo diario (fundamentalmente en condiciones de cielo despejado) y que los niveles de radiación solar interceptados por el cultivo en estudio, vienen afectados en días nublados.

7. Para estimar  $G/R_n$  a escala regional es posible utilizar la metodología propuesta por Santanello y Friedel (2003), que hace posible el uso de datos de satélites, una vez que la temperatura de la superficie ( $LST$ ) puede obtenerse de *SEVIRI*, el cual proporciona estimaciones de este parámetro con una frecuencia sin precedentes de 15

minutos y con una resolución espacial de  $3,1 \text{ km}^2$ , cubriendo totalmente el ciclo diurno de la *LST*. El coeficiente de correlación entre la temperatura estimada por *SEVIRI* y la medida en campañas de campo sobre matorral y viñas tienen valores altamente significativos ( $R^2 \geq 0,94$ ), lo cual pone de manifiesto la idoneidad de la zona y la significación de las medidas de las estaciones a la hora de compararse con las estimaciones de teledetección.

8. A través de la sinergia entre *GERB* y *SEVIRI* es posible obtener  $R_n$  en superficie, a partir de los flujos de onda corta y onda larga en el *TOA*, medidos con *GERB*, con una resolución espacial de  $12 \times 15 \text{ km}^2$ , para nuestra área de estudio (en el Ecuador terrestre esta resolución es más alta:  $9 \times 9 \text{ km}^2$ ), y con una resolución temporal de 15 minutos, cubriendo así todo el ciclo diurno de  $R_n$ . Esta es una aportación significativa, una vez que  $R_n$  estimada a partir de satélites de órbita polar ofrecen imágenes sobre una misma área solamente dos veces al día y, por tanto, no permiten directamente estimar el ciclo diurno completo de  $R_n$ .

9. La comparación de los resultados obtenidos por el modelo neuronal (*MLP*) propuesto para estimar  $R_n$ , a partir de la sinergia entre *GERB* y *SEVIRI*, con un modelo multivariante lineal (*MLR*), indicaron que el *MLP*, para los días despejados, produce resultados significativamente mejores que el modelo *MLR*. Para los días nubosos los índices de error aumentan para ambos modelos, pero los errores del *MLR* son mayores que los del *MLP*.

10. La radiación solar que llega a la superficie de la Tierra interactúa con la atmósfera de forma no lineal, de modo que  $R_n$  en superficie es una función no lineal de las radiaciones de onda corta y onda larga. Esto conlleva que hay que usar un modelo no lineal, en nuestro caso un modelo neuronal, y que éste se puede utilizar como una metodología alternativa para estimar  $R_n$  solucionando, implícitamente, el proceso de corrección atmosférica.

## 5.2 Extensiones para trabajos futuros

El trabajo desarrollado hasta ahora muestra que la sinergia entre los sensores *GERB* y *SEVIRI*, a bordo de los satélites *MSG*, asociada a la capacidad de los modelos neuronales para establecer relaciones cualitativas y cuantitativas entre magnitudes meteorológicas comunes (y fácilmente medibles) y flujos radiativos en el *TOA*, son herramientas poderosas para estimar  $R_n$  que es una de las variables fundamentales en la evolución del clima tanto a nivel local como regional y global. Por tanto, las ideas reflejadas en este trabajo se pueden extender en una serie de direcciones:

- La metodología empleada para la aplicación de los modelos neuronales a las viñas, matorral y suelo desnudo puede extenderse a otras superficies y así desarrollar modelos para distintas superficies estableciendo una caracterización de su comportamiento mediante los modelos obtenidos. Estos modelos permitirían un análisis más profundo de las propiedades de las superficies estudiadas.
- Los modelos neuronales desarrollados a una escala puntual, asociados a la sinergia entre *GERB* y *SEVIRI*, que permite estimar  $R_n$  una con alta resolución espacial y temporal, deben generalizarse para su aplicación a escalas regionales y globales. Para tal finalidad se puede, por ejemplo, utilizar los datos de  $R_n$  de la red *ARM* (*Atmospheric Radiation Measurement*).
- La potencia del modelo desarrollado se manifiesta por los resultados proporcionando estimaciones fiables de  $R_n$ . Su extensión a la consideración de los demás flujos del balance de energía en superficie, especialmente la obtención de la evapotranspiración es de gran significación por su aplicación directa en temas agrometeorológicos y agroclimáticos en lo que se refiere a gestión de recursos hídricos, técnicas de riego, etc. encaminadas al desarrollo de una agricultura de precisión.

## **BIBLIOGRAFIA**

---

Abdelghania, C., Hoedjesa, J. C. B., Rodriguez, J.C., Watts, C. J., Garatuzac, J., Jacobd, F., Kerr, Y. H, 2008. Using remotely sensed data to estimate area-averaged daily surface fluxes over a semi-arid mixed agricultural land. *Agricultural and Forest Meteorology*, **148** (3), 330 - 342.

Alados, I., Foyo-Moreno, I., Olmo, F.J., Alados-Arboledas, L., 2003. Relationship between net radiation and solar radiation for semi-arid shrub-land. *Agricultural and Forest Meteorology*, **116** (3 - 4), 221 - 227.

Allen, R. G.; Pereira, L. S.; Raes, D.; Smith, M., 1998. *Crop Evapotranspiration: Guidelines for computing crop water requirements, Rome: FAO*, 301 pp. Irrigation and Drainage Paper 56.

Amarakoon, D., Chen, A., 1999. Estimating daytime net radiation using routine meteorological data in Jamaica. *Caribbean Journal of Science*, **35** (1-2), 132 - 141.

Anandakumar, k., Venkatesan, R., Prabha, T. V., 2001. Soil thermal properties at Kalpakkan in coastal south India. *Earth Planet Science*, **110** (3), 239 - 245.

Arbib, 2003. *The Handbook of brain theory and neural networks*. Cambridge, MA: MIT Press, 1118 pp.

Arya, S. P., 1988. *Introduction to micrometeorology*. Academic Press, INC. Vol 42 – International Geophysics Series, San Diego – Califórnia – USA - 307 pp.

Azevedo, P.V. de, Teixeira, A. H. de C.; Silva, B. B. da, 1997. Avaliação da reflectância e do saldo de radiação sobre um cultivo de videira europeia. *Revista Brasileira de Agrometeorologia*, Santa Maria, **5** (1), 1 - 7.

Bennie, J., Huntley B., Wiltshire, A., Hill, M. O., & Baxter, R., 2008. Slope, aspect and climate: Spatially explicit and implicit models of topographic microclimate in chalk grassland. *Ecological Modelling*, **216** (1), 47 - 59.

Bishop, Ch. M., 1996. *Neural networks for pattern recognition*. Oxford, Clarendon Press, 482 pp.

Bishop, C.M, 2007. *Pattern recognition and machine learning*. Springer, Cambridge – UK, 730 pp.

Bisht, G. R. Bras, 2010. Estimation of net radiation from MODIS data under all sky conditions: Southern great plains case study. *Remote Sensing of Environment*, **114**, 1522 - 1534.

Braud, I., Noilhan, J., Bessemoulin, P. and Mascart, P., 1993. Bare-ground surface heat and water exchanges under dry conditions: Observations and parameterization. *Boundary-Layer Meteorology*, **66**, 173 - 200.

Carrasco, M., Ortega-Farías, S., 2008. Evaluation of a model to simulate net radiation over a vineyard CV. Cabernet Sauvignon. *Chilean Journal of Agricultural Research*, **68**, 156 - 165.

Casanellas, P, J.; Reguerín, L.- A., de Laburu, M., y de Laburu Roquero, C., 2003. *Edafología para la agricultura y el medio ambiente*. 3ª Edición. Ed. Mundi- Prensa, Madrid. 929 pp.

Cellier, P. Richard, G., Robin, P., 1996. Partition of sensible heat fluxes into bare soil and the atmosphere. *Agricultural and Forest Meteorology*, **82**, 245 - 265.

Cybenko, G. V., 1989. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, **2** (4), 303 - 314.

Daughtry, C. S. T., Kustas, W. P., Moran, M. S., Pinter, P. J., Jr and Jackson, R. D., Brown, P. W., Nichols, W. D., Gay, L. W., 1990. Spectral estimates of net radiation and soil heat flux. *Remote Sensing Environmental*, **32**, 111 - 124.

Davies, J. A., 1967. A note on the relationship between net radiation and solar radiation. *Quarterly Journal of the Royal Meteorological Society*, **93**, 109 - 115.

de Jong, R., Shaykewich, C. F., Reimer, A., 1980. The calculation of the net radiation flux. *Archiv Für Meteorologie Geophysik Und Bioklimatologie, Serie B*, **28**, 353 - 363.

De Vries, D. A., 1963. Thermal properties of soil: In van Wijk, W. R. (Ed.), *Physics of the Plant Environment*. North-Holland, Amsterdam, 210 - 235.

Dewitte, S., L. Gonzalez, N. Clerbaux, A. Ipe, C. Bertrand, B. D. Paepe, 2008. The geostationary earth radiation budget edition 1 data processing algorithms. *Advances in Space Research*, **41**, 1906 - 1913.

Domenech, C., Lopez-Baeza, E, Donovan, D. P., Wehr, T., 2011. Radiative flux estimation from a broadband radiometer using synthetic angular models in the earthcare mission framework. Part I: Methodology. *Journal of Applied Meteorology and Climatology*, **50**, 974 - 993.

Ferreira, A. G., Sória\_Olivas, E., Serrano-López, A. J., López-Baeza, E, 2010. Characterization and modelization of surface net radiation through neural networks. In: *Soft computing methods for practical environment solutions: Techniques and studies*, IGI Global, Hershey, NY - USA, 260 – 277 pp.

Ferreira, A. G., Soria-Olivas, E., Gómez-Sanchis, J., Serrano-López, A. J., Velázquez-Blazquez, A., López-Baeza, E., 2011a. Modelling net radiation at surface using “in situ” netpyrradiometer measurements with artificial neural networks. *Expert Systems with Applications*, **38**, 14190 – 14195.

Ferreira, A. G., Soria-Olivas, E., López, A. J. S., Lopez-Baeza, E., 2011b. Estimating net radiation at surface using artificial neural networks: a new approach. *Theoretical and Applied Climatology*, **106**, 263 - 279.

Fritschen, L. J., 1967. Net and solar radiation relations over irrigated field crops. *Agricultural Meteorology*, **4**, 55 - 62.

Gomez, J., Martin, J. D., Soria, E., Vila, J., Carrasco, J. L., del Valle, S, 2006. Neural networks for analysing the relevance of input variables in the prediction of tropospheric ozone concentration. *Atmospheric Environment*, **40**, 6173 - 6180.

Gonzalez L., A. Hermans, S. Dewitte, A. Ipe, G. Sadowski, N. Clerbaux, 2002. Resolution enhancement of GERB data. *RMIB Technical Note: MSG-RMIB-GE-TN-0003*.

Harries, J. E., Russell, J. E., Hanafin, J. A., *et al.*, 2005. The geostationary earth radiation budget project. *Bulletin of American Meteorological Society*, **86**, 945 - 959.

Haykin, S., 1999. *Neural networks: A comprehensive foundation*. Upper Saddle River-NJ: Prentice Hall International, 842 pp.

Haykin, S., 2008. *Neural networks and learning machines*. Prentice Hall, Englewood Cliffs, 936 pp.

Idso, S.B., Aase, J.K., Jackson, R.D., 1975b. Net radiation-soil heat flux relations as influenced by soil water content variations. *Boundary-Layer Meteorology*, **9**, 113 - 122.

Ipe, G. L., A., 2006. *RMIB GERB products user guide, MSG-RMIB-GE-UG- Version 2.1*.

Irmak, S., Asce, M., Irmak, A., Jones, J. W., Howell, T. A., Jacobs, J. M., Allen, R. G., Hoogenboom, G., 2003. Predicting daily net radiation using minimum climatological data. *Journal of irrigation and drainage engineering*, **129** (4), 256 - 269.

Iziomon, M. G., Mayer H., Matzarakis A., 2000. Empirical models for estimating net radiative flux: a case study for three mid-latitude sites with orographic variability. *Astrophysics and Space Science*, **273**, 313 - 330.

Jegade, O. O., 1997. Estimating net radiation from air temperature for diffusion modelling applications in a tropical area. *Boundary-layer Meteorology*, **85**, 161 - 173.

Jegade, O.O., Ogolo, E. O., Aregbesola, T. O., 2006. Estimating net radiation using routine meteorological data at a tropical location in Nigeria. *International Journal of Sustainable Energy*, **2** (25), 107 - 115.

Ji, X.B., Kang, E.S., Zhao, W.Z., Zhang, Z.H., & Jin, B.W., 2009. Simulation of heat and water transfer in a surface irrigated, cropped sandy soil. *Agricultural Water Management*, **96** (6), 1010 - 1020.

Kaminsky, K. Z., Dubayah, R., 1997. Estimation of surface net radiation in the boreal forest and northern prairie from shortwave flux measurements. *Journal of Geophysical Research*, **102** (D24), 29707 - 29716.

Kjaersgaard, J.H., Cuenca, R. H., Plauborg, F. L., 2007. Long-term comparisons of net radiation calculation schemes. *Boundary-Layer Meteorology*, **123**, 417 - 431.

Kohonen, T, 2001. *Self organizing maps*, Springer.

Kohsiek, W., Liebenthal, C., Foken, T., Vogt, R., Oncley, S. P., Bernhofer, Ch., Debruin, H. A. R., 2007. The energy balance experiment EBEX-2000. Part III: Behavior and quality of the radiation measurements. *Boundary-Layer Meteorology*, **123**, 55 - 75.

Krzyscin, J. W., 2003. Nonlinear (MARS) modeling of long-term variations of surface UV-B radiation as revealed from the analysis of Belsk, Poland data from the period 1976-2000. *Annales Geophysicae*, **21**, 1887 - 1896.

Kustas, W. P., Daughtry, C. S. T., 1990. Estimation of the soil heat flux/net radiation ratio from spectral data. *Agricultural and Forest Meteorology*, **49**, 205 - 223.

Kustas, W. P., Daughtry, C. S.T., Oevelen, P. J. Van, 1993. Analytical treatment of the relationship between soil heat flux/net radiation ratio and vegetation indices. *Remote Sensing Environmental*, **46**, 319 - 330.

Kustas, W. P., Prueger, J. H., Hatfield, J. L., Ramalingam, K, Hipps, E, 2000. Variability in soil heat flux from a mesquite dune site. *Agricultural and Forest Meteorology*, **103** (3), 249 - 264 (16).

Lemon, E., 1963. Energy and water balance of plant communities. In. L. T. Evans (ed.). *Environmental Control of plant growth*. Academic Press, 55 - 78 pp.

Li S., Tong L., Li F., Zhang L., Zhang B., & Kang S., 2009. Variability in energy partitioning and resistance parameters for a vineyard in northwest China. *Agricultural Water Management*, **96** (6), 955 - 962.

Liebenthal, C., Huwe, B., Foken, T., 2005. Sensitivity analysis for two ground heat flux calculation approaches. *Agricultural and Forest Meteorology*, **132**, 253 - 262.

Lopez-Baeza, E., 1993. Climatología de la superficie de la tierra. In *La teledetección en el seguimiento de los fenómenos naturales. Climatología y Desertificación*. Coordinadores de la edición: Gandía, S. y Meliá, J., Universitat de València, Departament de Termodinàmica, Guada Litografia, S.L., Valencia – Spain, 55 - 82.

López-Baeza, E., Velazquez, A., Antolin, C., Bodas-Salcedo, A., Gimeno, J. F., Saleh, K., Ferrer, F., Domenech, C., Castell, N., Sanchez, M. A., 2003: The VALENCIA Anchor Station, a Cal/Val Reference Area for Large-scale Low Spatial Resolution Remote Sensing Missions. *3rd International Conference on Experiences with Automatic Weather Stations*. Torremolinos (Málaga), 19 - 21 February.

Lu, L., Liu, S., Sun, M., Wang, J., Zhou, H., 2005. A study of soil heat flux. *Geoscience and Remote Sensing Symposium. IGARSS '05. Proceedings. 2005 IEEE International*, **7**, 5150 - 5152.

Luenberger, D. G., Ye, Y., 2008. *Linear and nonlinear programming. International Series in Operations Research & Management Science*, Springer, 3rd edition, 546 pp.

Luhmann, H-J., 2002. MSG's GERB instrument. *ESA Bulletin* **111**, 18 - 20.

Mayocchi, C. L., Bristow, K. L., 1995. Soil surface heat flux: some general questions and comments on measurements. *Agricultural and Forest Meteorology*, **75**, 43 - 50.

Meetschen, F. A. D., van den Hurk, B. J. J. M., Drusch, M., 2004. Optimized surface radiation fields derived from Meteosat imagery and a regional atmospheric model. *Journal of Hydrometeorology*, **5** (6), 1091 - 1101.

Mitra, S., Acharya, T., 2003. *Data mining, multimedia, soft computing and bioinformatics*. John Wiley & Sons, New Jersey - USA, 401 pp.

Monteith, J. L., 1973. *Principles of environmental physics*. Edward Arnold Publisher, London, 241 pp.

Murray, T., Verhoef, A., 2007. Moving towards a more mechanistic approach in the determination of soil heat flux from remote measurements I. A universal approach to calculate thermal inertia. *Agricultural and Forest Meteorology*, **147**, 80 - 87.

Murray, T., Verhoef, A., 2007. Moving towards a more mechanistic approach in the determination of soil heat flux from remote measurements II, Diurnal shape of soil heat flux. *Agricultural and Forest Meteorology*, **147**, 88 - 97.

N. Clerbaux, 2002. "Resolution enhancement of GERB data," MSGRMIB-GE-TN-0003 issue 1.0, RMIB GERB Internal Document - Royal Meteorological Institute of Belgium, Brussels; <http://gerb.oma.be/gerb/>.

Oke, T. R., 1987. *Boundary layer climates*. Second Edition, University Press, Cambridge, 435 pp.

Oliver, H. R., Sene, K. J., 1992. Energy and water balances of developing vines. *Agricultural and Forest Meteorology*, **61**, 167 - 185.

Ortega-Farias, S., Antonioletti, R., Oliosio, A., 2000. Net radiation model evaluation at an hourly time step for mediterranean conditions. *Agronomie*, **20**, 157 - 164.

Pérez-Cueva A. J., 1994. *Atlas climático de la Comunidad Valenciana*. Generalitat Valenciana, Conselleria d'Obres Públiques, Urbanisme i Transports, Serie: Publicacions de Divulgació Tècnica, Colecció: Territori n' 4, 205 pp.

Pinker, R.T., Corio,,L. A., 1984. Surface radiation budget from Satellite. *Monthly Weather Review*, **112**, 209 -2 15.

Pinker, R. T. J. A. Ewing, J. D. Tarpley, 1985. The relationship between the planetary and surface net radiation. *Journal of Climate and Applied Meteorology*, **24**, 1262 - 1268.

Pinker, R. T., J. D. Tarpley, 1988. The relationship between the planetary and surface net radiation: An update. *Journal of Applied Meteorology*, **27**, 957 - 964.

Price, J. C., 1982. On the use of satellite data to infer surface fluxes at meteorological scales. *Journal of Applied Meteorology*, **21** (8), 1111 – 1122.

Reed, R. D., Marks, R.J., 1999. *Neural smithing, supervised learning in feedforward artificial neural networks*, MIT Press, 346 pp.

Refenes, A. N., Zapranis, A., Francis, G., 1994. Stock performance modeling using neural networks: comparative study with regression models. *Neural Networks*, 375 - 388.

Ripley, B.D., 1995. *Pattern recognition and neural networks*. Cambridge University Press, New York - USA, 416 pp.

Santanello, J. A., Friedl, M. A, 2003. Diurnal covariation in soil heat flux and net radiation. *Journal of Applied Meteorology*, **42**, 851 - 862.

Schmetz, J., Pili, P., Tjemkes, S., Just, D., Kerkmann, J., Rota, S., and Ratier, A., 2002. An introduction to meteosat second generation (MSG). *Bulletin of American Meteorological Society*, **83**, 977 - 992.

Sellers, P. J., Rasool, S. I. & Bolle, H.-J.,1990. A review of satellite data algorithms for studies of the land surface. *Bulletin of the American Meteorological Society*,**71**, 1429 - 1447.

Sene, K. J., 1994. Parametrizations for energy transfers from a sparse vine crop. *Agricultural and Forest Meteorology*, **71**, 1 - 18.

Sentelhas, P.C., Gillespie, T.J., 2008. Estimating hourly net radiation for leaf wetness duration using the Penman-Monteith equation. *Theoretical and Applied Climatology*, **91**, 205 - 215.

Smith, G. L., Lee, R. B., Szewczyk, Z. P, Rutan, D. A., 2004. Comparison of measurements from satellite-borne radiation budget instruments for 1985-2004. *GIST (GERB International Science Team) Meeting 22*, RMIB, Bruxelles, 2 - 4 November.

Trenberth, K. E., Fasullo, J. T., Kiehl, J., 2008. Earth's global energy budget. *Bulletin of the American Meteorological Society*, DOI: 10.1175/2008BAMS2634.1.1.

Trezza, R., 2006. Evapotranspiration from a remote sensing model for water management in a irrigation system in Venezuela. *Interciencia*, **31** (6), 417 - 423.

Verhoef, A., 2004. Remote estimation of thermal inertia and soil heat flux for bare soil. *Agricultural and Forest Meteorology*, **123**, 221 - 236.

Viollier, M., C. Standfuss, O. Chomette, A. Quesney, 2009. Top-of-Atmosphere radiance to flux conversion in the sw domain for the SCARAB-3 instrument on Megha-Tropiques. *Journal of Atmospheric and Oceanic Technology*, **26**, 2161 - 2171.

Wallace, J. M., Hobbs, P. V., 2006. *Atmospheric science an introductory survey*. Second Edition, Elsevier Inc, London-UK, 488 pp.

Wan, J., 2006. *Encyclopedia of data warehousing and data mining*. Idea group Reference, 1280 pp.

Wang, J., Bras, R. L., 1999. Ground heat flux estimated from surface soil temperature. *Journal of Hydrology*, **216**, 214 - 226.

Wang, K., and S. Liang, 2009. Estimation of surface net radiation from solar radiation measurements. *Journal of applied Meteorology and Climatology*, **48**, 634 - 643.

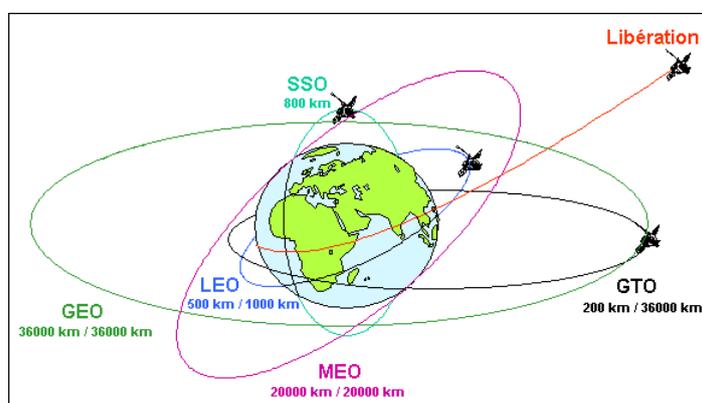
Weigend, A., N. Gershenfeld, 1993. *Time series prediction: forecasting the future and understanding the past. Proceedings of the NATO Advanced research workshop on comparative time series analysis, held in Santa Fe, New Mexico, May 14-17, 1992*, Addison-Wesley Publishing Co, 643 pp.

Ye, N., 2003. *The handbook of data mining*. Lawrence Erlbaum Associates, New Jersey - USA, 720 pp.

## DESCRIPCIÓN DE LOS SENSORES SEVIRI Y GERB

### I.1 SATÉLITES METEOSAT

Los satélites de la serie *METEOSAT* son de órbita geosíncrona o geoestacionaria (situados sobre el plano ecuatorial), y están posicionados a una altura de, aproximadamente 36.000 km. La Figura I.1 muestra los diferentes tipos de órbitas de los satélites de Observación de la Tierra. En la órbita geoestacionaria, los satélites se mueven de forma conjunta con la rotación de la Tierra, o sea, sus movimientos son síncronos con el movimiento de rotación de nuestro planeta. La localización operacional principal de los satélites *METEOSAT* está sobre el Ecuador terrestre, en la longitud 0°. Estos satélites barren de forma casi continua el hemisferio del planeta observado por el satélite.



**Figura I.1** - Ejemplos de algunas trayectorias típicas de los satélites ambientales y de Observación de la Tierra – LEO: Low Earth Orbit - MEO: Medium Earth Orbit - GEO: Geostationary Orbit - GTO: Geostationary Transfer Orbit - SSO: Sun Synchronous Orbit (Copyright - CNES - Direction of the launchers Christophe Bonnal). **Fuente:** <http://www.cnes.fr>. Fecha de acceso: 03/11/2009, 01:08 h (Valencia-España, hora local).

El primer *METEOSAT*, *METEOSAT-1*, fue lanzado en 1977, y el último de la primera generación, *METEOSAT-7*, fue lanzado 20 años más tarde, en 1997 (ver Tabla I.1). Los satélites de esta generación proporcionaban imágenes cada 30 minutos. El sensor principal se llamaba *MVIRI* (*METEOSAT Visible and InfraRed Imager*) y generaba

imágenes en tres canales espectrales del espectro electromagnético (regiones visible, infrarrojo, y del vapor de agua atmosférico).

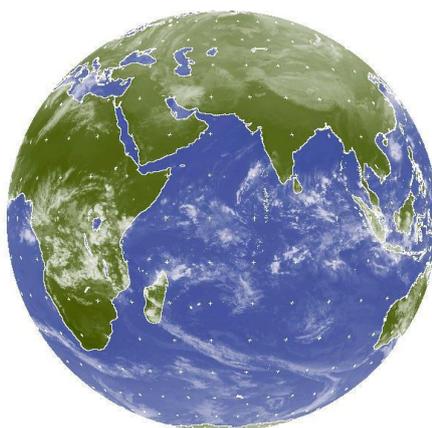


**Figura I.2** - METEOSAT First Generation Satellite. **Fuente:** <http://www.eumetsat.int>. Fecha de acceso: 03/11/2009, 01:30 h (Valencia - España, hora local).

**Tabla I.1** Historia operacional de los satélites METEOSAT (primera y segunda generación).

SATÉLITE	CRONOLOGIA/OBSERVACIONES	BASE DE LANZAMIENTO/COHETE
METEOSAT-1	23/11/1977 - 1985	Cape Canaveral/Delta 2000; Masa: 697 kg
METEOSAT-2	19/06/1981 - 1991	Kourou/Ariane 1; Masa: 697 kg
METEOSAT-3	15/06/1988 - 1995	Kourou/Ariane 44LP; Masa: 696 kg
METEOSAT-4	06/03/1989 - 1995 - EUMETSAT lo desplazó a una órbita cementerio, o sea, 200 a 300 kilómetros sobre altitud geoestacionaria.	Kourou/Ariane 44LP; Masa: 681 kg
METEOSAT-5	02/03/1991 - 2007 - Permanece en 63° E y genera las imágenes cada hora de esta parte de la Tierra, observando principalmente el Océano Índico (ver Figura I.3).	Kourou/Ariane 44LP; Masa: 681 kg
METEOSAT-6	20/11/1993 - 2006 - En septiembre de 2001, METEOSAT-6 fue dedicado a las exploraciones rápidas (cada 10 minutos) y continuas del área comprendida entre las latitudes 15° N - 65° N.	Kourou/Ariane 44LP; Masa: 704 kg
METEOSAT-7	02/09/1997 - 2012 - Es el último de esta serie. Es el primer satélite operacional, situado en 0° de longitud. En noviembre de 2006 Meteosat-7 fue desplazado sobre el Océano Índico (latitud 57,5° E)	Kourou/Ariane 44LP; Masa: 692 kg
MSG-1	28/02/2002	Kourou/Ariane 5; Masa: 2010 kg
MSG-2	21/12/2005	Kourou/Ariane 5; Masa: 2034 kg
MSG-3	05/07/2012	Kourou/Ariane 5; Masa: 2050 kg
MSG-4	Lanzamiento planeado para 2014	

**Fuente:** <http://www.eumetsat.int> . Fecha de acceso: 03/07/2012.

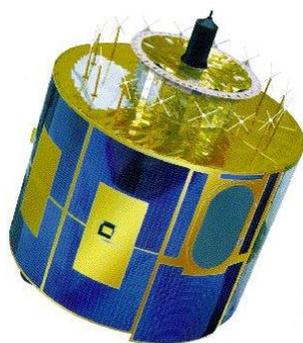


**Figura I.3** - Imagen *METEOSAT 5* del día 13/12/2006, sobre el Océano Índico. **Fuente:** [http://oiswww.eumetsat.org/SDDI/html/product\\_usage.html](http://oiswww.eumetsat.org/SDDI/html/product_usage.html). Fecha de acceso: 03/11/2009, 02:00 h (Valencia-España, hora local) - *Copyright 2006 EUMETSAT*.

## I.2 MSG - LA SEGUNDA GENERACIÓN DE LOS SATÉLITES METEOSAT

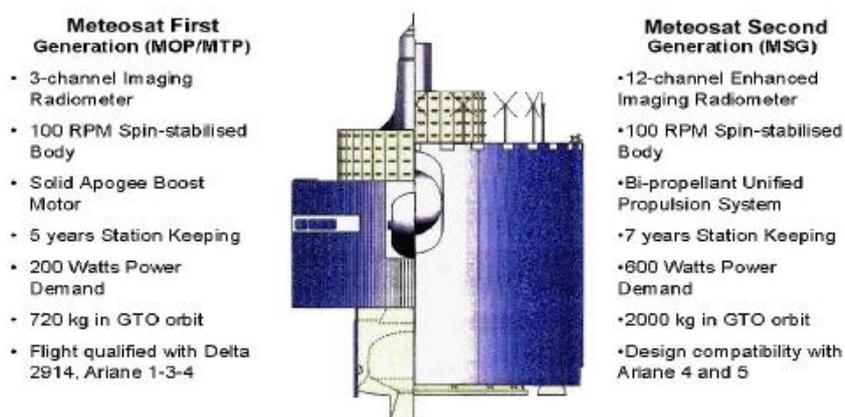
El proyecto de los *MSG (METEOSAT Second Generation)* fue aprobado por la *ESA (European Space Agency)* en 1994 para garantizar la continuidad operacional, y la calidad de las imágenes proporcionadas por los satélites de la serie *METEOSAT*, para que se consolidaran como una herramienta indispensable para los servicios meteorológicos Europeos, de África y de América del Sur. El primero de la nueva serie, el denominado *MSG-1*, fue lanzado al espacio el 28 de agosto de 2002. *MSG-2*, el segundo de una serie prevista de 4 satélites, fue lanzado al espacio el día 21 de diciembre de 2005.

Los satélites de la serie *MSG*, representan un enorme avance en la adquisición de datos de la superficie terrestre y de la atmósfera, ya que hace un barrido cada 15 minutos (frente a los 30 minutos para la serie anterior de *METEOSAT*). El sensor *SEVIRI (Spinning Enhanced Visible and Infrared Imager)* de *MSG* tiene 12 canales espectrales (3 canales para la serie anterior de *METEOSAT*), cuantización de 10 *bits* por *píxel* (8 *bits* para la serie anterior de *METEOSAT*), y una resolución espacial de 3 kilómetros en el *nadir* para todos los canales espectrales excepto para el de alta resolución del visible cuya resolución es de 1 kilómetro (5 y 2,5 km, respectivamente para la serie *METEOSAT*). De la misma forma que los satélites de la primera serie *METEOSAT*, los *MSG* también se estabilizan por giro a 100 rpm (*spin-stabilised at 100 rpm*), que ofrece un método sencillo y eficaz para el control del satélite (Schmetz *et al.*, 2002).

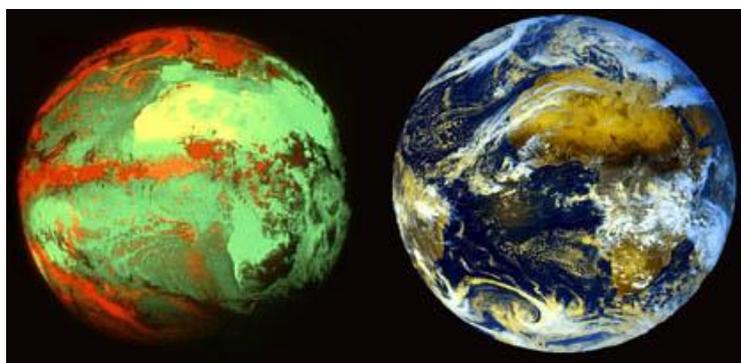


**Figura I.4** - Satélite *MSG*, que de la misma forma que los de la primera serie de *METEOSAT*, son estabilizados por giro (*spin stabilized*). **Fuente:** [http://directory.eoportal.org/images/METEOSAT8\\_Auto2.jpeg](http://directory.eoportal.org/images/METEOSAT8_Auto2.jpeg). Fecha de acceso: 04/11/2009, 14:44 h (Valencia – España, hora local).

En la figura I. 5 se presenta una comparación entre los satélites *METEOSAT* de primera y segunda generación. En la figura I.6 se muestra una imagen de la Tierra observada con *METEOSAT* y *MSG*.

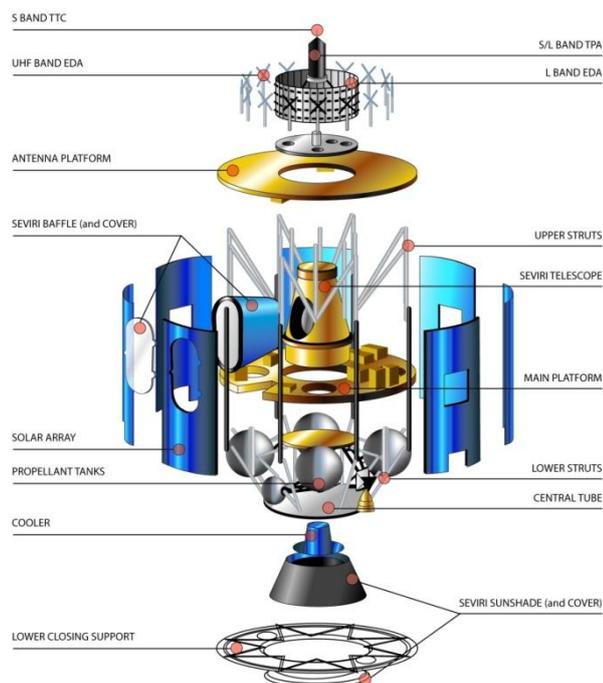


**Figura I.5** - Comparación de los satélites *METEOSAT* de primera y segunda generación. **Fuente:** [www.eumetsat.int](http://www.eumetsat.int). "METEOSAT Second Generation – MSG system Overview-EUM TD07 – Issue 1.1 - 25 May 2001. Fichero pdf, página 29 - Fecha de acceso: 05/11/2009, 11:30 h (Valencia-España, hora local).



**Figura I.6** - Imagen de la Tierra vista por el satélite *METEOSAT-1* (a la izquierda), lanzado al espacio en 1977, y a la derecha, una imagen de la Tierra vista desde *MSG-1*, lanzado al espacio en 2002. **Fuente:** [http://www.cnes.fr/html/\\_455\\_461\\_1446\\_1448\\_.php](http://www.cnes.fr/html/_455_461_1446_1448_.php). Fecha de acceso: 06/11/2009, 01:08 h (Valencia-España, hora local).

En la figura I.7 se presenta una vista detallada del satélite *MSG*. El satélite es básicamente cilíndrico con un tamaño total de 3,7 m de diámetro y 2,4 m de alto. La nave espacial *MSG* se compone de tres secciones principales. La sección superior contiene la carga útil de las comunicaciones de la misión e incluye las antenas y los transpondedores requeridos para transmitir datos y controlar el satélite. Además proporcionan: enlace de bajada (*down linking*) de los datos brutos de los radiómetros *SEVIRI* y *GERB* (Instrumento diseñado para medir el balance radiactivo de la Tierra desde órbita geostacionaria, también a bordo del *MSG-1* y *2*), transmisión de los datos de las *DCP* (*Data Collection Platforms*) a las *PGS* (*Primary Ground Station*), difusión de las informaciones *LRIT* (*Low Rate Information Transmission*) y *HRIT* (*High Rate Information Transmission*), así como el transmisor de la señal de socorro. El compartimiento central contiene el radiómetro sensor de imagen *SEVIRI* y sus componentes electrónicos asociados. La sección inferior contiene los sistemas de propulsión del satélite y los componentes para el control de la órbita y de la posición.



**Figura I.7** - Vista detallada del satélite *MSG*. **Fuente:** [www.eumetsat.int](http://www.eumetsat.int). "METEOSAT Second Generation – MSG system Overview-EUM TD07 – Issue 1.1 – 25 May 2001". Fichero pdf, página 14 - Fecha de acceso: 07/11/2009, 11:30 h (Valencia-España, hora local).

### I.3 EL SENSOR SEVIRI

De acuerdo con el informe “EUM TD 07 - Issue 1.1, 25 May 2001 Page 15”, de EUMETSAT, el radiómetro SEVIRI es la carga útil principal de los satélites MSG. Este sensor proporciona los datos básicos del sistema METEOSAT de la segunda generación. SEVIRI tiene 12 canales espectrales que cubren las partes visibles e infrarrojas del espectro electromagnético (Figura I.8 y Tabla I.2). Hay un canal de alta resolución, en la región visible del espectro electromagnético, que se puede utilizar para apoyar los servicios meteorológicos operacionales en la tarea de hacer predicción inmediata y a muy corto plazo (*nowcasting*). Hay también siete canales multi-espectrales que proporcionan, entre otras, información sobre la temperatura de la superficie de las nubes, de la tierra y del mar.



**Figura I.8** - Detalles del sensor SEVIRI (*Spinning Enhanced Visible and Infrared Imager*)

**Fuente:** [http://www.esa.int/images/SEVIRI\\_06\\_L.jpg](http://www.esa.int/images/SEVIRI_06_L.jpg). Fecha de acceso: 07/11/2009, 15:35 h (Valencia-España, hora local).

**Tabla I.2** - Características espectrales de *SEVIRI* en términos de longitud de onda central, mínima y máxima de los canales y sus principales aplicaciones.

Canal No.	Banda espectral( $\mu\text{m}$ )	Características de las bandas espectrales ( $\mu\text{m}$ )			Principales aplicaciones
		$\lambda_{\text{central}}$	$\lambda_{\text{mínima}}$	$\lambda_{\text{máxima}}$	
1	VIS0,6	0,635	0,56	0,71	Detección y seguimiento de nubes; imágenes diurnas de la superficie terrestre; seguimiento de aerosoles y vegetación
2	VIS0,8	0,81	0,74	0,88	Las mismas del canal 1
3	NIR1,6	1,64	1,50	1,78	Permite distinguir las nubes de la nieve; las nubes de agua de las de hielo y proporciona información sobre aerosoles
4	IR3,9	3,90	3,48	4,36	Detección nocturna de niebla; nubes bajas; estimación de la temperatura (continente/océano) y de los campos del viento a partir del seguimiento de las nubes
5	WV6,2	6,25	5,35	7,15	Estimación de la distribución de vapor de agua en la atmósfera; observación de vientos y determinación de la altura de las nubes semitransparentes
6	WV7,3	7,35	6,85	7,85	Las mismas del canal 5
7	IR8,7	8,70	8,30	9,1	Observación continua de las nubes y discriminación entre nubes de agua y hielo
8	IR9,7	9,66	9,38	9,94	Este canal se corresponde con la banda de absorción del ozono y puede utilizarse para hacer un seguimiento de la capa de ozono
9	IR10,8	10,80	9,80	11,80	Estimación de la temperatura del mar, de la tierra y del techo de las nubes; detección de nubes cirrus y nubes de cenizas volcánicas
10	IR12,0	12,00	11,00	13,00	Las mismas del canal 9
11	IR13,4	13,40	12,40	14,40	Detección de CO <sub>2</sub> y determinación de la altura de nubes cirros
12	HRV	Banda ancha (alrededor 0,4 - 1,1 $\mu\text{m}$ )			Seguimiento de aspectos de pequeña escala en la superficie y de las nubes

*Observación:*  $\lambda$  = longitud de onda; **VIS** = visible; **NIR** = infrarrojo cercano; **IR** = infrarrojo; **WV** = vapor de agua; **HRV** = canal de alta resolución centrado en visible. **Fuente:** Adaptado de Schmetz, J *et al.*, 2002.

#### I.4 EL SENSOR GERB

Como carga útil científica adicional, MSG lleva a bordo un instrumento llamado GERB (*Geostationary Earth Radiation Budget*), que es un radiómetro de barrido (*scanning radiometer*) que fue diseñado para medir radiancias y flujos de onda larga y onda corta en el techo de la atmósfera terrestre cada 15 minutos, siendo su resolución nominal en el nadir de 44,6 km (norte-sur) x 39,3 km (este-oeste). GERB (Figura I.9) posee dos canales espectrales de banda ancha, uno que cubre el espectro solar (0,32 a 4,0  $\mu\text{m}$ ) y otro que cubre una amplia porción del espectro electromagnético (0,32 a 30  $\mu\text{m}$ ).

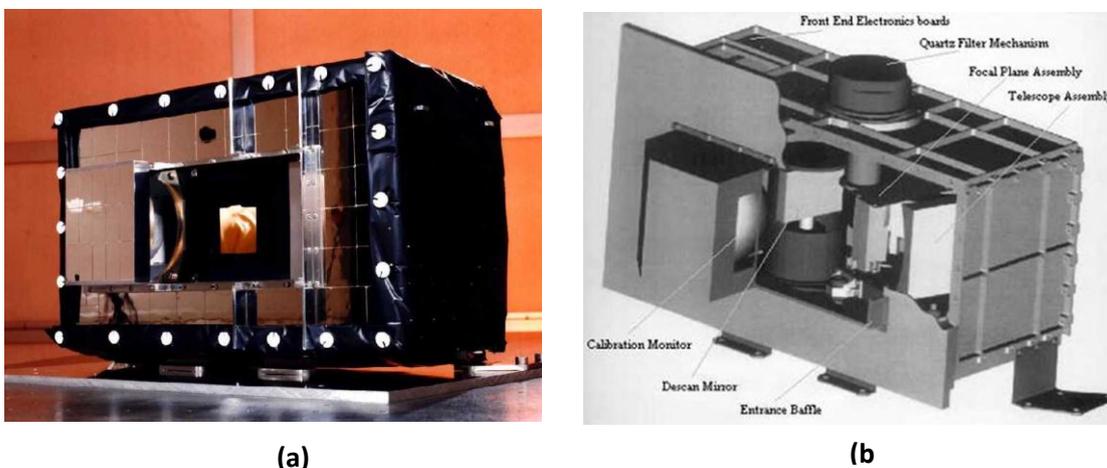


Figura I.9 (a) Sensor GERB (unidad óptica) y (b) diagrama esquemático

Fuente: a) [http://www.ssd.rl.ac.uk/gerb/FM\\_I0U2.JPG](http://www.ssd.rl.ac.uk/gerb/FM_I0U2.JPG) y (b) <http://www.esa.int>. Fecha de acceso: 07/11/2009, 16:35 h (Valencia-España, hora local).

Estos canales se utilizan, en conjunto, para determinar la radiación térmica reflejada por la Tierra en la banda espectral de onda corta (0,32 a 4,0  $\mu\text{m}$ ) y la radiación térmica emitida por la Tierra en el rango espectral de onda larga (4,0 a 30  $\mu\text{m}$ ) que se obtiene por diferencia entre la radiación observada en la banda total (0,32 a 30  $\mu\text{m}$ ) y la de onda corta (Luhmann, 2002; Harries, *et al.*, 2005).

Los datos obtenidos por GERB se calibran a bordo del satélite obteniéndose las radiancias de onda corta y de onda larga con una precisión <1% (Harries *et al.*, 2005). La Tabla I.3 muestra más detalles de las especificaciones de diseño de GERB, y la información y descripción sobre los contenidos de los archivos de datos GERB se puede encontrar en <http://gerb.oma.be/gerb>.

Tabla I.3 - Especificaciones del diseño del GERB.

Wave bands	TOTAL	0,32 $\mu\text{m}$ $\rightarrow$ 100,0 $\mu\text{m}$	
	SW	0,32 $\mu\text{m}$ $\rightarrow$ 4,0 $\mu\text{m}$	
	LW (by subtraction)	4,0 $\mu\text{m}$ $\rightarrow$ 100,0 $\mu\text{m}$	
Radiometry		SW	LW
	Absolute accuracy	< 1,0%	< 1,0%
	Signal/noise	1250	400
	Dynamic range	0 - 380 $\text{W m}^{-2} \text{sr}^{-1}$	0 - 90 $\text{W m}^{-2} \text{sr}^{-1}$
Spatial sampling	44,6 Km (north - south) x 39,3 Km (east - west) at nadir		
Temporal sampling	15 – min SW and LW fluxes		
Cycle time	Full Earth disc. Both channels in 6 min		
Coregistration	Spatial: 3 - Km w.r.t. <i>SEVIRI</i> at satellites subpoint Temporal: within 15 min of <i>SEVIRI</i> at each pixel		
Instrument mass	25 Kg		
Power	35 W		
Dimension	0,45 m x 0,2 m x 0,2 m		

Fuente: Adaptado de Harries, J.E. *et al.*, 2005 - pg. 947.

## I.5 IMAGENES *GERB*

A continuación, a título de ejemplo, se muestran imágenes de radiancias y flujos de onda corta y de onda larga procesadas a partir de los datos *GERB* correspondientes al día 20 de junio de 2007 a las 12:00 UTC.

### I.5.1 Radiancia solar reflejada

En la Figura I.10, se observa una imagen *GERB* de la radiancia solar reflejada que es la cantidad de radiación solar entrante que es reflejada por el sistema Tierra-Atmósfera en la dirección del radiómetro *GERB*. Como se puede observar en dicha figura, los valores más altos para la radiancia solar reflejada se observan sobre la cubierta de nubes más densas, situadas cerca del punto sub-solar, donde la

iluminación es máxima, como por ejemplo, donde se localiza la Zona de Convergencia Intertropical (ZCIT), en el mes de junio, cerca de la latitud 7° N. La unidad física para esta magnitud es el watio por metro cuadrado y por estereorradián ( $W m^{-2} sr^{-1}$ ). En los ficheros de datos *GERB*, la radiación solar reflejada está cuantificada con un factor de cuantificación de  $0,05 W m^{-2} sr^{-1}$  ([http://gerb.oma.be/gerb/Description/sol\\_rad.html](http://gerb.oma.be/gerb/Description/sol_rad.html)).

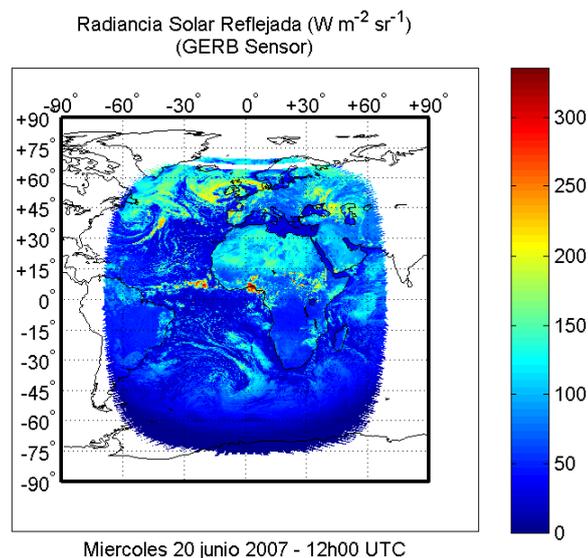


Figura I.10 - Imagen *GERB* (20/06/2007 – 12h00 UTC) de la Radiancia Solar Reflejada.

### 1.5.2 Flujo solar reflejado

La Figura I.11 ilustra el flujo solar reflejado. Este campo proporciona la cantidad de radiación solar entrante que es reflejada por el sistema Tierra-Atmósfera. Los valores más altos para el flujo solar reflejado también son los observados sobre la cubierta de nubes más densas situadas cerca del punto sub-solar, donde la iluminación es máxima. La unidad física para esta magnitud es el watio por metro cuadrado ( $W m^{-2}$ ). En el fichero de datos *GERB*, el flujo solar está cuantificado con un factor de cuantificación de  $0,25 W m^{-2}$  ([http://gerb.oma.be/gerb/Description/sol\\_flux.html](http://gerb.oma.be/gerb/Description/sol_flux.html)).

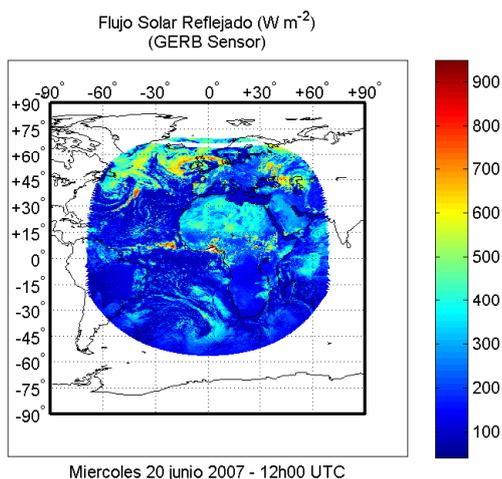


Figura I.11 - Imagen GERB (20/06/2007 – 12h00 UTC) del Flujo Solar Reflejado.

### I.5.3 Radiancia térmica emitida

Esta magnitud física, ilustrada en la Figura I.12, proporciona la cantidad de energía térmica emitida por el sistema Tierra-Atmósfera en la dirección del radiómetro GERB. Los valores más altos para la radiancia térmica se observan sobre áreas cálidas del desierto bajo condiciones de cielo despejado. Las nubes, generalmente, causan una disminución de la emisión térmica de la tierra al espacio (efecto invernadero de las nubes). En el área donde se localiza la ZCIT, alrededor de la latitud 7° N, se observan valores menores de radiancia térmica emitida, en comparación con otras áreas de la imagen. La unidad física para esta cantidad es el watio por metro cuadrado por estereorradián ( $W m^{-2} sr^{-1}$ ), y está cuantificada con un factor de cuantificación de 0,05  $W m^{-2}sr^{-1}$  ([http://gerb.oma.be/gerb/Description/th\\_rad.html](http://gerb.oma.be/gerb/Description/th_rad.html)).

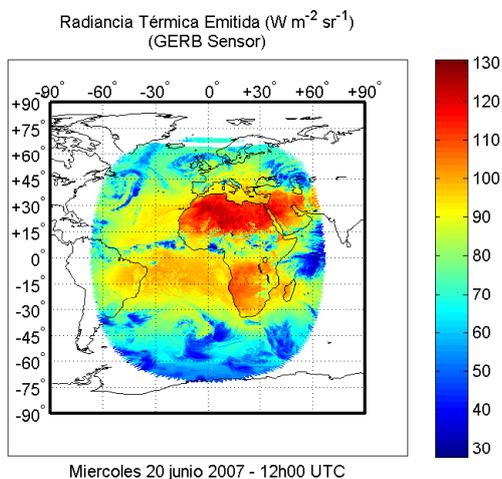


Figura I.12 - Imagen GERB (20/06/2007 – 12h00 UTC) de la Radiancia Térmica Emitida.

#### I.5.4 Flujo térmico emitido

Este campo, ilustrado a través de la Figura I.13, proporciona la cantidad de energía térmica emitida por el sistema Tierra-Atmósfera. Los valores más altos para el flujo térmico, así como para los de la radiancia térmica emitida, se observan también sobre áreas cálidas del desierto bajo condiciones de cielo despejado. Las nubes generalmente causan una disminución de la emisión térmica de la Tierra hacia el espacio (efecto invernadero de las nubes). En la imagen de la Figura I.13 se observa claramente la posición de la ZCIT, alrededor de la latitud 7° N, donde se observan valores bajos del flujo térmico emitido. La unidad física para esta magnitud es el watio por metro cuadrado ( $W m^{-2}$ ). En el fichero de datos GERB, el flujo térmico está cuantificado con un factor de cuantificación de  $0.25 W m^{-2}$ . ([http://gerb.oma.be/gerb/Description/th\\_flux.html](http://gerb.oma.be/gerb/Description/th_flux.html)).

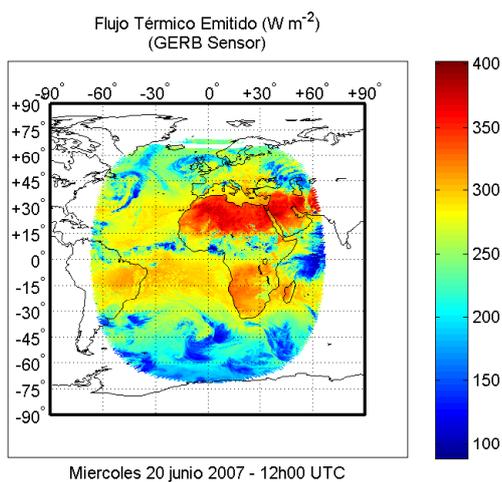


Figura I.13 - Imagen GERB (20/06/2007 – 12h00 UTC) del Flujo Térmico Emitido.

**Artículo**

**“Characterization and Modelization of Surface Net Radiation Through  
Neural Networks”**

*El presente artículo está publicado en el libro “Soft Computing Methods for Practical Environment Solutions Techniques and Studies – editor IGI Global), capítulo 16.*

## Chapter 16

# Characterization and Modelization of Surface Net Radiation through Neural Networks

Antonio Geraldo Ferreira

*University of Valencia, Spain & Fundação Cearense de Meteorologia e Recursos Hídricos  
(FUNCEME), Brazil*

Emilio Soria

*University of Valencia, Spain*

Antonio J. Serrano López

*University of Valencia, Spain*

Ernesto Lopez-Baeza

*University of Valencia, Spain*

### ABSTRACT

*Artificial neural networks have shown to be a powerful tool for system modeling in a wide range of applications. In this chapter, the focus is on neural network applications to obtain qualitative/quantitative relationships between meteorological and soil parameters and net radiation, the latter being a significant term of the surface energy balance equation. By using a Multilayer Perceptron model an artificial neural network based on the above mentioned parameters, net radiation was estimated over a vineyard crop. A comparison has been made between the estimates provided by the Multilayer Perceptron and a linear regression model that only uses solar incoming shortwave radiation as input parameter. Self-Organizing Maps, another type of neural model, made it possible to get knowledge in an easy way on how the input variables are related to each other in the data set. The results achieved show the potential of artificial neural networks as a tool for net radiation estimation using more commonly measured meteorological parameters.*

DOI: 10.4018/978-1-61520-893-7.ch016

Copyright © 2010, IGI Global. Copying or distributing in print or electronic forms without written permission of IGI Global is prohibited.

## INTRODUCTION

Artificial Neural Networks (ANN) applications on atmospheric science have experienced considerable growth in the last years if we consider the increasing number of publications in the topic. The most significant applications refer to solar radiation (Elizondo, Hoogenboom, & McClendon, 1994; Reddy & Ranjan, 2003), evapotranspiration (Landeras, Ortiz-Barredo, & López, 2008), ozone concentrations in urban areas (Yi & Prybutok, 1996; Prybutok, Yi, & Mitchell, 2000) or thunderstorms prediction (MacCann, 1992; Manzato, 2007), processing of Earth observation satellite data (Krasnopolsky & Schiller, 2003; Diego & Loyola, 2006), etc. But to the authors' knowledge, surface net radiation ( $Q^*$ ) estimation has not been attempted yet using ANNs. In effect, surface net radiation estimation is a complex problem because according to Venäläinen *et al.* (1998), there are complicated feedback mechanisms between the surface energy balance quantities and the surface characteristics. The usual approach to this problem has been through conventional statistical modeling techniques. In spite of finding successful applications by using regressions models to estimate  $Q^*$  (Glover, 1972; Iziomon *et al.*, 2000; Sentelhas & Gillespie, 2008), the input parameters used sometimes are difficult to obtain or measure. Thus, the objective of this chapter is to develop a *Multilayer Perceptron* ANN model, based on *in situ* measured micrometeorological and soil parameters, to estimate  $Q^*$  and compare and evaluate this model against the performance of a more commonly used  $Q^*$  linear regression model (LM) that only uses incoming solar radiation as input parameter. A *Self-Organizing Map* (SOM) was applied to extract knowledge of the possible relationships between the measured micrometeorological and soil parameters. The SOM, which is another neural model, preserves the topological relationships among the data while mapping this data into a two-dimensional map.

## BACKGROUND

The energy exchanges between the land surface and the atmosphere can be described by the surface energy balance equation given by the algebraic sum of fluxes over the surface

$$Q^* + Q_H + Q_{LE} + Q_G = 0 \quad (1)$$

where  $Q^*$  is net radiation at surface,  $Q_H$  is the sensible heat flux,  $Q_{LE}$  is the latent heat flux, a product of the evaporative rate  $E$  and the latent heat per unit quantity of water evaporated,  $\lambda$ , and  $Q_G$  is the soil heat flux, the rate at which heat is transferred from the surface downward into the soil profile, all in units of  $W m^{-2}$ . In Eq. (1), the fluxes are considered as positive if directed toward the surface and negative in the opposite case (Hillel, 2004) (See Figure 1).

In Eq. (1),  $Q^*$  is also the algebraic sum of net components of shortwave ( $K^*$ ) and longwave ( $L^*$ ) radiation, which can be written as

$$Q^* = K^* + L^* \quad (2)$$

where the symbol \* represents net flux. The  $K^*$  and  $L^*$  in Eq. (2) can be written as

$$K^* = K_{\downarrow} - K_{\uparrow} \quad (3)$$

and

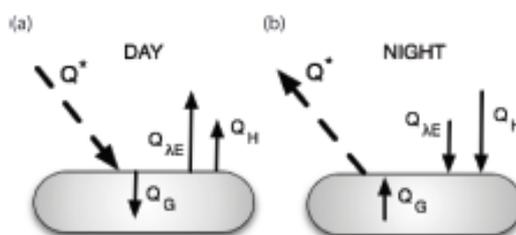
$$L^* = L_{\downarrow} - L_{\uparrow} \quad (4)$$

finally resulting

$$Q^* = K_{\downarrow} - K_{\uparrow} + L_{\downarrow} - L_{\uparrow} \quad (5)$$

where the downward arrows ( $\downarrow$ ) and upward arrows ( $\uparrow$ ) indicate incoming and outgoing radiation components respectively, and the energy moving toward the surface is also considered positive and the energy moving away from the surface is considered negative.

Figure 1. Typical variation of terms of the surface energy balance for: (a) daytime over land and (b) night-time over land. The arrow size indicates the relative magnitude



The outgoing shortwave radiation  $K\uparrow$  is the fraction of the shortwave incoming radiation  $K\downarrow$  that is reflected by the surface under consideration, i.e.,

$$K\uparrow = \alpha K\downarrow \quad (6)$$

where  $\alpha$  is the surface albedo. Thus equation (5) can be rewritten as

$$Q^* = K\downarrow (1 - \alpha) + (L\downarrow - L\uparrow) \quad (7)$$

Eq. (7) clearly shows that  $Q^*$  constitutes the fundamental parameter which governs the climate of the lower atmosphere and is a measure of the total amount of energy available at the ground (Iziomon *et al.*, 2000; Oke, 1987). It is therefore the driving force in many physical and biological processes such as evapotranspiration, air and soil heating, as well as other small energy-consuming processes such as photosynthesis. When available, the  $Q^*$  measurements are used in agricultural, biological and engineering sciences for estimation of evapotranspiration, which in turn is used to optimize crop yield and quality, crop modeling, water resource planning, climate predictions, etc (Bennie *et al.*, 2008; Ji *et al.*, 2009; Li *et al.*, 2009; Trezza, 2006).

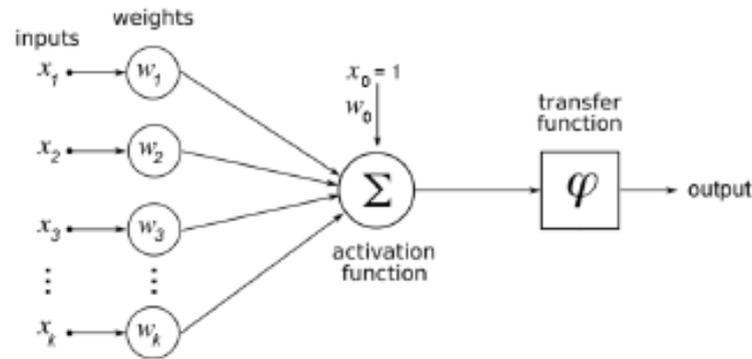
Although the surface meteorological stations (conventional/automatic) around the world normally record air temperature, wind velocity and direction, pressure, relative humidity, and

incoming solar radiation, however,  $Q^*$  is rarely measured, and therefore, not generally available. According to this, many studies have put major efforts into the accurate determination of  $Q^*$  from conventional meteorological data, and various models have been proposed and evaluated for that purpose (Federer, 1968; de Jong *et al.*, 1980; Irmak *et al.*, 2003; Kjaersgaard *et al.*, 2007). One of the most commonly used equations to estimate  $Q^*$  is

$$Q^* = a_1 K\downarrow + b_1 \quad (8)$$

where  $a_1$  and  $b_1$  are regression coefficients and  $K\downarrow$  is the incoming solar radiation, that is more commonly measured than  $Q^*$ . The investigations have shown that the regression coefficients in those models are, among other things, dependent on the type and conditions of the surface (Kessler, 1985; Kjaersgaard *et al.*, 2007). Concerning the ANN, the literature shows many studies that were developed/evaluated in order to estimate  $K\downarrow$  (Áženkal & Kuleli, 2009; Elizondo *et al.*, 1994; Mohandes *et al.*, 1998a; Reddy & Ranjan, 2003; Jiang, Y., 2008). Rehman & Mohandes (2008), for example, by applying feedforward ANNs, estimated global solar radiation, for Abba city in Saudi Arabia. An ANN was trained with 3 inputs (day of the year, daily mean relative humidity and daily mean temperature), 24 hidden neurons in one layer and one output ( $K\downarrow$ ). The mean squared data error found by the mentioned authors, on testing data, was about  $3 \times 10^{-5}$  and the absolute mean

Figure 2. Scheme of a typical neuron;  $x_i$  are the inputs and  $w_j$  are the neuron weights



percentage error was about 4.5%. Concerning  $Q^*$  estimation using ANN models, references have not been found by the authors in the literature.

As a consequence of what has been mentioned above and taking into account that several meteorological factors, together with land cover and land use, do affect the quantity of  $Q^*$  that is registered at any particular place, an automatic micrometeorological station was installed inside a vineyard field (latitude 39° 31' 23" N and longitude 1° 17' 22" W), at the Valencia Anchor Station area located on the natural region of the Utiel-Requena Plateau, Spain, in order to understand the behavior of  $Q^*$  during the vine growing season. The field campaign denominated FESEBAV-2007 (*Field Experiment on Surface Energy Balance Aspects over the Valencia Anchor Station area*) was carried out between June 18 - September 19, 2007.

Based on the collected data, a new model utilizing ANNs, which consists in a layered arrangement of individual computation units known as artificial neurons (Bishop, 2007; Haykin, 2008), was proposed.

### The Multilayer Perceptron

A *Multilayer Perceptron* (MLP) is an ANN that is composed of elementary processing units, the so-

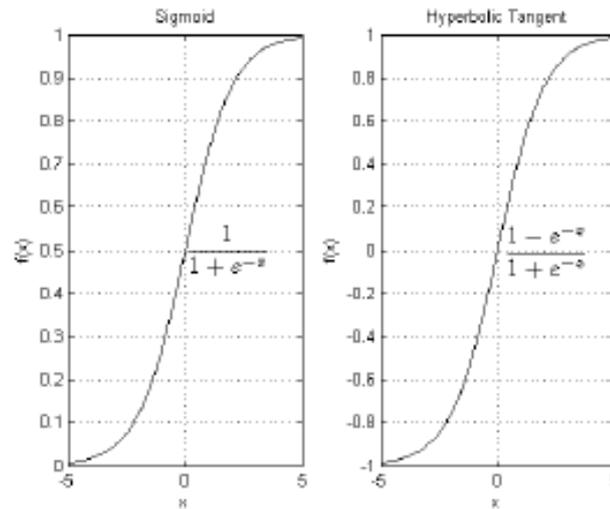
called neurons. A typical neuron model is shown in Figure 2 (Haykin, 1999).

The main components of the model are:

- *Sum function.* It carries out a linear combination of the neuron inputs through the use of a set of coefficients, known as synaptic weights. Being  $w=[w_0, w_1, \dots, w_k]$  the vector of coefficients, and  $x=[1, x_1, \dots, x_k]$  the input vector, the sum function is given by the scalar product of both vectors. When using a neural model, the goal is to find the optimal synaptic weights to solve the problem, the process of searching the optimal weights is known as network learning.
- *Activation function.* It is a non-linear function which gives the network its non-linear nature. The most used activation functions are the sigmoid function (its values ranging between 0 and 1) and the hyperbolic tangent, which ranges between -1 and +1 (Figure 3).

Neurons are arranged in layers to form an MLP. The first layer is known as input layer, and the last one is called output layer. All the other layers are called hidden layers (Haykin, 1999). This kind of arrangement enables the neuron outputs to be used as inputs to neurons of following layers

Figure 3. Sigmoid function and hyperbolic tangent

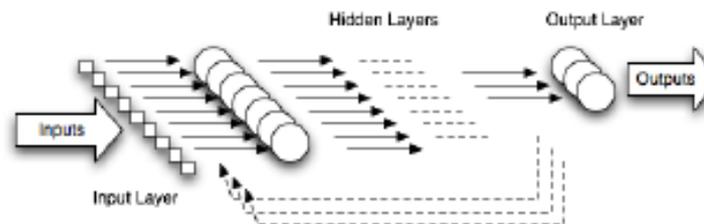


(non-recurrent network) and/or previous layers (recurrent networks). Figure 4 shows a typical MLP structure.

Several remarks should be made regarding the learning process (Haykin, 1999; Bishop 1996):

1. The learning rate must be chosen appropriately. The learning algorithm is based on finding the closest minimum, being this learning rate a parameter which measures the speed of approaching the minimum.
2. The network architecture must also be chosen appropriately. While the number of neurons
3. in the input layer and the output layer is given by the problem, the number of hidden layers, and the quantity of neurons in each hidden layer must be chosen depending on the particular problem.
4. Due to the iterative nature of the learning process, it is necessary to choose the initial values of the synaptic weights. Different initial values are usually tested in order to achieve an optimal model and avoid a local minimum.

Figure 4. Scheme of a Multilayer Perceptron (MLP)



Characterization and Modelization of Surface Net Radiation through Neural Networks

relationship between two data sets, the usual procedure is based on dividing the whole data set into two groups, known as the training set and the validation set, respectively. The first set is used to determine the synaptic weights, and the second one is used to test the behaviour of the neural model with data that the network has not yet seen.

5. Two different approaches can be carried out to train the network. The first one is based on updating the synaptic weights for each pattern of the data set (*on-line* approach) whereas the other approach is based on updating the synaptic weights once for all the training data set (*batch* approach).

The data utilized to build the ANN model proceed from the *FESEBAV-2007* experiment. Wind velocity ( $m s^{-1}$ ), wind direction (degrees), air and surface temperature ( $^{\circ}C$ ), soil temperature at 5 cm depth ( $^{\circ}C$ ), relative humidity (%), soil moisture at 5 cm depth ( $m^3 m^{-3}$ ), and net radiation ( $W m^{-2}$ ), was the data used as input during training and validation sets, standing out that  $Q^*$  is the output variable.

Self-Organizing Map

The *Self-Organizing Map* is a neural network proposed by Teuvo Kohonen in 1984 (Haykin, 1999; Kohonen, 2001). Neurons are arranged in two layers: an input layer, formed by  $n$  neurons (one neuron for each input variable) and an output layer in which information is processed; this second layer is usually arranged in a two-dimensional structure (see Figure 5).

Neurons of the output layer are characterised by a weight vector with the same dimension as the input vector. For instance, neuron  $i,j$  ( $i$ -th row,  $j$ -th column) is characterised by the weight vector  $w_{ij} = [w_{ij}^1, w_{ij}^2, \dots, w_{ij}^n]$ . Similar input patterns are mapped close to each other in the output layer (Kohonen, 2001). The algorithm procedure can be summarized, as follows (Haykin, 1999):

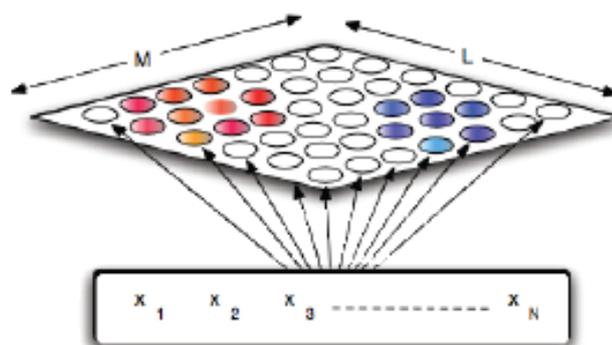
1. Weight initialisation.
2. Choice of an input pattern  $x = [x_1, x_2, \dots, x_n]$ .
3. Measurement of the similarity between weights and inputs. If the Euclidean distance is taken into account, then the similarity measure is given by  $d(w_{ij}, x) = \sum_{k=1}^n (w_{ij}^k - x_k)^2$ .  
The most similar neuron to the input pattern is called *Best Matching Unit* (BMU).
4. Synaptic weights are updated as  $w_{ij} = w_{ij} + \alpha \cdot h(BMU, w_{ij}) \cdot (x - w_{ij})$ , where here  $\alpha$  represents the learning rate and  $h$  is known as neighbourhood function. The value of this function depends on the distance between the BMU and the neuron to be updated, the closer the two neurons the higher the value of this function.
5. The previous steps are performed a predetermined number of iterations. When this number is reached, the learning algorithm is stopped. While the number of iterations is lower than the predetermined value, go to step 2.

Once the map training is finished, the visualisation of the two-dimensional map provides qualitative information about how the input variables are related to each other for the data set used to train the map. SOM is a visualisation tool rather than a clustering tool, although it is possible to obtain clusters of similar patterns from the two-dimensional map.

ANALYSIS OF NET RADIATION WITH ARTIFICIAL NEURAL NETWORKS

1. Issues, Controversies, Problems

When analyzing data we are looking not only for relationships between variables by fitting an equation to the observed data set, but also for relationships to define and establish models. In

Figure 5. Kohonen SOM topology showing the input vectors  $x_i$  and the output space (SOM) in 2D space

the case of environmental modeling, a variety of approaches and combinations can be made. Choosing the most suitable approach depends on the complexity of the problem being addressed and on the degree to which the problem is understood (Gardner & Dorling, 1998). Normally, the models used to estimate  $Q^*$  require geophysical non-operational parameters such as surface albedo, surface temperature, air vapor pressure, fraction of cloud cover, emissivity of the surface and of the atmosphere, etc. as input to the model (Amarakoon & Chen, 1999; de Jong *et al.*, 1980; Iziomon *et al.*, 2000; Jegede, 1997; Ortega-Farias *et al.*, 2000; Sentelhas & Gillepie, 2008). These parameters are not routinely measured at meteorological stations so that it is too difficult to apply these models in an operational way. Another point is that some parameters used in these models are estimated and not measured, so that estimations made for them can lead to increasing errors in  $Q^*$  estimations. Gladly,  $Q^*$  can be estimated by using a linear regression model (Gentle, Härdle, & Mori, 2004) between both measured incoming solar radiation ( $K_{\downarrow}$ ) and  $Q^*$ . The problem is that during the night the earth surface does not receive solar radiation and the regression equation to predict  $Q^*$  during the night cannot be used, limiting its application only for daytime. But observations show that  $Q^*$

is not zero during the night. For this reason, efforts should be made to estimate  $Q^*$  from others geophysical parameters.

## 2. Solutions and Recommendations

In order to accurately determine  $Q^*$  in an operational way, an alternative approach has been presented by using ANNs. The proposed ANN model uses as input a limited number of meteorological parameters measured in conventional/automatic meteorological stations, being this one of its practical advantages.

The first step is starting the data analysis by plotting different SOM graphs for the *in situ* measured micrometeorological and soil parameters such as those listed in Table 1 which will allow a visualization of the possible relationships among them. This is because the SOM preserves the topology of the input vectors in a bidimensional visualization (Kaltch *et al.*, 2008; Kohonen, 2001). In the SOM's learning process; firstly the two possible types of learning (on-line and batch) have been considered and, secondly, the most common neighbourhood functions (Gaussian and Mexican hat) have been varied as well as the learning constants and the neurons coefficients initialization (50 different initializations for each possibility).

Characterization and Modelization of Surface Net Radiation through Neural Networks

Table 1. Meteorological and soil parameters measured during FESEBAV-2007

Graph: SOM Title (Figure 7)	Parameter	Unit
G12.5 and G7.5	Soil heat flux at depths of 12.5 and 7.5 cm, respectively	W m <sup>-2</sup>
Rad_inc, Rad_ref, and Rad_net	Incident, reflected and net radiation at 2 m height	W m <sup>-2</sup>
Wind_vel	Wind speed at 2.10 m height	m s <sup>-1</sup>
Wind_dir	Wind direction at 2.10 m height	degrees
T_soil25, T_soil15, T_soil10, T_soil5	Soil temperature at depths of 25, 15, 10 and 5 cm, respectively.	°C
T_sfp	Surface temperature	°C
T_air	Air temperature at 2.0 m height	°C
Rel_hum	Relative humidity at 2.0 m height	%
Soil_moisture	Soil moisture at 5 cm depth in the ground	m <sup>3</sup> m <sup>-3</sup>
Prec	Precipitation	mm

The self-organized maps were analyzed in order to determine the quantization error (adjustment of the neurons' vectors to the input data) and the topographic error (a measure of how well the neighbourhood relationship is maintained between the original and the final bidimensional space), finally choosing the map that presented a lower product of the quantization error times the topographic one.

As far as the architecture is concerned, the algorithm used was the one implemented in

Matlab's SOM library ([www.cis.hut.fi/projects/somtoolbox](http://www.cis.hut.fi/projects/somtoolbox)), which takes into account the scattering of the data and the number of variables (Kohonen, 2001). The final map had a size of 22x11 neurons.

Figure 6a shows the number of patterns assigned to each neuron, where the more filled up is the hexagon (the hexagon represents a neuron). In addition, the SOM contents can show the different behaviour presented by the data (Figure 6b).

Figure 6. (a) Patterns number assigned to the neuron (winners), and (b) number of different types of behaviour in the data set (cluster): Dark color indicates weak similarity between categories and clear color indicates strong similarity between categories

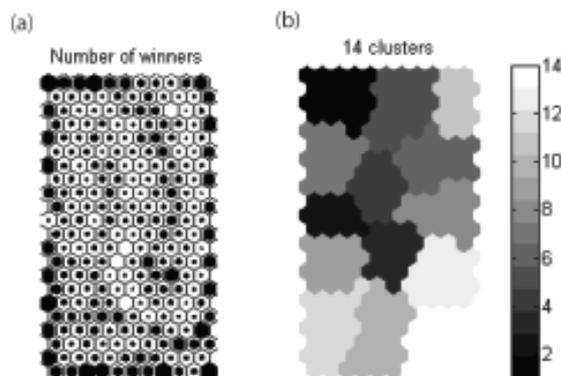
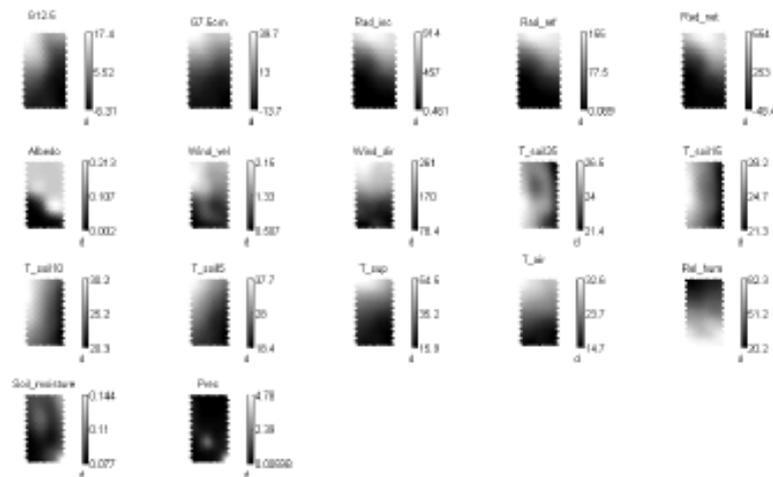


Figure 7. Self-Organizing Maps (SOM) of meteorological and soil parameters. Each SOM graph contains 22 rows and 11 columns of neurons



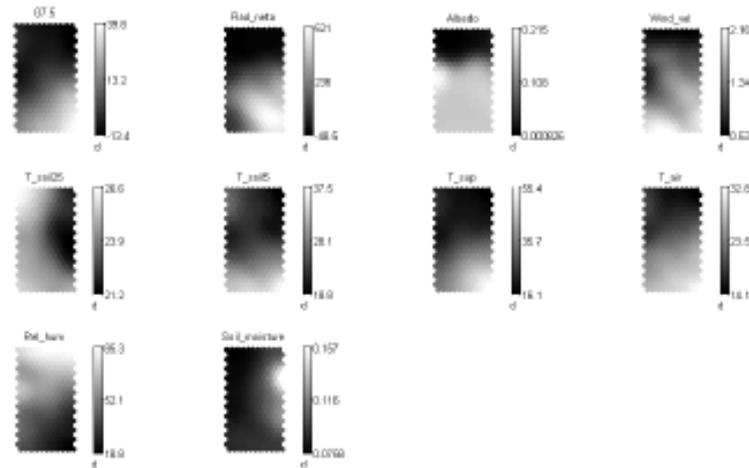
The neuron assigned will be the unit whose incoming connection weights are the closest to the input topology in terms of Euclidean distance. Figure 7 shows the SOM visualization graphs of the meteorological variables listed in Table 1, where we can directly, with just a glance to the maps, see the relationships between the variables used. In this sense, the SOM provides, literally, a visual map of our data thus allowing a fast understanding on how everything fits together.

It can be seen, for example, from Figure 7, that  $Rad\_inc$ ,  $Rad\_ref$ ,  $Rad\_net$ , show similar patterns, where the clear color indicates that the higher values of  $Rad\_inc$ , imply more reflected ( $Rad\_ref$ ) and more net radiation ( $Rad\_net$ ). More  $Q^*$  implies more energy available at the surface for physical and biological processes. The opposite is also true, i. e., lower values of  $Rad\_inc$ , imply less reflected radiation ( $Rad\_ref$ ) and less  $Q^*$  available at the surface (dark color). By paying attention to  $G_{75}$ ,  $T_{sup}$  and  $T_{air}$ , the clear color in these SOM maps suffer a displacement in the upper

left corner direction in relation to  $Rad\_inc$ . This means that the incoming shortwave radiation that reaches the surface begins, after a lag in time, to heat it up. Then, part of this energy is transferred to the soil, heating it up, from where a part is used to heat up the air near the surface. During the day, the surface receives more quantity of  $Rad\_inc$  from the sun (clear color), consequently, the surface heats up, and more quantity of heat is transferred from the surface to the soil in the  $Q_D$  form and to the air in  $Q_H$  and  $Q_{LE}$  form. During the night, the  $Rad\_inc$  is cut off (dark color), and consequently the surface does not receive energy from the sun and the surface cools up, and heat begins to be transferred from deeper layers of the soil towards the surface. Now comparing, for example,  $Rel\_hum$  and  $T_{air}$ , they present an opposite pattern, i. e., when the  $Rel\_hum$  is low/high (dark color/clear color) the  $T_{air}$  is high/low (clear color/dark color). Relative humidity (RH) is a measure of the amount of moisture in the air. Expressed as a percentage, it describes the amount

Characterization and Modelization of Surface Net Radiation through Neural Networks

Figure 8. SOM of the meteorological and soil parameters used as input layer in the ANN modeling



of water vapor in the air compared to the amount needed for the air to be saturated (i.e. 100% RH). Humidity varies with temperature—as temperature increases humidity decreases and when temperature decreases humidity increases. This indicates that the SOM pattern makes physical sense.

After analysing the SOM maps presented in Figure 7, the variables chosen to develop the ANN models are presented in Figure 8. Since the *Multilayer Perceptron* requires no prior knowledge between variables and their relationships, the criteria to choose the variables that will be used in the ANN model input layer were: (i) meteorological variables not linked directly with our target variable, i.e., ( $Q^*$ ), and (ii) variables that are usually measured routinely at meteorological stations. For these reasons,  $Rad_{inc}$ ,  $Rad_{ref}$ ,  $G1.5$ ,  $T_{soil25}$ ,  $T_{soil15}$  and  $T_{soil10}$ , were not used in the model development.

The next step was, considering that  $Q^*$  can be positive, negative, or even zero, to divide the data set in three parts: The first part considering all the  $Q^*$  measured data, the second one considering only the negative net radiation ( $Q^* < 0$ ) values, and the third one considering only the positive

net radiation ( $Q^* > 0$ ) values, hereafter referred as  $Q^*_+$ ,  $Q^*_0$  and  $Q^*_+$ , respectively. This procedure allows to find a model for  $Q^*_0$  overall values, and more specific models for  $Q^*_0$  and  $Q^*_+$ . Then, each of these data sets were divided into two subsets, the first one with 2/3 of the data for developing LMs / training ANN and the remaining 1/3 for testing the models.

In the same way that was made in the SOM's case, in order to train the *Multilayer Perceptron*, all its parameters were varied, namely the number of hidden layers (1 and 2) and the number of neurons per layer (from 2 to 10). According to Cybenko's Theorem, no more layers were necessary (Haykin, 2008) and in order to avoid overfitting problems no more neurons were considered (Alpaydin, 2004). The learning algorithm chosen was that of Levenberg-Marquardt's with a variable learning constant because of its performance characteristics with respect to speed and accuracy (Haykin, 2008). Due to the local minima problem, the networks of each structure were initialized 50 times using a normal distribution of mean zero and unity variance to avoid the neurons saturation

Table 2. Statistical results for  $Q^*$  using linear regression models (developing / testing phase) and networks (training / validation sets)

Linear Model	R <sup>2</sup>	RMSE	MAE	ME	N
$Q_+^* = 0.657 K_{\downarrow} - 4.273$	0.96 / 0.96	39.48 / 35.38	34.19 / 30.87	0.006 / 7.10	4397 / 2198
<b>Neural Models:</b>					
$Q_-^*$	0.92 / 0.92	6.23 / 6.54	4.59 / 4.76	0 / 0.089	4435 / 2218
$Q_+^*$	0.97 / 0.96	42.9 / 48.75	26.81 / 29.29	-0.33 / 0.26	4397 / 2198
$Q_{\pm}^*$	0.98 / 0.98	38.09 / 39.26	21.67 / 22.60	0.0209 / 1.41	8832 / 4416

RMSE and MAE are in units of  $W m^{-2}$ , and N is the number of data utilized

problem: if the initial weights are very high, the network does not learn because the neurons act in the flat zone of the activation function (Haykin, 2008). The best architecture for each case, using the RMSE of the generalization set as index were:

$Q_+^*$ : 1 hidden layer and 10 neurons;  $Q_-^*$ : 1 hidden layer and 10 neurons; and  $Q_{\pm}^*$ : 2 hidden layers and 9 and 10 neurons.

The accuracy of the (different)  $Q^*$  estimated values using both the LM and the ANN models was assessed through the correlation coefficient ( $R^2$ ), the Root Mean Square Error (RMSE), the Mean Absolute Error (MAE) and the Mean Error (ME). These statistical values (those corresponding to the best networks and using RMSE as the performance index) are presented in Table 2.

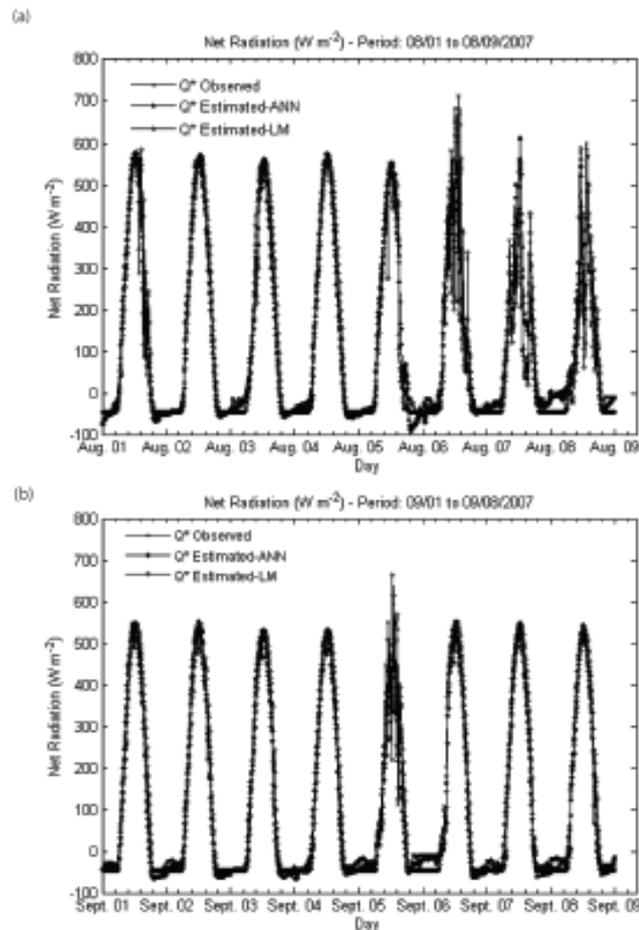
According to the results shown in Table 2, the proposed ANN provides similar results to the LMs when considering  $Q_+^*$ . But when considering  $Q_-^*$  and  $Q_{\pm}^*$ , the performance of the ANN was markedly high. The value of  $R^2 = 0.92$  and  $0.98$  were obtained respectively for both training and validation sets. Taking into account that during the night there is no solar radiation, in order to develop a  $Q_-^*$  linear model, which depends only on solar radiation, it makes no sense. But  $Q^*$  is neither zero nor constant during the night period as it is observed in the field data collected, and this

is because net radiation depends not only on  $K_{\downarrow}$  but also on other radiation fluxes and atmospheric parameters (Table 1). The good results provided by the ANNs  $Q_-^*$ ,  $Q_+^*$ , and  $Q_{\pm}^*$ , is because the ANNs learn from the data. On the one hand,  $K_{\downarrow}$  is not used as an input parameter in the ANN model because the model sought should not be influenced directly for any parameter in particular, and solar radiation has a direct influence on the amount of  $Q^*$  available at the surface. However, the ANN model accounts very well for the rest of the surface and atmospheric parameters. On the other hand, because the  $Q^*$  LM depends only on  $K_{\downarrow}$  and not on the other parameters, it can only perform correctly during the day but not during the night. Therefore, the ANN provides good results for  $Q_-^*$ . The ANN's ability to learn from a given set of collected data makes them attractive and exciting because no prior knowledge about the relationship between variables inside the data set is needed. It's one of the advantages that ANN's present over conventional regression analyses.

Figure 9 shows the time series of  $Q^*$  (measured, predicted by the LMs and ANN), for two different periods, August 01 - 08, 2007 and September 01 - 08, 2007. From these time series, four different days were chosen for analysis, where two of them are cloudy days: August 01, 2007 (Figure

Characterization and Modelization of Surface Net Radiation through Neural Networks

Figure 9. Time series of  $Q^*$  observed, estimated by using ANN and LM for the periods between: (a) August 01 – 08, 2007 and (b) September 01 – 08, 2007



10a), and September 05, 2007 (Figure 10d). The other two cloudless days: August 02, 2007 and September 04, 2007, are shown in Figures 10b and 10c respectively.

An accurate prediction is achieved in a global point of view. Nevertheless, it seems that in general, over cloudless conditions, the LMs have a tendency to slightly underestimate  $Q^*$  during morning hours, approximately between 9:00 h

and 11:00 h, and overestimate  $Q^*$  in the afternoon hours, approximately between 13:00 h and 18:00 h. Over overcast conditions, it seems that the LMs present better performance. Perhaps this is because only  $K_t$ , a meteorological parameter linked directly to  $Q^*$ , is used as input parameters in LMs. As mentioned earlier, the ANN uses other meteorological parameters as input layer.

## FUTURE RESEARCH DIRECTIONS

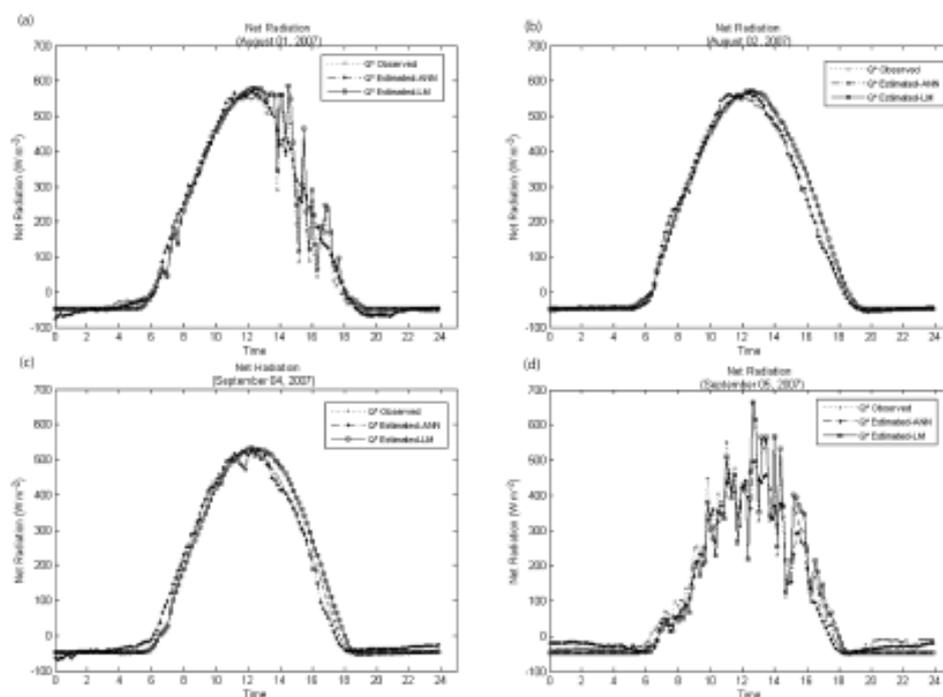
One possible extension of this work is to apply the ANN models to other sites around the study area, i. e., the Valencia Anchor Station area, considering different soil types, land cover, and meteorological parameters collected by the existing meteorological stations in the area. After building ANN models for each considered site, the next step would be to look for a general ANN model. It would be obtained by averaging the ANN models generated for each site.

Along this chapter, the application of two neural models has been discussed. These models can be considered as classical neural models by the number of practical developments made from

them, but there are other models that could be applied to compare their performance with the procedures described here, so we would have:

*Alternative models to the MLP.* Here feedback or Multi-Layers models as Elman and Jordan network, Finite Impulse Response (FIR) or Infinite Impulse Response (IIR) networks (depending on the type of digital filter applied as synapses), as well as, models that utilize other types of temporal memory in the ANN, for example, Laguerre models (Haykin, 2008). If multilayer ANN models are not used, other elements of the learning machine that can work as universal modellers are the Support Vector Machines (SVM) and the regression trees (Alpaydin, 2004).

Figure 10.  $Q^*$  observed and estimated by using ANN and LM for: cloudy days (a) and (d); and for cloudless days (b) and (c)



## Characterization and Modelization of Surface Net Radiation through Neural Networks

*Alternative models to the SOM.* In this case, the solution could be given by the model known as Generative Topographic Mapping (GTM). In this case, the approach is of Bayesian type which complicates the algorithm utilized to obtain the parameters if compared to a *Self-Organizing Map* (Bishop, 2007).

The estimation of geophysical parameters such as net and solar radiation, surface temperature, wind (velocity and direction) over land and ocean, phytoplankton concentration in the ocean, aerosol concentration in the atmosphere, soil moisture etc, is required with high quality and adequate spatial and temporal scales, depending on the applications under consideration, but this is not generally available. Presently, only satellites can retrieve many of these parameters with good quality and accuracy. But, the quality of geophysical parameters derived from satellite measurements varies significantly depending, not only on the strength and uniqueness of the signal from the mentioned geophysical parameters but also on the mathematical methods applied to extract these parameters, i. e., to solve forward inverse remote sensing problems. In this way, the ANN technique is a very promising mathematical tool to accurately solve forward and inverse problems in remote sensing (Krasnopolsky, 2003).

## CONCLUSION

In this chapter, LMs and ANNs applications to estimate  $Q^*$ , a significant term of the energy balance equation, over vineyard crops has been presented. Micrometeorological/soil data, averaged over a ten-minutes period, from the *FESEBAV-2007* experiment (June 18–September 19, 2007), was used to develop and train the models.

With respect to the SOM, the maps allow to visualize the relationships between meteorological/soil parameters in an easy way, as well as to interpret physically the relationships between them. The SOM was also utilized in order to select

the parameters used as input layer in the *Multilayer Perceptron* models. The SOM associated with *Multilayer Perceptron* allows increasing the knowledge of physical processes, as well as the interaction of the driving mechanisms concerning the surface energy balance. Taking into account that  $K_{\downarrow}$  was not used as input layer in the ANN model training, and by looking at the statistical results presented in Table 2, the ANN demonstrated to be a helpful tool to estimate  $Q^*$  at the surface from operational meteorological parameters, mainly for sites where radiation fluxes related parameters are not currently measured, showing that the modeling process using ANN is effective to estimate  $Q^*$ , when only a limited number of meteorological variables is available.

## REFERENCES

- Alpaydin, E. (2004). *Introduction to Machine Learning (Adaptive Computation and Machine Learning)*. Cambridge, MA: MIT Press.
- Amarakoon, D., & Chen, A. (1999). Estimating daytime net radiation using routine meteorological data in Jamaica. *Caribbean Journal of Science*, 35(1-2), 132–141.
- Áženkal, O., & Kuleli, T. (2009). Estimation of solar radiation over Turkey using artificial neural network and satellite data. *Applied Energy*, 86(7-8), 1222–1228. doi:10.1016/j.apenergy.2008.06.003
- Bennie, J., Huntley, B., Wiltshire, A., Hill, M. O., & Baxter, R. (2008). Slope, aspect and climate: Spatially explicit and implicit models of topographic microclimate in chalk grassland. *Ecological Modelling*, 216(1), 47–59. doi:10.1016/j.ecolmodel.2008.04.010
- Bishop, C. (2007). *Pattern Recognition and Machine Learning (Information Science and Statistics)*. New York: Springer-Verlag.

- Bishop, C. M. (1996). *Neural Networks for Pattern Recognition*. New York: Oxford University Press.
- de Jong, R., Shaykewich, C. F., & Reimer, A. (1980). The calculation of the net radiation flux. *Archiv Für Meteorologie Geophysik Und Bioklimatologie. Serie B*, 28, 353–363.
- Diego, G., & Loyola, R. (2006). Applications of neural network methods to the processing of earth observation satellite data. *Neural Networks*, 19(2), 168–177. doi:10.1016/j.neunet.2006.01.010
- Elizondo, D., Hoogenboom, G., & McClendon, R. W. (1994). Development of neural network model to predict daily solar radiation. *Agricultural and Forest Meteorology*, 7, 115–132. doi:10.1016/0168-1923(94)90103-1
- Federer, C. A. (1968). Spatial variation of net radiation, albedo and surface temperature of forests. *Journal of Applied Meteorology*, 7, 789–795. doi:10.1175/1520-0450(1968)007<0789:SVONRA>2.0.CO;2
- Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14), 2627–2636. doi:10.1016/S1352-2310(97)00447-0
- Gentle, J. E., Härdle, W., & Mori, Y. (2004). *Handbook of Computational Statistics. Concepts and Methods*. Berlin: Springer-Verlag.
- Glover, J. (1972). Net radiation over tall and short grass. *Agricultural Meteorology*, 10, 455–459. doi:10.1016/0002-1571(72)90046-5
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Englewood Cliffs, NJ: Prentice Hall International.
- Haykin, S. (2008). *Neural Networks and Learning Machines* (3rd Ed.). Englewood Cliffs, NJ: Prentice Hall International.
- Hillel, D. (2004). *Introduction to Environmental Soil Physics*. San Diego, CA: Elsevier Academic Press.
- Irmak, S., Asce, M., Irmak, A., Jones, J. W., Howell, T. A., & Jacobs, J. M. (2003). Predicting daily net radiation using minimum climatological data. *Journal of Irrigation and Drainage Engineering*, 129(4), 256–269. doi:10.1061/(ASCE)0733-9437(2003)129:4(256)
- Iziomon, M. G., Mayer, H., & Matzarakis, A. (2000). Empirical models for estimating net radiative flux: a case study for three mid-latitude sites with orographic variability. *Astrophysics and Space Science*, 273, 313–330. doi:10.1023/A:1002787922933
- Jegade, O. O. (1997). Estimating net radiation from air temperature for diffusion modelling applications in a tropical area. *Boundary-Layer Meteorology*, 85, 161–173. doi:10.1023/A:1000462626302
- Ji, X. B., Kang, E. S., Zhao, W. Z., Zhang, Z. H., & Jin, B. W. (2009). Simulation of heat and water transfer in a surface irrigated, cropped sandy soil. *Agricultural Water Management*, 96(6), 1010–1020. doi:10.1016/j.agwat.2009.02.008
- Jiang, Y. (2008). Prediction of monthly mean daily diffuse solar radiation using artificial neural networks and comparison with other empirical models. *Energy Policy*, 36, 3833–3837. doi:10.1016/j.enpol.2008.06.030
- Kalteh, A. M., Hjorth, P., & Berndtsson, R. (2008). Review of the self-organizing map (SOM) approach in water resources: analysis, modelling and application. *Environmental Modelling & Software*, 23, 835–845.
- Kessler, A. (1985). *World Survey Climatology, General Climatology, 1A, Heat Balance Climatology*. Amsterdam: Elsevier Science Publishers.

## Characterization and Modelization of Surface Net Radiation through Neural Networks

- Kjaersgaard, J. H., Cuenca, R. H., & Plauborg, F. L. (2007). Long-term comparisons of net radiation calculation schemes. *Boundary-Layer Meteorology*, *123*, 417–431. doi:10.1007/s10546-006-9151-8
- Kohonen, T. (2001). *Self-Organizing Maps*. New York: Springer.
- Krasnopolsky, V. M., & Schiller, H. (2003). Some neural applications in environmental sciences. Part I: forward and inverse problems in geophysical remote measurements. *Neural Networks*, *16*, 321–334. doi:10.1016/S0893-6080(03)00027-3
- Landeras, G., Ortiz-Barredo, A., & López, J. J. (2008). Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). *Agricultural Water Management*, *95*(5), 553–565. doi:10.1016/j.agwat.2007.12.011
- Li, S., Tong, L., Li, F., Zhang, L., Zhang, B., & Kang, S. (2009). Variability in energy partitioning and resistance parameters for a vineyard in northwest China. *Agricultural Water Management*, *96*(6), 955–962. doi:10.1016/j.agwat.2009.01.006
- MacCann, D. W. (1992). A neural network short-term forecast of significant thunderstorm. *Forecasting Techniques*, *7*, 525–534. doi:10.1175/1520-0434(1992)007<0525:ANNS TF>2.0.CO;2
- Manzato, A. (2007). Sounding-derived indices for neural network based short-term thunderstorm and rainfall forecasts. *Atmospheric Research*, *83*(2–4), 349–365. doi:10.1016/j.atmosres.2005.10.021
- Mohandes, M. A., Rehman, S., & Halawani, T. O. (1998a). Estimation of global solar radiation using artificial neural networks. *Renewable Energy*, *14*, 179–184. doi:10.1016/S0960-1481(98)00065-2
- Oke, T. R. (1987). *Boundary Layer Climates*. Cambridge, UK: University Press.
- Ortega-Farias, S., Antonioletti, R., & Olioso, A. (2000). Netradiation model evaluation at an hourly time step for Mediterranean conditions. *Agronomie*, *20*, 157–164. doi:10.1051/agro:2000116
- Prybutok, V. R., Yi, J., & Mitchell, D. (2000). Comparison of neural network models with ARIMA and regression models for prediction of Houston's daily maximum ozone concentrations. *European Journal of Operational Research*, *122*(1), 31–40. doi:10.1016/S0377-2217(99)00069-7
- Reddy, K. S., & Ranjan, M. (2003). Solar resource estimation using artificial neural networks and comparison with other correlation models. *Energy Conversion and Management*, *199*, 272–294.
- Rehman, S., & Mohandes, M. (2008). Artificial neural network estimation of global solar radiation using air temperature and relative humidity. *Energy Policy*, *36*, 571–576. doi:10.1016/j.enpol.2007.09.033
- Sentelhas, P. C., & Gillespie, T. J. (2008). Estimating hourly net radiation for leaf wetness duration using the Penman-Monteith equation. *Theoretical and Applied Climatology*, *91*, 205–215. doi:10.1007/s00704-006-0290-0
- Trezza, R. (2006). Evapotranspiration from a remote sensing model for water management in a irrigation system in Venezuela. *Interiencia*, *31*(6), 417–423.
- Venäläinen, A., Solantie, R., & Laine, V. (1998). Mean long-term surface energy balance components in Finland during the summertime. *Boreal Environment Research*, *3*, 171–180.
- Yi, J., & Prybutok, R. (1996). A neural network model forecasting for prediction of daily maximum ozone concentration in an industrial urban area. *Environmental Pollution*, *92*(3), 349–357. doi:10.1016/0269-7491(95)00078-X

## ADDITIONAL READING

- Abdel-Aal, R. E., Elhadidy, M. A., & Shaahid, S. M. (2009). Modeling and forecasting the mean hourly wind speed time series using GMDH-based abductive networks. *Renewable Energy*, 34, 1686–1699. doi:10.1016/j.renene.2009.01.001
- Céréghino, R., & Park, Y.-S. (2009). Review of the Self-Organizing Map (SOM) approach in water resources: Cometary. *Environmental Modelling & Software*, 24, 945–947. doi:10.1016/j.envsoft.2009.01.008
- Chérut, F., Chevallier, F., Scott, N. A., & Chédin, A. (1996). A Fast method using neural networks for computing the vertical distribution of the thermal component of the Earth radiative budget. *Comptes Rendus de l'Académie des Sciences de Paris* 322(S. IIb), 665–672.
- Diaz-Robles, L. A., Ortega, J. C., Fu, J. S., Reed, G. D., Chow, J. C., Watson, J. G., & Moncada-Herrera, J. A. (2008). A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco. *Atmospheric Environment*, 42(35), 8331–8340. doi:10.1016/j.atmosenv.2008.07.020
- Diaz-Robles, L. A., Ortega, J. C., Fu, J. S., Reed, G. D., Chow, J. C., Watson, J. G., & Moncada-Herrera, J. A. (2008). A new scheme to predict chaotic time series of air pollutant concentrations using artificial neural network and nearest neighbor searching. *Atmospheric Environment*, 42(18), 4409–4417. doi:10.1016/j.atmosenv.2008.01.005
- Eslamloueyan, R., & Khademi, M. H. (2009). Estimation of thermal conductivity of pure gases by using artificial neural networks. *International Journal of Thermal Sciences*, 48(6), 1094–1101. doi:10.1016/j.ijthermalsci.2008.08.013
- Fadare, D. A. (2009). Modelling of solar energy potential in Nigeria using an artificial neural network model. *Applied Energy*, 86, 1410–1422. doi:10.1016/j.apenergy.2008.12.005
- Gurney, K. (1997). *An Introduction to Neural Networks*. New York: CRC Press.
- Hsieh, W. W., & Tang, B. (1998). Applying neural network models to prediction and data analysis in meteorology and oceanography. *Bulletin of the American Meteorological Society*, 79, 1855–1870. doi:10.1175/1520-0477(1998)079<1855:ANNMTP>2.0.CO;2
- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial Neural Networks: A Tutorial. *Computer*, 29(3), 31–44. doi:10.1109/2.485891
- Kalogirou, S. A. (2001). Artificial neural networks in renewable energy systems applications: a review. *Renewable & Sustainable Energy Reviews*, 5, 373–401. doi:10.1016/S1364-0321(01)00006-5
- Kavzoglu, T. (2009). Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling & Software*, 24, 850–858. doi:10.1016/j.envsoft.2008.11.012
- Kim, S., & Kim, H. S. (2008). Neural networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modeling. *Journal of Hydrology (Amsterdam)*, 351(3–4), 299–317. doi:10.1016/j.jhydrol.2007.12.014
- Krasnopolsky, V. M., & Schiller, H. (2003). Some neural applications in environmental sciences. Part II: advancing computational efficiency of environmental numerical models. *Neural Networks*, 16, 335–348. doi:10.1016/S0893-6080(03)00026-1
- Kung, S. Y., & Hwang, J. N. (1998). Neural networks for intelligent multimedia processing. *Proceedings of the IEEE*, 86(6), 1244–1272. doi:10.1109/5.687838
- McNelis, P. D. (2005). *Neural Networks in Finance: Gaining Predictive Edge in the Market*. Orlando, FL: Elsevier Academic Press.
- Principe, J. C. (1997). Neural networks for dynamics modeling. *Signal Processing Magazine*, 14(6), 33–35. doi:10.1109/MSP.1997.637300

*Characterization and Modelization of Surface Net Radiation through Neural Networks*

- Prokhorov, D. V. (2007). Training Recurrent Neurocontrollers for Real-Time Applications. *Neural Networks. IEEE Transactions*, 18(4), 1003–1015.
- Qi, M., & Zhang, G. P. (2008). Trend Time Series Modeling and Forecasting With Neural Networks. *Neural Networks. IEEE Transactions*, 19(5), 808–816.
- Ripley, B. (2008). *Pattern Recognition and Neural Networks*. Cambridge, UK: Cambridge University Press.
- Samarasinghe, S. (2006). *Neural Networks for Applied Sciences and Engineering: From Fundamentals to Complex Pattern Recognition*. Boston, MA: Auerbach Publications.
- Senkal, O., & Kuleli, T. (2009). Estimation of solar radiation over Turkey using artificial neural network and satellite data. *Applied Energy*, 86, 1222–1228. doi:10.1016/j.apenergy.2008.06.003
- Tripathy, P. P., & Kumar, S. (2009). Neural network approach for food temperature prediction during solar drying. *International Journal of Thermal Sciences*, 48(7), 1452–1459. doi:10.1016/j.ijthermalsci.2008.11.014
- Weigend, A. S., & Gershenfeld, N. A. (1993). *Time Series Prediction: Forecasting the Future and Understanding the Past*. Reading, MA: Addison-Wesley Publishing Co.
- Widrow, B., & Lehr, M. A. (1990). 30 years of adaptive neural networks: Perceptron, Madaline, and Backpropagation. *Proceedings of the IEEE*, 78(9), 1415–1442. doi:10.1109/5.58323
- Yuhong, Z., & Wenxin, H. (2009). Application of artificial neural network to predict the friction factor of open channel flow Communications. *Non-linear Science and Numerical Simulation*, 14(5), 2373–2378. doi:10.1016/j.cnsns.2008.06.020

**Artículo**

**“Estimating net radiation at surface using artificial neural networks: a new approach”**

*El presente artículo está publicado en la revista Theoretical and Applied Climatology, que posee un factor de impacto de 1.942 de acuerdo con el Thomson Reuters journal citation reports 2011.*

## Estimating net radiation at surface using artificial neural networks: a new approach

Antonio Geraldo Ferreira · Emílio Soria-Olivas ·  
Antonio José Serrano López · Ernesto Lopez-Baeza

Received: 11 March 2010 / Accepted: 7 July 2011 / Published online: 19 July 2011  
© Springer-Verlag 2011

**Abstract** This study describes the results of artificial neural network (ANN) models to estimate net radiation ( $R_n$ ), at surface. Three ANN models were developed based on meteorological data such as wind velocity and direction, surface and air temperature, relative humidity, and soil moisture and temperature. A comparison has been made between the  $R_n$  estimates provided by the neural models and two linear models (LM) that need solar incoming shortwave radiation measurements as input parameter. Both ANN and LM results were tested against in situ measured  $R_n$ . For the LM ones, the estimations showed a root mean square error (RMSE) between 34.10 and 39.48  $\text{Wm}^{-2}$  and correlation coefficient ( $R^2$ ) between 0.96 and 0.97 considering both the developing and the testing phases of calculations. The estimates obtained by the ANN models showed RMSEs between 6.54 and 48.75  $\text{Wm}^{-2}$  and  $R^2$  between 0.92 and 0.98 considering both the training and the testing phases. The ANN estimates are shown to be similar or even better, in some cases, than those given by the LMs. According to the

authors' knowledge, the use of ANNs to estimate  $R_n$  has not been discussed earlier, and based on the results obtained, it represents a formidable potential tool for  $R_n$  prediction using commonly measured meteorological parameters.

### 1 Introduction

Net radiation is the most significant energy exchange quantity on Earth because it represents the limit to the available energy source or sink for physical and biophysical processes, thus constituting the fundamental parameter governing the lower atmosphere climate (Oke 1987; Izimon et al. 2000). The surface net radiative energy balance can be calculated by using:

$$R_n = R_s^{\downarrow} - R_s^{\uparrow} + R_l^{\downarrow} - R_l^{\uparrow} \quad (1)$$

This equation represents the algebraic sum of both shortwave  $R_s$  and longwave  $R_l$  radiation flux densities, where the downward ( $\downarrow$ ) and upward ( $\uparrow$ ) arrows, respectively, indicate incoming and outgoing radiation components at the surface (Fig. 1). According to the arrows in Eq. 1, the downward incident radiation is taken as positive, while the upward emerging radiation is taken as negative.

The outgoing shortwave  $R_s^{\uparrow}$  is the fraction of the shortwave incoming solar radiation  $R_s^{\downarrow}$  that is reflected by the surface under consideration, i.e.,

$$R_s^{\uparrow} = \alpha R_s^{\downarrow}, \quad (2)$$

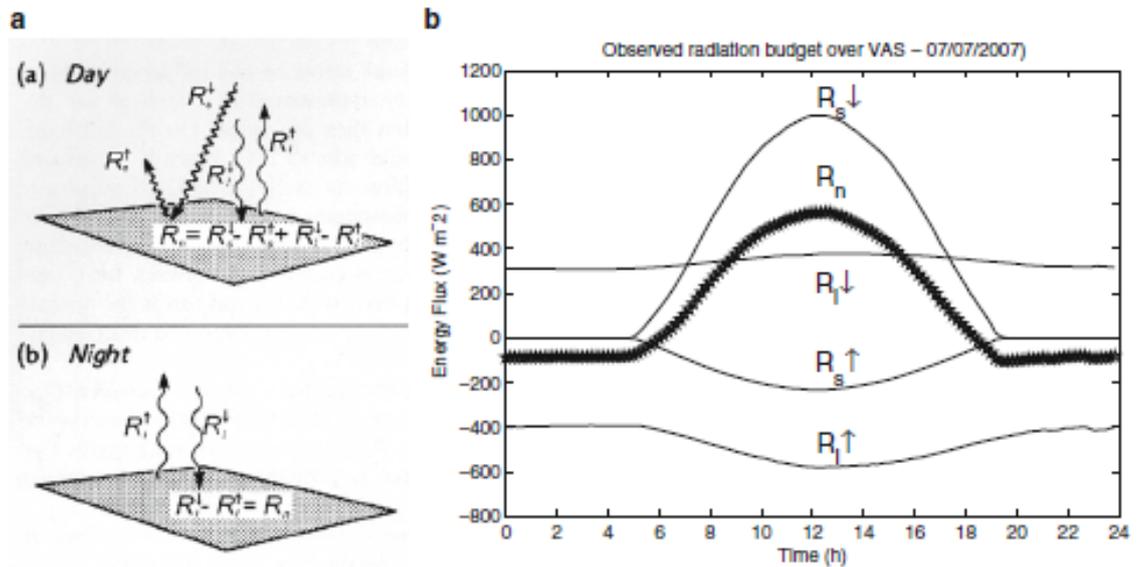
where  $\alpha$  is the surface albedo. Thus, Eq. 1 can be rewritten as

$$R_n = (1 - \alpha)R_s^{\downarrow} + (R_l^{\downarrow} - R_l^{\uparrow}). \quad (3)$$

A. G. Ferreira · E. Lopez-Baeza  
Department of Physics of the Earth and Thermodynamics,  
Faculty of Physics, University of Valencia,  
Calle Dr Moliner 50,  
46100 Burjassot, Valencia, Spain

E. Soria-Olivas · A. J. S. López  
Department of Electronic Engineering, ETSE,  
University of Valencia,  
Calle Dr Moliner 50,  
46100 Burjassot, Valencia, Spain

A. G. Ferreira (✉)  
Fundação Cearense de Meteorologia  
e Recursos Hídricos—FUNCEME,  
Av. Rui Barbosa,  
1246—CEP 60115-221 Fortaleza, Ceará, Brazil  
e-mail: antonio.ferreira@uvel.es



**Fig. 1** a Schematic summary of the fluxes involved in the radiation budget of an "ideal" site, b observed radiation budget over the *Valencia Anchor Station* (latitude 39°34'15" N and longitude 1°17'18" W at the Utiel-Requena Plateau, Spain) under clear sky conditions on July 7, 2007

For natural surfaces, the emission of longwave radiative flux is given by the modified Stefan–Boltzmann law, assuming a given emissivity for the Earth's surface (Arya 1988). Then, the net radiation flux at the surface is given by

$$R_n = (1 - \alpha)R_s^\downarrow + (R_n^\downarrow - \varepsilon\sigma T_{s\&E}^4), \quad (4)$$

where  $\varepsilon$  is the surface emissivity,  $T_{s\&E}$  the surface temperature (K), and  $\sigma$  the Stefan–Boltzmann constant ( $\sigma = 5.670 \times 10^{-8} \text{ W m}^{-2} \text{ K}^{-4}$ ). Equation 4 shows that the net radiative flux is the result of the radiation balance at the surface and is influenced by the climate near the ground and other properties such as surface temperature, albedo, and emissivity. Since its magnitude is directly related to the various radiative fluxes reaching or outgoing from the surface, it is clear that  $R_n$  is a key parameter for surface energy budget studies.

Despite its importance,  $R_n$  is measured routinely, with net radiometers, only at very few climatological stations around the world, or by scientists in short-term studies, partly because of the problem of providing a standard surface, but also because net radiation instruments are cumbersome to maintain (Irmak et al. 2003; Monteith and Unsworth 1990). As a consequence, a number of studies have put major effort into the accurate determination of  $R_n$  for a given location, considering its land cover and land use, from meteorological data, like soil surface and air temperature, fraction of the sky covered by clouds, relative

humidity, radiation emitted by the atmosphere, and incoming solar radiation, giving origin to various models that have been proposed or evaluated by Carrasco and Ortega-Farías (2007), de Jong et al. (1980), Irmak et al. (2003), Jegede et al. (2006), Kjaersgaard et al. (2007), Wang and Liang (2008), etc. These models based on empirical equations and coefficients either from the literature or based on the physical principles of radiation balance differ from each other in terms of the complexity of the required meteorological data (Sentelhas and Gillespie 2008). However, looking more carefully, most of the  $R_n$  equations utilized to estimate hourly, daily, or long-term  $R_n$  values need incoming solar radiation as input parameter—not a currently measured parameter in the majority of meteorological stations. Taking this into account, the objectives of the present study are (1) the development of a new model for estimating  $R_n$  over a vine crop employing artificial neural networks (ANNs) from routinely observed meteorological data, (2) the application of the two most commonly considered  $R_n$  linear estimation models using incoming solar radiation and albedo as input parameters, and (3) the analysis and comparison of the performance of the LMs against the new proposed ANN model.

The estimated  $R_n$  values from both LM and ANN models were compared to in situ  $R_n$  values measured during a field campaign denominated FESEBAV-2007 (*Field Experiment on Surface Energy Balance Aspects over the Valencia Anchor Station area*) carried out between June 19th and September 18th 2007. The Valencia Anchor Station is a

**Table 1** Description and arrangement of the sensors used for the measurements of the different meteorological and soil parameters during the FESEBAV07 field campaign

Parameter	Instrument	Manufacturer	Elevation
Net radiation	CN1 Net Pyradiometer	Middleton & Co. Pty. Ltd.	2 m
Incident and reflected solar radiation	Albedometer CM-14	Kipp and Zonen	2 m
Soil heat flux	RIMCO HP3 Heat Flux Plate	Middleton & Co. Pty. Ltd.	-7.5 cm; -12.5 cm
Air temperature	PT 100/3	Campbell Scientific Ltd.	2 m
Soil temperature	PT 100/3	Campbell Scientific Ltd.	Surface; -5 cm; -10 cm; -15 cm; -25 cm
Relative humidity	HMP45C	Campbell Scientific Ltd.	2 m
Wind speed/direction	RM Young 05103	R. M. Young Company	2.10 m
Soil moisture content	ThetaProbe Soil Moisture Sensor-ML2x	Delta-T Devices Ltd.	-5 cm; -35 cm horizontally

reference meteorological station (39°34'15" N, 1°17'18" W, elevation 813 m above sea level) that was mainly set up for the validation of low spatial resolution satellite data and products.

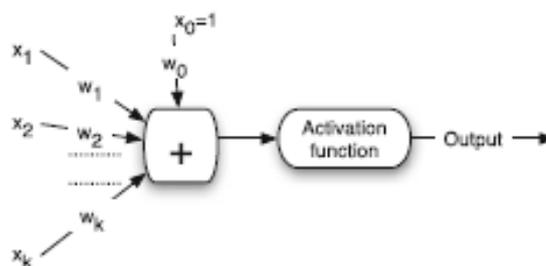
## 2 Material and methods

### 2.1 Description of the experimental site

In order to better achieve the objective of this study and considering that several meteorological factors as well as land cover and land use do affect the quantity of  $R_n$  that is registered at any particular place, an automatic agrometeorological station was mounted inside a vineyard (39°31'23" N, 1°17'22" W, elevation 796 m above sea level), during the FESEBAV-2007 field campaign mentioned earlier.

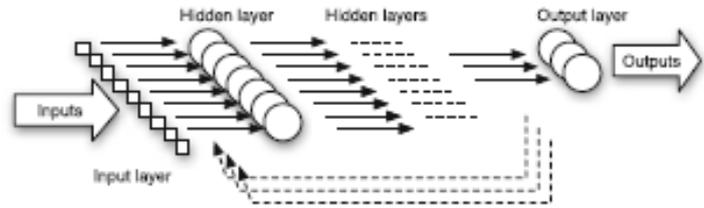
The area where FESEBAV-2007 took place is located over the natural region of Utiel-Requena Plateau, Spain. It represents a reasonably homogeneous area of about 50 km × 50 km (NW -1.5734, 39.8045; NE -0.9897, 39.7958; SE -1.0026, 39.3455; SW -1.5826, 39.3541) primarily dedicated to vineyard crops. The vines represent about 70–80% of the vegetation cover in the region. The land use of the remaining area is primarily dedicated to dryland crops, almonds, and olives trees, and to a lesser extent, pines and scrubs are also found. The climate in this area is a typical Mediterranean semiarid climate with an average monthly temperature varying between 5.6°C and 7.0°C in winter and between 21.2°C and 25°C in summer. The total annual rainfall is about 461 mm and the average monthly rainfall in the region is between 12 and 61 mm, mainly falling during the autumn months, but spread evenly throughout the year except in the summer dry period between July (12 mm) and August (21 mm).

The area observed by the agrometeorological station corresponds to an extensive plantation of vines distributed in northwest to southeast rows 2.9 m apart with 2.1 m between stumps. The grapevines belong to the typical Spanish *tempranillo* variety and were trained in vertical trellis with the main wire about 1 m above the soil surface. The soil is sandy loam and the laboratory analysis gave a composition of 67% sand, 13% silt, and 20% clay, with bulk density of 0.77 g cm<sup>-3</sup>, 70.9% porosity, and volumetric heat capacity varying between 1.57 × 10<sup>6</sup> and 1.87 × 10<sup>6</sup> J m<sup>-2</sup> K<sup>-1</sup>, depending on soil moisture content, that at a depth of 5 cm, ranged between 0.066 and 0.290 m<sup>3</sup> m<sup>-3</sup>, along FESEBAV-2007. During the 92 days of the field campaign, mainly covering the summer season and the full vineyard phenological cycle, nine rainfall events were registered, with three of them presenting a significant daily total rainfall of 35 mm (day 48, August 5, 2007), 20 mm (day 49, August 6, 2007), and 51 mm (day 69, August 26, 2007). In the other 6 days, the daily total rainfall varied between 1 and 7 mm.



**Fig. 2** Scheme of a neuron;  $x_i$  are the inputs and  $w_j$  are the neuron weights

Fig. 3 Scheme of a multilayer perceptron



2.2 Instrumentation and measurements

The agrometeorological station installed within the vine field was operated continuously for almost 4 months,

during the 2007 vine growing season, collecting the following parameters: air temperature (degree Celsius), relative humidity (percent), wind direction (degrees), and speed (meter per second); surface temperature and soil

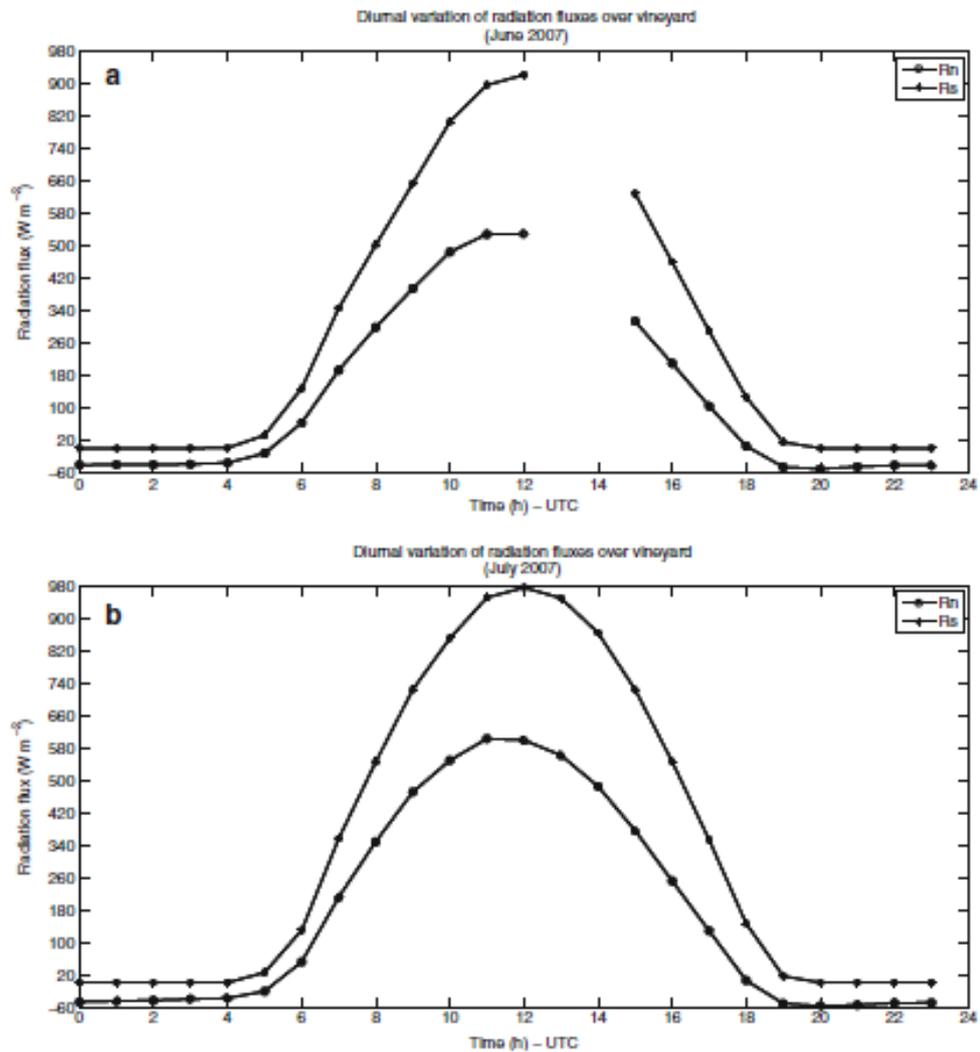


Fig. 4 Average diurnal variation of measured net radiation ( $R_n$ ) and incoming shortwave radiation ( $R_i^1$ ) over a vineyard in the period June 19 to September 18, 2007. a June 2007, b July 2007, c August 2007, and d September 2007

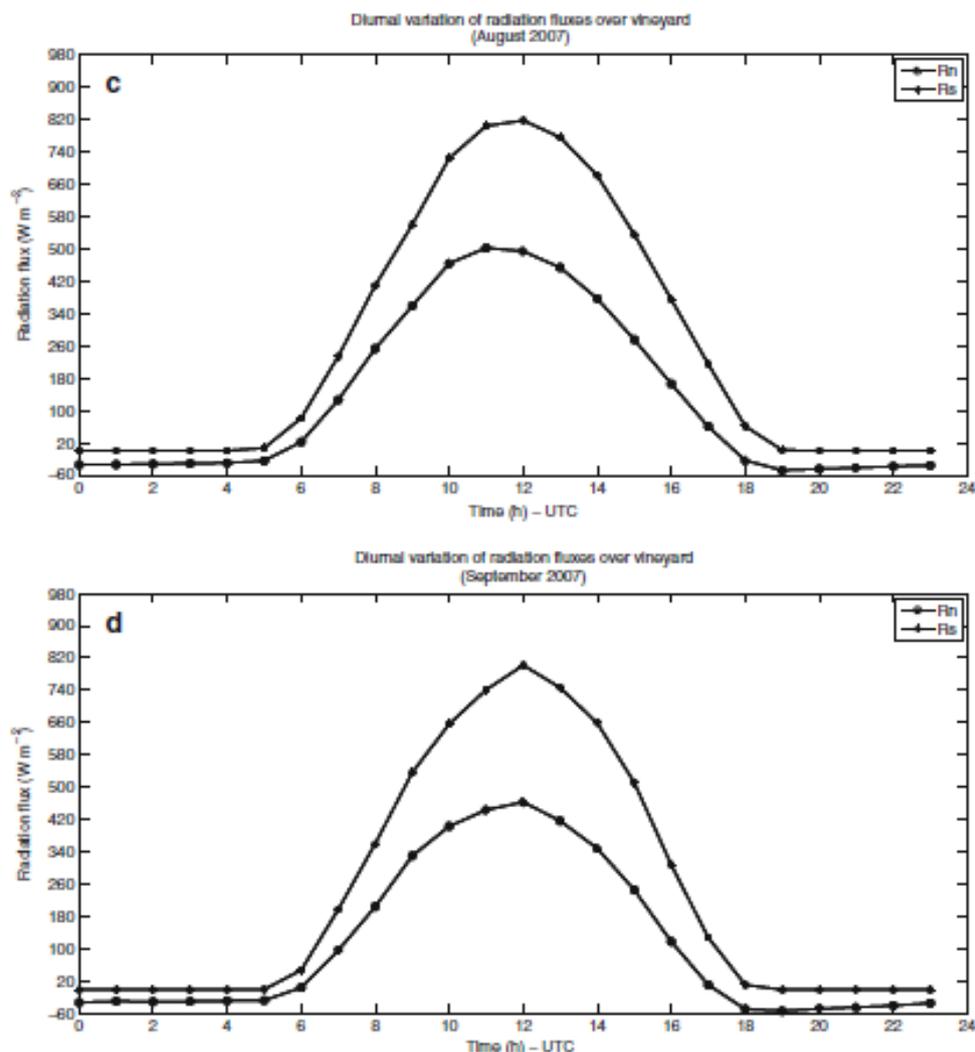


Fig. 4 (continued)

temperature profile (degree Celsius); soil heat flux (watt per square meter); incident, reflected, and net radiation (watt per square meter); and soil moisture (cubic meter per cubic meter). The different sensors (Table 1) were integrated into

Table 2 Linear regression models obtained for  $R_n$  and statistical results of the comparison between observed and estimated values of  $R_n$

Model	$R^2$	RMSE	MAE	ME	$N$
$R_{n1} = a_1 R_i^1 + b_1$					
$R_{n1} = 0.657 R_i^1 - 54.273$	0.96/0.97	39.48/35.38	34.19/30.87	0.006/7.10	4,397/2,198
$R_{n2} = a_2(1 - \alpha)R_i^2 + b_2$					
$R_{n2} = 0.791(1 - \alpha)R_i^2 - 54.161$	0.96/0.97	37.85/34.10	32.94/30.15	-0.009/8.21	4,397/2,198

$R^2$ , RMSE, MAE, ME, and  $N$  (number of data utilized). The results are given both for the developing and the testing phases, respectively, separated by /. RMSE, MAE, and ME are in units of watt per square meter

two Campbell CR1000 dataloggers that were programmed to collect the data every second for all sensors and average it for 10 min.

### 2.3 Methods

Since  $R_n$  can be positive, negative, or even zero, in order to better investigate its behavior during the field campaign, the dataset was divided in three parts: The first one considers all  $R_n$  in situ measured data, the second one considers only the negative net radiation ( $R_n < 0$ ) values, and the third one

considers only the positive net radiation ( $R_n > 0$ ) values, hereafter referred to as  $R_{n+}$ ,  $R_{n-}$ , and  $R_{n0}$ , respectively. This procedure allows to find a model for  $R_{n+}$  overall values and more specific models for  $R_{n-}$  and  $R_{n0}$ . Besides this, each of these datasets was divided into two subsets: the first one comprising two thirds of the data and was used to develop the LM and to train the ANN, and the remaining one third of the data were used for testing the models. The accuracy of the  $R_n$  estimated values using both the LM and the ANN models was assessed through the mean value of the absolute error (MAE), the mean error (ME),  $R^2$ , and root mean square error (RMSE).

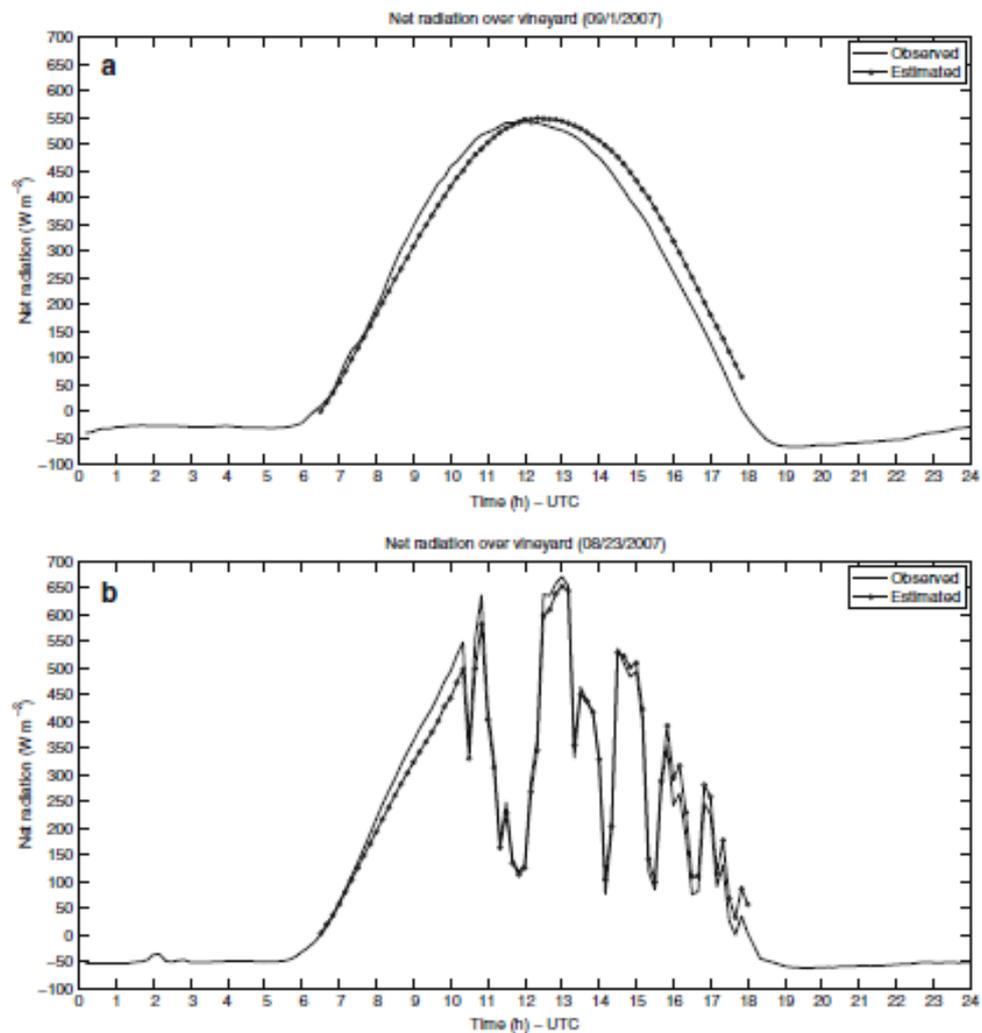


Fig. 5 Observed and estimated  $R_n$  for cloudless conditions (days: September 1, 2007 and August 15, 2007) and cloudy conditions (days: August 23, 2007 and July 12, 2007). The linear models utilized to estimate  $R_n$  were:  $R_{n1} = 0.657 R_1^2 - 54.273$  for a and b, and  $R_{n2} = 0.791 (1 - \alpha) R_1^2 - 54.161$  for c and d

### 2.3.1 Linear models

Models for calculating  $R_n$  from other climatic parameters using regressions are widely used, including linear regression models, which are formal means of expressing the relationship between two or more variables, and have the power to empirically facilitate complicated relationships among the considered quantities. According to Kjaersgaard et al. (2007), the most commonly used equations to estimate  $R_n$  are

$$R_n = a_1 R_s^l + b_1 \quad (5)$$

$$R_n = a_2(1 - \alpha) R_s^l + b_2, \quad (6)$$

where  $a_1$ ,  $a_2$ ,  $b_1$ , and  $b_2$  are regression coefficients,  $\alpha$  represents the surface albedo, and  $R_s^l$  is the incoming solar radiation that is more commonly measured than  $R_n$ . The investigations have shown that the regression coefficients in those models are, among other things, dependent on the type of surface and its conditions.

### 2.3.2 Multilayer perceptron

Artificial neural networks are mathematical models that learn and establish nonlinear relationships between two datasets. They have the ability to find complex relationships in data (Bishop 1996; Haykin 1999). In this work, the ANN used is the *multilayer perceptron* (MLP), a model that

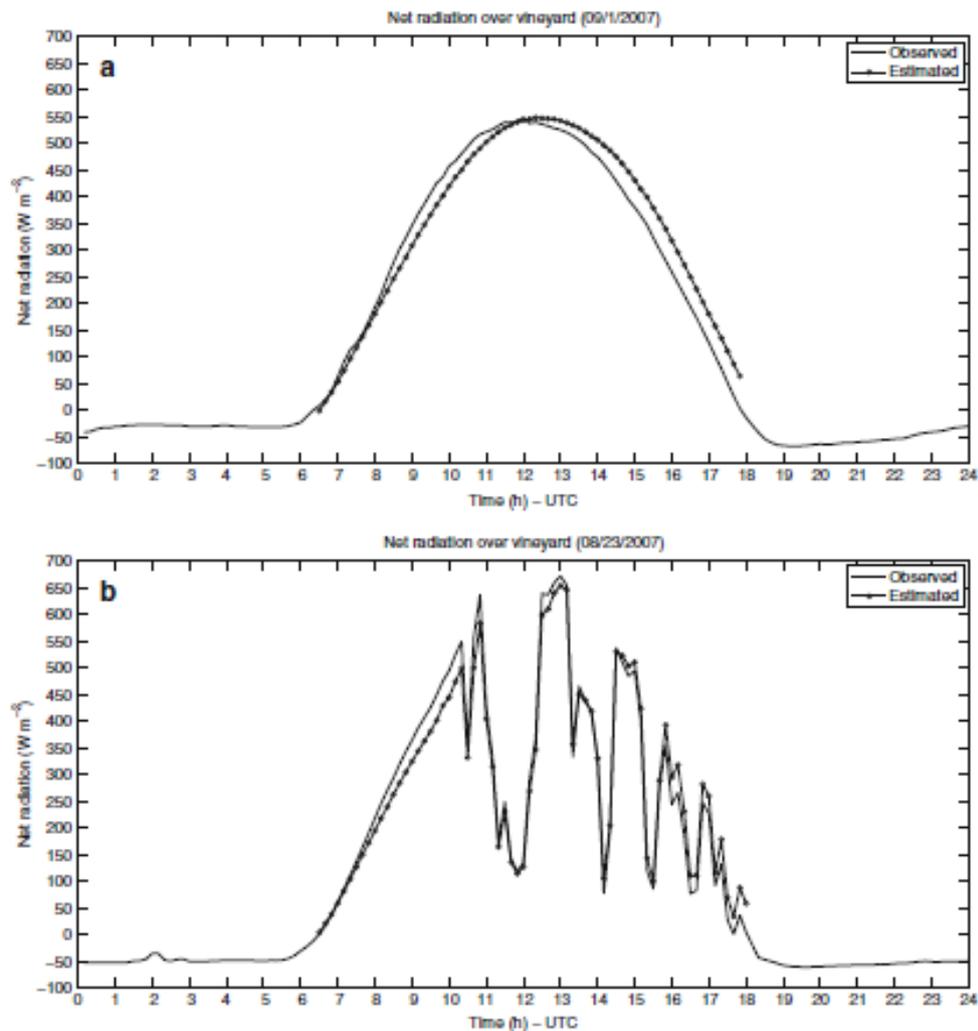


Fig. 5 (continued)

consists in a layered arrangement of individual computation units known as *artificial neurons*. The neurons of a given layer feed with their outputs the neurons of the next layer. A single neuron is shown in Fig. 2.

The inputs  $x_i$  to a neuron are multiplied by adaptive coefficients  $w_i$ , called *synaptic weights* which represent the connectivity between neurons. The output of a neuron is

usually taken to be a sigmoid-shaped (sigmoid or hyperbolic tangent function)  $\varphi$ . The output of the  $j$ th neuron is given by

$$O_j = \varphi \left( \sum_{i=0}^m w_{ij} x_i \right), \quad (7)$$

where  $\varphi$  is a nonlinear function named *activation function*.

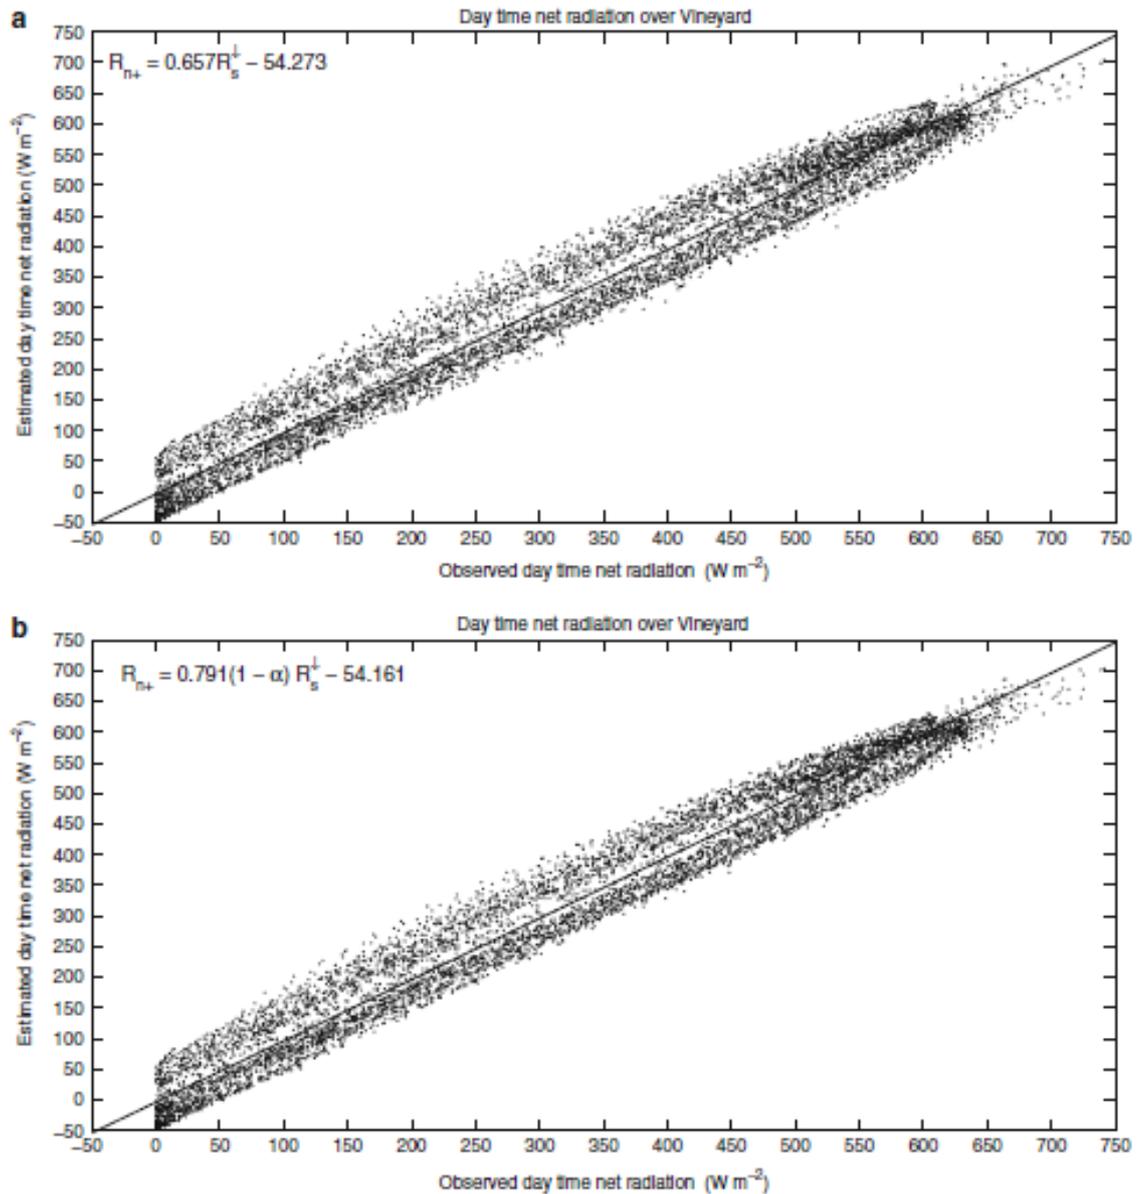


Fig. 6 Scatter plots of net radiation (observed versus estimated values) for both  $R_{n1}$  (a) and  $R_{n2}$  (b) models for daytime

**Table 3** Statistical values of the 10-min meteorological parameters utilized as input parameters in the ANN models for the training and validation set

Meteorological parameters	Statistics			
	Min	Max	Mean	Std
Wind velocity ( $\text{m s}^{-1}$ )	0.0	5.05	1.22	0.73
Wind direction (deg)	0.0	359.90	158.98	92.81
Air temperature ( $^{\circ}\text{C}$ )	8.81	39.92	21.83	6.45
Surface temperature ( $^{\circ}\text{C}$ )	10.63	61.91	28.85	13.12
Soil temperature at 5 cm depth ( $^{\circ}\text{C}$ )	14.16	41.70	25.84	6.12
Relative humidity (%)	6.89	99.30	54.74	25.87
Soil moisture at 5 cm depth ( $\text{m}^3 \text{m}^{-3}$ )	0.07	0.29	0.09	0.03
Soil heat flux at depth of 7.5 cm ( $\text{W m}^{-2}$ )	-22.54	50.68	-8.49	18.46
Net radiation* ( $\text{W m}^{-2}$ )	-73.33	741.30	144.94	231.24

Min minimum, Max maximum, Std standard deviation

\*Net radiation was considered as output parameter in the ANN models

Neurons from a specific network are grouped together in layers that form a fully connected network. The first layer contains the input nodes, which are usually fully connected to hidden neurons, and these are, in turn, connected to the output layer. Figure 3 shows a scheme of a fully connected multilayer perceptron. In our case, only one output neuron is necessary, since only one parameter is predicted at each time.

### 3 Results and discussion

The diurnal courses of  $R_n$  and  $R_s^1$  observed during FESEBAV-2007 are presented in Fig. 4. It can be seen that the maximum values of these parameters are reached around midday (UTC), and July is the month in which  $R_s^1$  is maximum over the vineyard, having more available  $R_n$  for the soil-plant-atmosphere system and, consequently, for physical and biophysical processes required by the vineyard growth. The ratios between  $R_n$  and  $R_s^1$  were in average 0.54, 0.58, 0.57, and 0.54 for June 19–31, July, August, and September 1–18, respectively.

Based on Eqs. 5 and 6, hereafter called  $R_{n1}$  and  $R_{n2}$ , respectively, the estimated  $R_n$  values were obtained by using  $R_s^1$  measurements from the FESEBAV-2007 dataset. The same dataset was utilized to estimate the local regression coefficients  $a_1$ ,  $a_2$ ,  $b_1$ , and  $b_2$ , and the linear models obtained are shown in Table 2. Figure 5 shows the diurnal courses of the observed  $R_n$  values as well as the estimated daytime values of  $R_n$  using  $R_{n1}$  and  $R_{n2}$ , for four different days, where two of these days were under cloudless conditions (Fig. 5a, c) and the other two were cloudy (Fig. 5b, d). For these days, both  $R_{n1}$  and  $R_{n2}$  models tend to overestimate  $R_n$  slightly after 1300 hours and underestimate it slightly between 900 and 1300 hours approximately. In both cases, cloudless (day August 15, 2007: RMSE=41.93  $\text{W m}^{-2}$  and MAE=37.74  $\text{W m}^{-2}$ ; day September 1, 2007: RMSE=36.20  $\text{W m}^{-2}$  and MAE=31.94  $\text{W m}^{-2}$ ) and cloudy (day July 12, 2007: RMSE=

37.72  $\text{W m}^{-2}$  and MAE=33.93  $\text{W m}^{-2}$ ; day August 23, 2007: RMSE=30.03  $\text{W m}^{-2}$  and MAE=25.71  $\text{W m}^{-2}$ ), the estimates obtained are in good agreement with the measured values.

According to the statistical results given in Table 2, the obtained LMs showed a high accuracy in estimating  $R_{n1}$  and  $R_{n2}$ , considering that these models do not take into account the longwave component of net radiation which is obviously more significant during nighttime. At night, net radiation usually has a negative value (see Figs. 4 and 5) because there is no incoming solar radiation and the net longwave radiation is dominated by the outgoing terrestrial longwave flux. Simple regression models such as  $R_{n1}$  and  $R_{n2}$  do not contain any correction for longwave radiation nor factors affecting the longwave radiation components (Kjaersgaard et al. 2007).

During daytime, solar radiation dominates the diurnal cycle and is almost always incident to the surface, while at night, net radiation is much weaker and emerging from the surface. As a result, the surface warms up during daytime, while it cools down during evening and night hours, especially under clear sky and undisturbed weather conditions (Arya 1988). In Fig. 6, estimates of 10-min  $R_n$  values, as obtained from the models presented in Table 2, are plotted against the measured data showing high correlation coefficients ( $0.96 \leq R^2 \leq 0.97$ ), considering both the developing and the testing phases.

**Table 4** Statistical results for net radiation flux using neural networks (training/validation sets)

Model	$R^2$	RMSE	MAE	ME
$R_{n1}$	0.92/0.92	6.23/6.54	4.59/4.76	0/0.089
$R_{n2}$	0.97/0.96	42.9/48.75	26.81/29.29	-0.33/0.26
$R_{n3}$	0.98/0.98	38.09/39.26	21.67/22.60	0.0209/1.41

RMSE, MAE, and ME are in units of watt per square meter

As mentioned earlier, the FESEBAV-2007 experiment was carried out over a vine crop, which somehow may be considered as sparse vegetation. During the experiment, the vineyard canopy reflectance ranges and monthly averages were respectively:  $0.15 \leq \alpha \leq 0.21$ ,  $\bar{\alpha} = 0.18$  (June);  $0.10 \leq \alpha \leq 0.22$ ,  $\bar{\alpha} = 0.17$  (July);  $0.11 \leq \alpha \leq 0.25$ ,  $\bar{\alpha} = 0.17$  (August); and  $0.11 \leq \alpha \leq 0.30$ ,  $\bar{\alpha} = 0.18$  (Septem-

ber). According to the results obtained by Alados et al. (2003), Azevedo et al. (1997); Fritschen (1967), and Kjaersgaard et al. (2007), the inclusion of the  $\alpha$  term in Eq. 6 improves only slightly the regression results as compared to Eq. 5. In this study, the statistical analysis also indicated that the inclusion of the  $\alpha$  term in Eq. 6, as compared to Eq. 5, leads to a slight improvement in  $R_m$

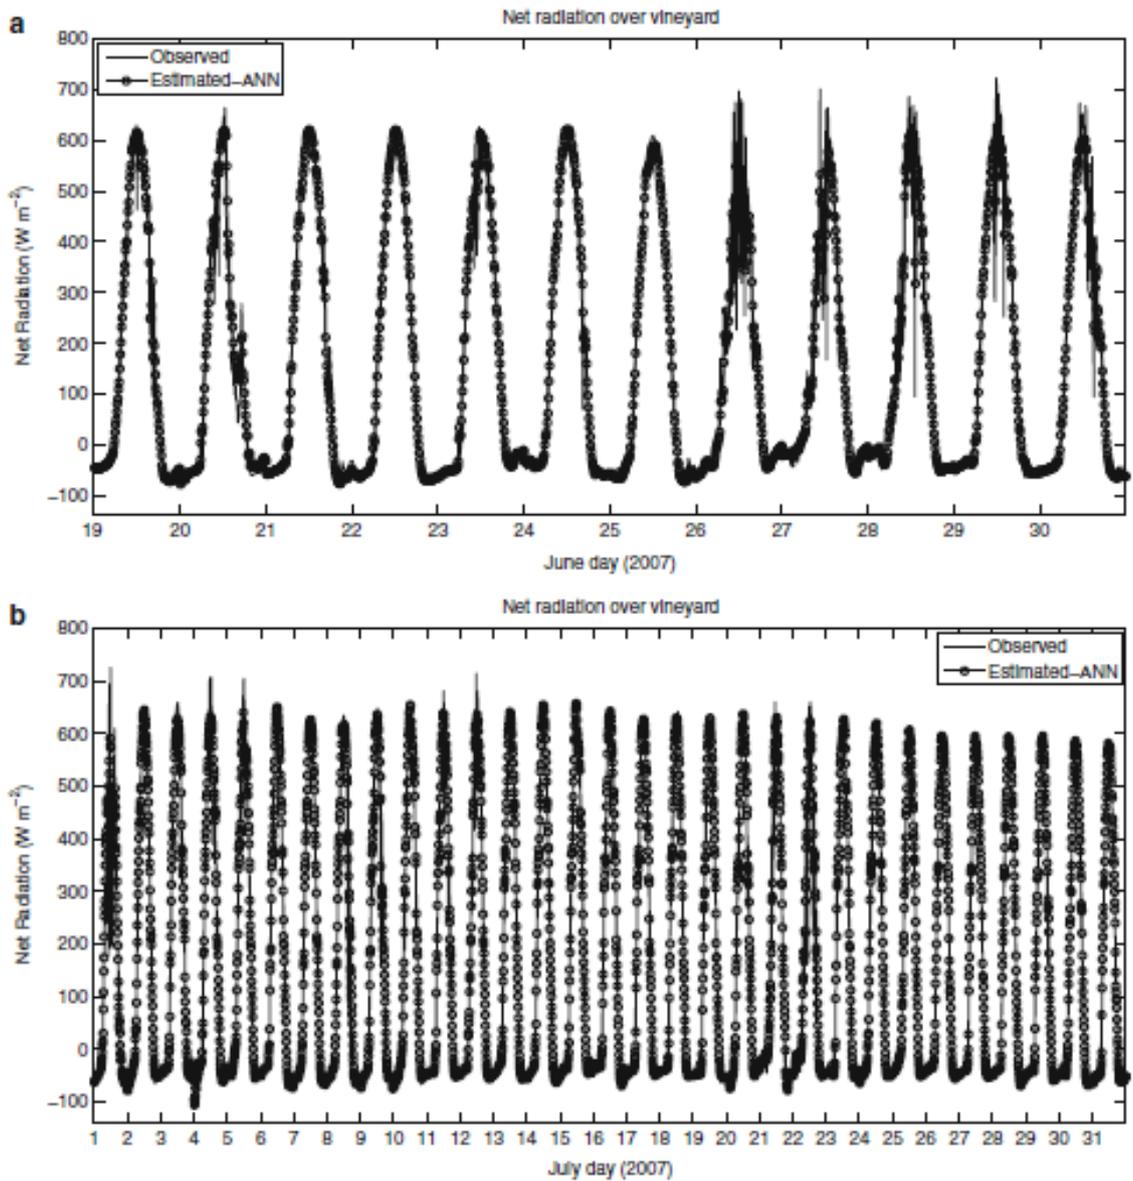


Fig. 7 Ten-minute  $R_n$  averages measured (lines) and calculated by the ANN model (dots) for: a June 2007, b July 2007, c August 2007, and d September 2007

estimations (see  $R^2$  and RMSE on Table 2 for both models represented by these equations).

The authors mentioned above carried out their studies over irrigated field crops, European wine grape vineyard, sparse clumped shrub-land of different species, and short grass surrounded by agricultural fields, respectively. But Alados et al. (2003) reported that the inclusion of surface albedo, in the studies made by Kaminsky and Dubayah

(1997) in the boreal forest and northern prairie sites, led to a general improvement in the determination coefficients. This means that when estimating  $R_n$  at any particular place, land cover and land use need to be considered as well as the local adjustment of the model parameters.

Since  $R_s^i$  and  $\alpha$  are not so frequently measured in meteorological networks, the LMs presented here and those mentioned in the literature cannot be used, with reliable

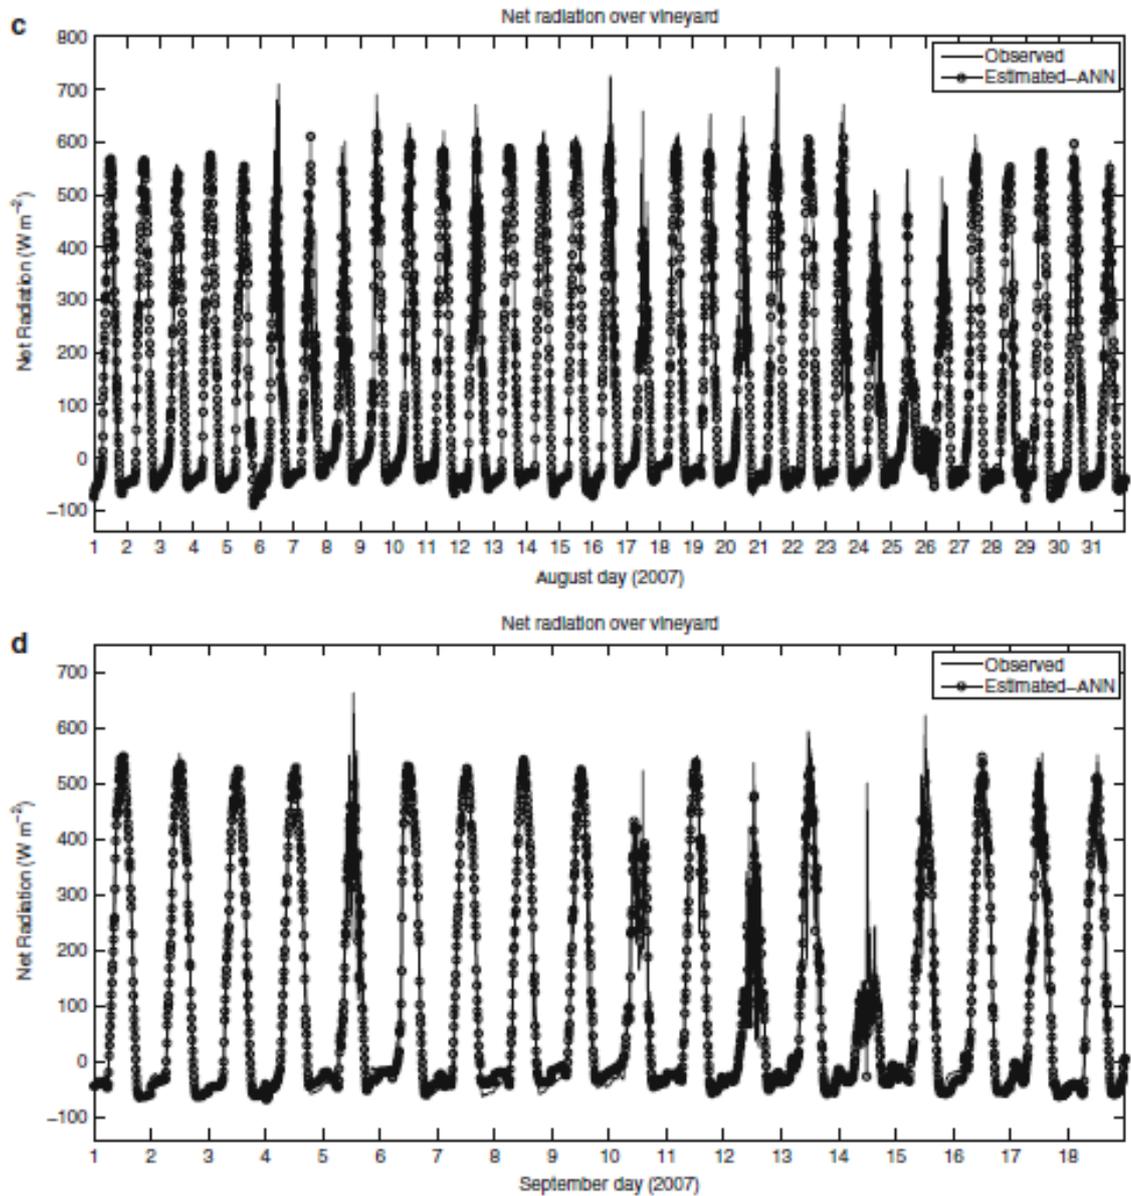


Fig. 7 (continued)

accuracy, in locations where  $R_n^i$  and  $\alpha$  are not measured. The alternative presented here to estimate  $R_n$  is modeling it using ANNs that use other meteorological parameters as input parameters. Eleven of those have been selected in this study for the estimation of  $R_n$ , namely month, day, hour, wind velocity, wind direction, air temperature, surface temperature, soil temperature, relative humidity, soil moisture, and soil heat flux (see Table 3).

ANNs of different architectures and weight initializations have been proposed and the Levenberg–Marquardt's algorithm was selected as the procedure to adjust the neural network parameters (Luenberger and Ye 2008). This algorithm shows a better performance than other more

widely used algorithms, such as the classical *backpropagation algorithm*, for example. As far as hidden nodes are concerned, only one hidden layer was taken into consideration (the number of neurons ranged between 2 and 15). The stopping criterion was based on cross-validation (Bishop 1996; Haykin 1999). The results of this proposed ANN model for the estimation of  $R_{net}$ ,  $R_{sw}$ , and  $R_{lw}$ , are shown in Table 4. As frequently indicated earlier, the calculations have been performed both for the training (they are the patterns to adjust the parameters) and for the validation (they are the patterns to avoid the overfitting) datasets. The former is used to adjust the parameters, and the latter is used to avoid overfitting.

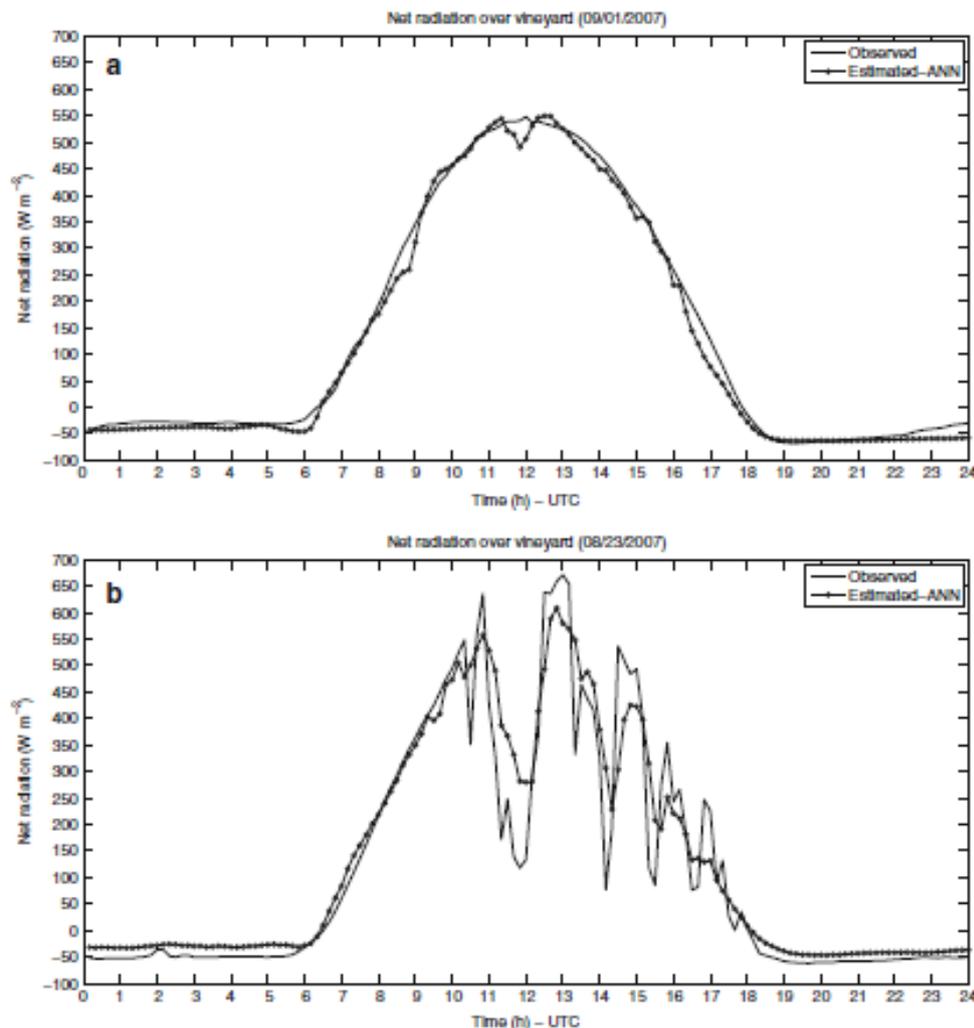


Fig. 8  $R_n$  estimated by using ANN and measured  $R_n$  for clear sky conditions (days: September 1, 2007 and August 15, 2007; a, c) and for cloudy conditions (days: August 23, 2007 and July 12, 2007; b, d)

According to the results shown in Table 4, the proposed ANN model provides similar results to those from the LMs for  $R_{n1}$  and  $R_{n2}$  (see Table 2) when considering daytime values, i.e.,  $R_{n+}$ . When considering only  $R_{n-}$  (nighttime) and  $R_{n\pm}$  (full diurnal cycle), high values of  $R^2=0.92$  and  $0.98$ , respectively, for the training and the validation phases are obtained for the proposed ANN model. ANN estimated  $R_{n\pm}$  fitted well the measured data mainly over clear sky conditions (Fig. 7). The advantage of the ANN model presented here when compared to  $R_{n1}$  and  $R_{n2}$  LMs is that the ANN can also be applied to estimate  $R_n$  during the nighttime, when the sun is cutoff, and to the full diurnal

cycle of  $R_n$  once the ANN does not use incoming solar radiation as input parameter.

Figure 8 shows the diurnal courses of  $R_{n\pm}$  estimated by the ANN model and of  $R_n$  measured at the agrometeorological station for the same 4 days presented in Fig. 5. Thus, Fig. 8a, c shows the results for the clear sky days and Fig. 8b, d for the two cloudy days. These case studies, obtained from the complete time series presented in Fig. 7, show that for clear sky conditions (day August 15, 2007: RMSE=17.80  $Wm^{-2}$  and MAE=13.38  $Wm^{-2}$ ; day September 1, 2007: RMSE=18.33  $Wm^{-2}$  and MAE=13.38  $Wm^{-2}$ ) the estimates are better than for cloudy conditions

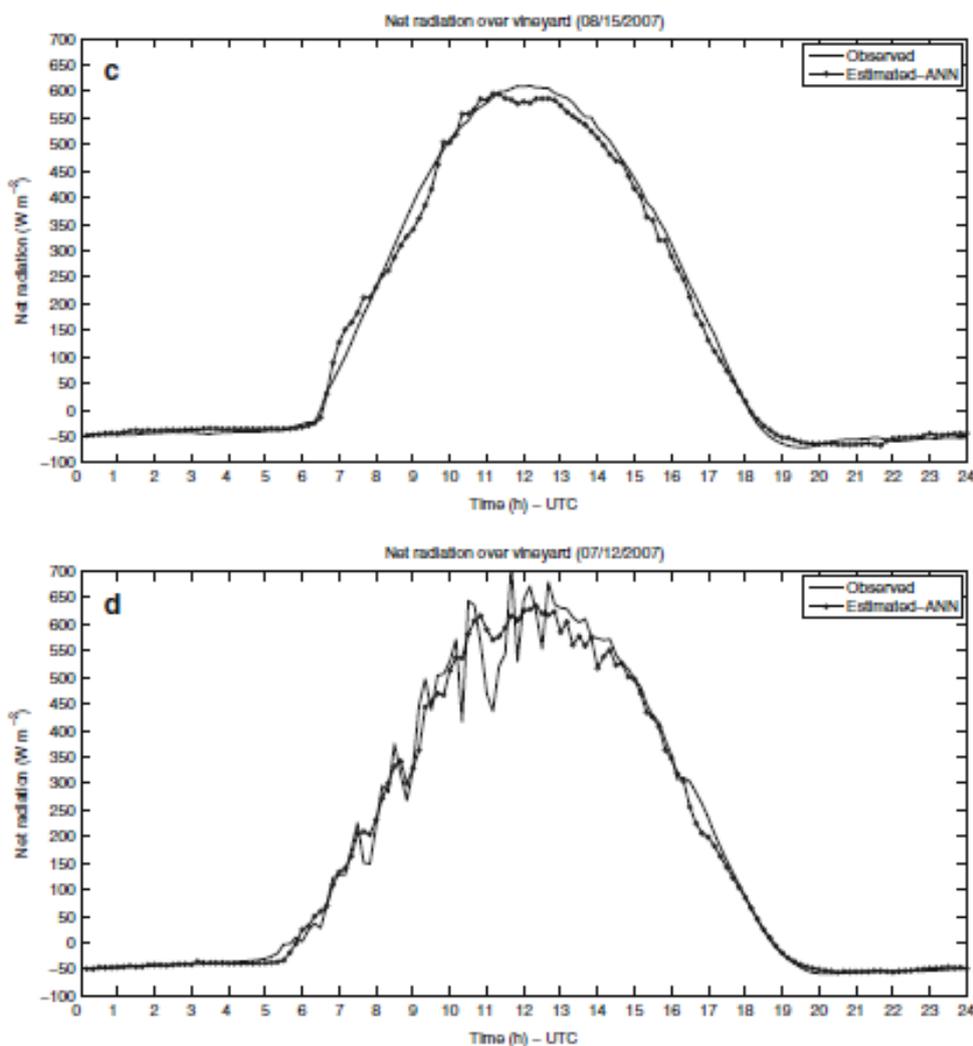


Fig. 8 (continued)

(day July 12, 2007: RMSE=31.45  $\text{W m}^{-2}$  and MAE=18.28  $\text{W m}^{-2}$ ; day August 23, 2007: RMSE=63.51  $\text{W m}^{-2}$  and MAE=39.27  $\text{W m}^{-2}$ ).

Figure 1b introduced earlier clearly showed that all radiation components are in phase under clear sky conditions and that no abrupt variation is found in the radiation components reaching the surface (Fig. 8a, c).

However, under cloudy conditions, abrupt and rapid changes appear in solar radiation reaching the surface leading to strong variations in  $R_n$  in short times (Fig. 8b, d), depending on cloud cover fraction and types, thus generating outliers in the dataset, as registered by the net radiometer (Figs. 7 and 8). These outliers are difficult to model, causing over- or underestimations of  $R_n$  depending

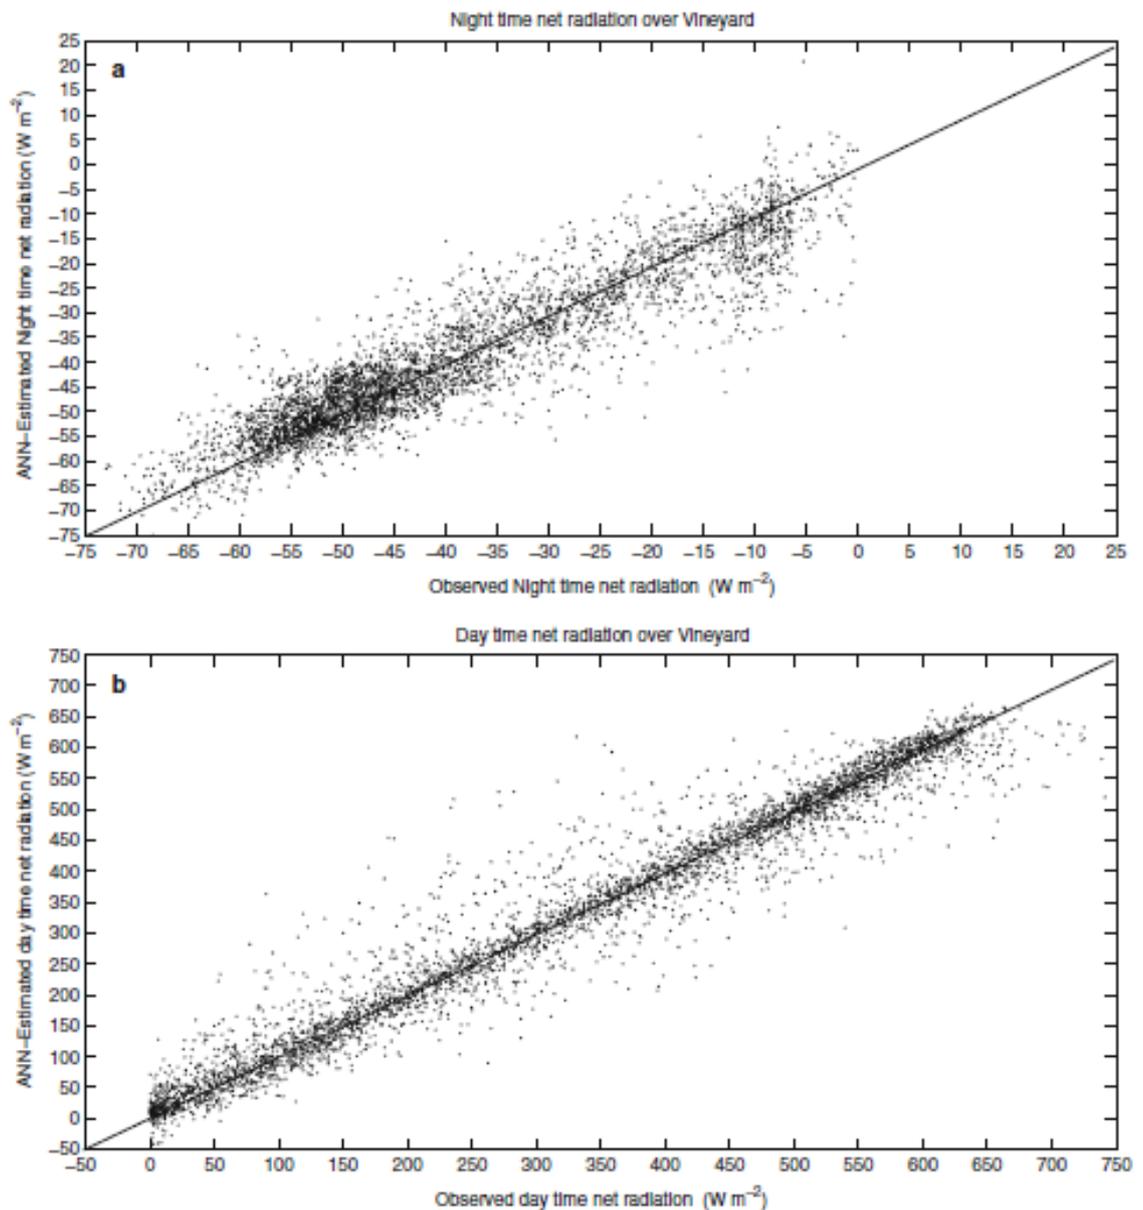


Fig. 9 Scatter plots of net radiation (observed versus ANN estimated). a Nighttime, b daytime, and c complete diurnal cycle

on the period of the day, and also because the meteorological parameters used in the ANN model reflect these abrupt variations as well.

A scatter diagram between observed and estimated  $R_n$  is also shown in Fig. 9 for the three ANN models  $R_{n-}$ ,  $R_{n+}$ , and  $R_{n\pm}$ . It can be seen that these three models present low dispersion values.

Table 5 shows now the slope and intercept for LMs ( $R_{n1}$  and  $R_{n2}$ ) and ANN and the average values of measured  $R_n$ . The slopes of the lines of observed  $R_n$  versus estimated  $R_n$  are close to 1.0, varying between 0.95 and 0.98 for  $R_{n+}$  and  $R_{n\pm}$  (LMs and ANN). For  $R_{n-}$ , the slope for the ANN is 0.86. The intercepts for  $R_{n+}$  and  $R_{n\pm}$  are about 5% or less of the average measured  $R_{n+}$  and  $R_{n\pm}$  (LMs and ANN). The intercept of the ANN model for  $R_{n-}$  (nighttime) is approximately 14% of the average measured  $R_{n-}$ , and the RMSE is 16.8%. This means that the ANN improves the accuracy of the LMs considering that the latter cannot be applied for the estimation of  $R_{n-}$  or  $R_{n\pm}$ . Amarakoon and Chen (1999) considered that an intercept and RMSE of about 10% or less of the averaged measured  $R_n$  are acceptable for the different types of conditions expressed by the measured data (climate, seasons, land cover, surface moisture, soil type, etc.). In this work, we obtain similar percent values for the intercepts and RMSE when only  $R_{n+}$  values (daytime) are considered. For  $R_{n\pm}$  (diurnal cycle), the intercept and the RMSE obtained are respectively and approximately 2.7% and 21% of the averaged measured  $R_{n\pm}$ . This difference observed in the RMSE

between the acceptable values and ANN can be explained by the fact that the ANN proposed here does not use incoming solar radiation as input parameter which is directly linked to surface  $R_n$ .

As indicated earlier,  $R_n^i$  was not used as an input to the ANN, and the results clearly demonstrate that the ANN is a helpful tool to estimate  $R_n$  from meteorological data such as those mentioned in Table 3, given that parameters related to radiation fluxes are not routinely measured.

According to Irmak et al. (2003), if  $R_n$  could be predicted in an accurate manner from a minimum number of climatological data, this would be a great improvement and contribution for engineers, agronomists, climatologists, and others who routinely use regular National Weather Service climatological data such as rainfall, air temperature, atmospheric pressure, relative humidity, wind velocity, and direction. In this sense, the ANN introduced here has the ability to predict  $R_n$  using a few common meteorological parameters as input. The multilayer perceptron network uses a *learning* algorithm to determine the best network parameters to model the relationship between the input and output variables, and the adjustment between these variables is done without any assumption on previous relationships between parameters because they are actually related per se and represent sufficiently well the problem (Haykin 1999). Therefore, the methodology developed here to estimate  $R_n$  could be successfully transferred and applied to other surfaces (for example, with different land cover and land uses) and seasons.

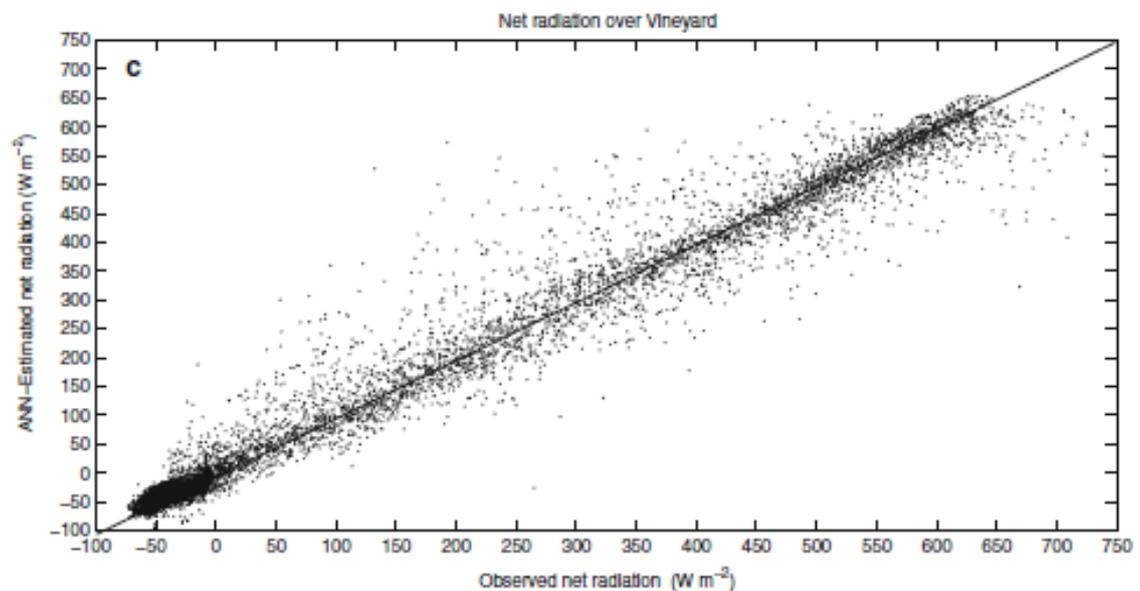


Fig. 9 (continued)

**Table 5** Linear regression ( $a$ =slope and  $b$ =intercept) between measured  $R_n$  and estimated  $R_n$  (watt per square meter) using LMs and ANN models

Model	LMs				ANN		$\overline{R_n}$
	$R_{n1}$		$R_{n2}$		$a$	$b$	
	$a$	$b$	$a$	$b$			
$R_{n+}$	0.98	5.48	0.98	4.23	0.95	16.28	330.44
$R_{n-}$	-	-	-	-	0.86	-5.50	38.94
$R_{na}$	-	-	-	-	0.97	3.92	144.94

$\overline{R_n}$  is the average of measured  $R_n$ .  $\overline{R_n}$  is given in units of watt per square meter

#### 4 Conclusions

This paper presents an alternative and convenient approach to estimate surface net radiation using an artificial neural network model that uses as input variables a limited number of operational meteorological parameters currently measured in conventional agrometeorological stations. This also emphasizes the practical advantages of the method. By using the training and validation datasets, the results obtained for  $R_{n2}$ ,  $R_{n+}$ , and  $R_{n-}$  show the good performance of the ANN model to estimate surface  $R_n$ .

Without using  $R_n^s$  as input parameter, the ANN presented in this work demonstrates to be a helpful tool to estimate  $R_n$  at the surface from operational meteorological parameters such as those mentioned in Table 3, which is very useful for sites where radiation flux-related parameters are not currently measured.

Another practical advantage of the ANN in estimating  $R_n$  in comparison to other physical, empirical, or semi-empirical models, being linear or nonlinear, is that the majority of these models require other geophysical parameters such as downwelling and reflected shortwave radiation, downwelling and upwelling longwave radiation, albedo, surface temperature, air vapor pressure, fraction of cloud cover, emissivity of the surface and of the atmosphere, among others, as input to the model (Amarakoon and Chen 1999; de Jong et al. 1980; Iziomon et al. 2000; Jegede 1997; Ortega-Farías et al. 2000; Sentelhas and Gillespie 2008). Usually, these parameters are not routinely measured in agrometeorological stations, and estimations made from them may lead to increasing errors in  $R_n$  estimations.

A brief commentary should be made about the transferability of the method to other surface and seasons conditions. In spite of the neural networks being a robust tool to explore and define relationships between parameters that presumably should exist out of empirical datasets, the limitation of these models is precisely the empirical

character of the data used both for the training and for the validation phases of the procedure. In our case, the strongest variability of the data proceeds from cloudiness. Fortunately, the long dataset employed in this study has offered the possibility of seeing the behavior of the neural network under cloudy conditions of very different intensity and temporal and spatial distributions, and the model has always produced good results. Therefore, we should expect the method to be applicable to other land use conditions as well. Moreover, the study applied covering the full vineyard cycle has permitted to apply the same methodology to the very heterogeneous situations from bare soil before the beginning of the vine season to the full development of the plants that have a very heterogeneous spatial distribution, and the results are equally satisfactory.

**Acknowledgments** Antonio Geraldo Ferreira held a grant from the Programme Alþan, a European Union Programme of High Level Scholarships for Latin America, scholarship no. E05D058998BR. The field work was carried out in the framework of the projects *Calibration of SMOS MIRAS Radiometer Measurements and Generation of Maps of Salinity and of Soil Moisture Content—UVEG Part (MIDAS-4/UVEG)* and *Product Validation, Data Exploitation and Expert Center for the SMOS Mission—UVEG Part (MIDAS-5/UVEG)*, both from the Spanish Ministry for Education and Science (National Programme on Space Research), and *Remote Sensing Techniques for the Observation of Environmental Parameters in the Valencia Community Autonomous Region for 2007–2009*, from the Department for Environment, Water, Planning and Housing, General Directorate for Climate Change, Generalitat Valenciana. The authors gratefully acknowledge the owners of *El Renegado* and *Cañada Honda* vineyard fields (Caudete de las Fuentes, Valencia, Spain) where the meteorological stations are installed.

#### References

- Alados I, Foyo-Moreno I, Olmo FJ, Alados-Arboledas L (2003) Relationship between net radiation and solar radiation for semi-arid shrub-land. *Agric For Meteorol* 116(3–4):221–227
- Amarakoon D, Chen A (1999) Estimating daytime net radiation using routine meteorological data in Jamaica. *Caribb J Sci* 35(1–2):132–141
- Arya SP (1988) *Introduction to micrometeorology*. Academic, London, 305 pp
- Bishop ChM (1996) *Neural networks for pattern recognition*. Clarendon, Oxford, p 482
- Azevedo PV de, Teixeira AH de C, Silva BB da, Soares JM, Saraiva FAM (1997) Avaliação da reflectância e do saldo de radiação sobre um cultivo de videira europeia. *Revista Brasileira de Agrometeorologia*, 5(1):1–7
- Carnasco M, Ortega-Farías S (2007) Evaluation of a model to simulate net radiation over a vineyard Cv Cabernet Sauvignon. *Chilcan Journal of Agricultural Research* 68:156–165
- Fritschen LJ (1967) Net and solar radiation relations over irrigated field crops. *Agric Meteorol* 4:55–62
- Haykin S (1999) *Neural networks: a comprehensive foundation*. Prentice Hall, Upper Saddle River, p 842
- Imak S, Asce M, Irmak A, Jones JW, Howell TA, Jacobs JM, Allen RG, Hoogenboom G (2003) Predicting daily net radiation using

- minimum climatological data. *J Irrig Drain Eng* 129(4):256–269
- Iziomon MG, Mayer H, Matzarakis A (2000) Empirical models for estimating net radiative flux: a case study for three mid-latitude sites with orographic variability. *Astrophysics and Space Science* 273:313–330
- Jegede OO (1997) Estimating net radiation from air temperature for diffusion modelling applications in a tropical area. *Boundary-layer Meteorology* 85:161–173
- Jegede OO, Ogolo EO, Amgbesola TO (2006) Estimating net radiation using routine meteorological data at a tropical location in Nigeria. *International Journal of Sustainable Energy* 25(2):107–115
- de Jong R, Shaykewich CF, Reimer A (1980) The calculation of the Net radiation flux. *Archiv Für Meteorologie Geophysik Und Bioklimatologie Serie B* 28:353–363
- Kaminsky KZ, Dubayah R (1997) Estimation of surface net radiation in the boreal forest and northern prairie from shortwave flux measurements. *J Geophys Res* 102(D24):29707–29716
- Kjaersgaard JH, Cuenca RH, Plaunborg FL (2007) Long-term comparisons of net radiation calculation schemes. *Boundary-Layer Meteorology* 123:417–431
- Luenberger DG, Ye Y (2008) *Linear and nonlinear programming*. International Series in Operations Research & Management Science, 3rd edition. Springer, New York, 546 pp
- Monteith JL, Unsworth MH (1990) *Principles of environmental physics*. Edward Arnold, 291 pp
- Oke TR (1987) *Boundary layer climates*, 2nd edn. Routledge, London, 435 pp
- Ortega-Fariñas S, Antonioletti R, Olioso A (2000) Net radiation model evaluation at an hourly time step for Mediterranean conditions. *Agronomie* 20:157–164
- Sentelhas PC, Gillespie TJ (2008) Estimating hourly net radiation for leaf wetness duration using the Penman-Monteith equation. *Theoretical and Applied Climatology* 91:205–215
- Wang K, Liang S (2008) Estimation of surface net radiation from solar shortwave radiation measurements. 978-1-4244-2808-3-IEEE-IGARSS 2008:v483–486

**Artículo**

**“Modelling net radiation at surface using “in situ” netpyrradiometer measurements with artificial neural networks”**

*El presente artículo está publicado en la revista Expert Systems with Applications, que posee un factor de impacto de 2.203 de acuerdo con el Thomson Reuters journal citation reports 2012.*



## Modelling net radiation at surface using “*in situ*” netpyrradiometer measurements with artificial neural networks<sup>†\*</sup>

Antonio Geraldo-Ferreira<sup>a,b</sup>, Emilio Soria-Olivas<sup>c</sup>, Juan Gómez-Sanchis<sup>c,\*</sup>, Antonio José Serrano-López<sup>c</sup>, Almudena Velázquez-Blázquez<sup>d</sup>, Ernesto López-Baeza<sup>b</sup>

<sup>a</sup> Fundação Gaúcha de Meteorologia e Recursos Hídricos, Fortaleza, Grav, Brazil

<sup>b</sup> Climatology from Satellites Group, Department of Physics of the Earth and Thermodynamics, University of Valencia, Spain

<sup>c</sup> Electronic Engineering Department, E.T.S.E., University of Valencia, C/ Dr Moliner 50, 46100 Burjassot, Valencia, Spain

<sup>d</sup> Royal Meteorological Institute of Belgium, Brussels, Belgium

### ARTICLE INFO

**Keywords:**  
Neural networks  
Modelization  
Net radiation  
Radiometer

### ABSTRACT

The knowledge of net radiation at the surface is of fundamental importance because it defines the total amount of energy available for the physical and biological processes such as evapotranspiration, air and soil warming. It is measured with net radiometers, but, the radiometers are expensive sensors, difficult to handle, that require constant care and also involve periodic calibration. This paper presents a methodology based on neural networks in order to replace the use of net radiometers (expensive tools) by modeling the relationships between the net radiation and meteorological variables measured in meteorological stations. Two different data sets (acquired at different locations) have been used in order to train and validate the developed artificial neural model. The statistical results (low root mean square errors and mean absolute error) show that the proposed methodology is suitable to estimate net radiation at surface from common meteorological variables, therefore, can be used as a substitute for net radiometers.

© 2011 Elsevier Ltd. All rights reserved.

### 1. Introduction

Net radiation is a fundamental parameter that governs the climate of the lower layers of the atmosphere and it depends critically on the structure and composition of the atmosphere and the presence of clouds, in addition to surface features such as albedo, emissivity, temperature, humidity and thermal properties of the underlying soil. Thus net radiation is a fundamental quantity for analyzing the evolution of climate, from both local and global perspective. It is the driving force of physical and biological processes such as evapotranspiration, the latter being used to optimize the quality and yield of crops, water resources planning, weather forecasting, etc. (Bennie, Wiltshire, Hill, & Baxter, 2008; Ji, Kang,

Zhao, Zhang, & Jin, 2009; Li et al., 2009). Despite its importance, the net radiation is measured only in a very few number of standard weather stations because net radiometers are expensive instruments and require constant care in the field, so that the net radiation measurements can be reliable. Hence, this quantity is difficult to obtain due to the cost of net pyrradiometers. This paper presents a methodology for modeling net radiation using artificial neural networks. After an initial period collecting data in order to train the network with real samples, the neural network model can be used as an estimator of net radiation samples for a given area without using net radiometers at all times. The strategy here is to train the neural network model using the net radiation collected “*in situ*” over a representative period and then use that model and not the net radiometer. There are a large number of linear and nonlinear models who perform modeling of the net radiation at surface but using as input the incoming solar radiation or the net radiation components separately (downwelling shortwave radiation, reflected shortwave radiation, downwelling and upwelling longwave radiation). But the root of the problem remains; radiometers are needed to obtain these input variables to the model (Alados, Foyo-Moreno, Olmo, & Alados-Arboledas, 2003; Daughtry et al., 1990; Kohsiek et al., 2007). This problem can be avoided by using as input parameters, in the neural networks developed to model the net radiation at surface, the most common meteorolog-

<sup>†</sup> This work was supported by the Programme Añjan, the European Union Programme of High Level Scholarships for Latin America, scholarship no. E05D0589088R-Antonio Geraldo Ferreira and also for Remote Sensing Techniques for the Observation of Environmental Parameters in the Valencia Community Autonomous Region for 2007–2009 contract of the Department for Environment, Water, Planning and Housing, General Directorate for Climate Change, Generalitat Valenciana, also this work was supported by the Spanish Ministerio de Educación y Ciencia under grant TIN2007-61006/Apendizaje por Refuerzo Aplicado en Fama-cocinética (RIA2AP).

\* Corresponding author.

E-mail address: [juan.gomez-sanchis@uv.es](mailto:juan.gomez-sanchis@uv.es) (J. Gómez-Sanchis).

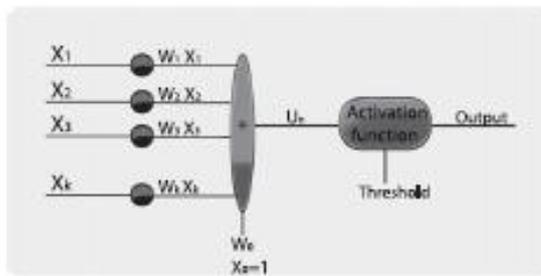


Fig. 1. Scheme of a neuron.

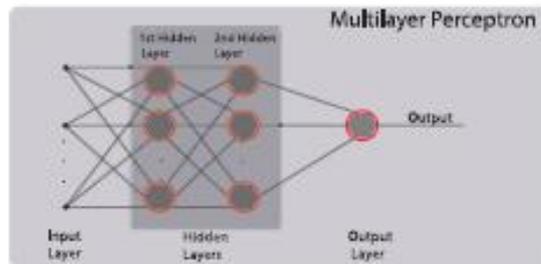


Fig. 2. Multilayer perceptron scheme. Dotted lines show the feedback in the model; in this paper this type of connections was not used.

ical variables collected in the majority of weather stations, around the world, including those that send, daily, information to the Global Telecommunication System (GTS). The GTS is defined as: *The co-ordinated global system of telecommunication facilities and arrangements for the rapid collection, exchange and distribution of observations and processed information within the framework of the World Weather Watch critegts*. These variables are: wind speed, air temperature, atmospheric pressure and humidity.

The following sections describe the neural model used, the multilayer perceptron. After this, the datasets and the variables involved in the problem will be presented. Finally, we will present the results and conclusions obtained in the study.

## 2. Multilayer perceptron

The multilayer perceptron (MLP) has been the neural network model used in this study. It consists of some individual process elements called neurons, which are arranged in a series of layers. Fig. 1 shows the structure of these neurons.

This neuron is constituted, in its first part, by a multiplier, which multiplies the inputs by a series of coefficients called synaptic weights. The objective of learning algorithm is to obtain the optimum values for the synaptic weights (Haykin, 2009). In the next part of the neuron we will find the activation function that gives nonlinear behavior to the neural network model. Fig. 2 shows the scheme of a MLP.

The number of neurons in the input and output layers is defined by the problem addressed. The user is responsible for choosing the number of hidden layers and neurons. There are many demonstrations of the fact that the multilayer perceptron with a hidden layer is an universal modelization tool of continuous functions. In the case of discontinuous functions two hidden layers are required (Reed & Marks, 1999). It is important to highlight that there are rules that guide to designer on the number of hidden neurons in each layer, however there is not work to set this number accurately. In a large number of applications a "trial and error" strategy is used in order to obtain the number of neurons in the hidden layer (Haykin, 2009).

The operation of the neural network is given by the values of synaptic weights. The learning algorithm is the procedure by which the neural model obtain the optimal parameters for solve the problem. There are many learning algorithms but, when choosing a particular one of them is necessary to consider the following features that any learning algorithm should fulfill (Bishop, 1995): Effectiveness, robustness, independence from initial conditions, high generalization ability, low computational cost and simplicity. The aim of any learning algorithm is to obtain as an error (defined



Fig. 3. (left) Net radiometer used to measure net radiation at surface in the FESEBAV experiment and (right) radiometer used at WAS that measure net radiation components separately (downwelling and reflected shortwave radiation, downwelling and upwelling longwave radiation).

Table 1

Basic statistic of FESEBAV and VAS data sets. WS: Wind speed; AT: air temperature; AP: atmospheric pressure; RH: relative humidity; RN: net radiation.

	WS (m/s)	AT (°C)	AP (mb)	RH (%)	RN (W/m <sup>2</sup> )
<b>FESEBAV (N = 13,248)</b>					
Maximum	5.05	40.05	937.00	99.30	741.30
Minimum	0.00	8.82	916.00	6.89	-73.30
Mean	1.21	21.99	926.12	54.74	144.94
Standard deviation	0.73	6.57	3.77	25.8	213.34
<b>VAS (N = 23,616)</b>					
Maximum	8.30	36.50	938.00	95.00	1011.15
Minimum	0.00	4.00	914.00	8.00	-114.2
Mean	1.90	19.50	925.44	53.89	136.96
Standard deviation	1.42	6.07	4.06	21.78	244.34

as the difference between actual signal and the neural network output) a value of zero. There are two different kinds of algorithms (Haykin, 2009):

- **On-line.** In this type of learning, error is calculated by the neural network model for each pattern in the data set. The synaptic weights are updated using the error of each pattern.
- **Batch.** In this type of learning, error is calculated by the neural network model for all patterns. After this, the synaptic weights are updated using the average error for all patterns.

The learning algorithm used in this paper has been Levenberg–Marquart algorithm which presents a good compromise between speed of convergence, steady-state error and complexity (Bishop, 1995; Haykin, 2009). Random synaptic weights have been used for each architecture in order to avoid the problem of local minima; the authors have initialized 100 times each neural architecture.

### 3. Data sets

In order to validate our approach were used two data sets obtained from two surface areas with the same land use (vineyard crop) but with different land cover (vineyard and bare soil). Methodology and sensors employed to data collection are described below.

- **Data set 1 (FESEBAV).** The first data set corresponds to data collected during the field campaign called FESEBAV 2007 (*Field Experiment on Surface Energy Balance Aspects over the Valencia Anchor Station area*) conducted from June 19th to September 18th 2007. In this experiment a mobile weather station (EMM) was installed in a field of vines (latitude 39° 31' 23"N and de longitude 1° 17' 22" W, at an altitude of 796 m above sea level), in the study area of the Valencia Anchor Station (VAS), near the town of Caudete de las Fuentes (Utiel-Plana de Requena), Valencia, Spain, with the goal of collecting the data necessary for the surface energy balance studies of the crops. The net radiation was measured with a CN1 Net Pyradiometer (Middleton & Co. Pty. Ltd.), air temperature with a probe PT 100/3 (Campbell Scientific Ltd.), the relative humidity with a probe HMP45C (Campbell Scientific Ltd.) and wind speed with an anemometer RM Young 05103 (R.M. Young Company). All sensors were installed at 2 m over the surface, except for the wind that was set to 2.10 m. The sensors were integrated into Campbell CR1000 datalogger and were scheduled to collect data every second. The data recorded every second was stored as 10 min averages.
- **Data set 2 (VAS).** The second data set was obtained at the meteorological station known as VAS (latitude 39° 34' 15" N and longitude 1° 17' 18" W, lying at an altitude of 813 m above sea level), a reference meteorological station used to calibrate and

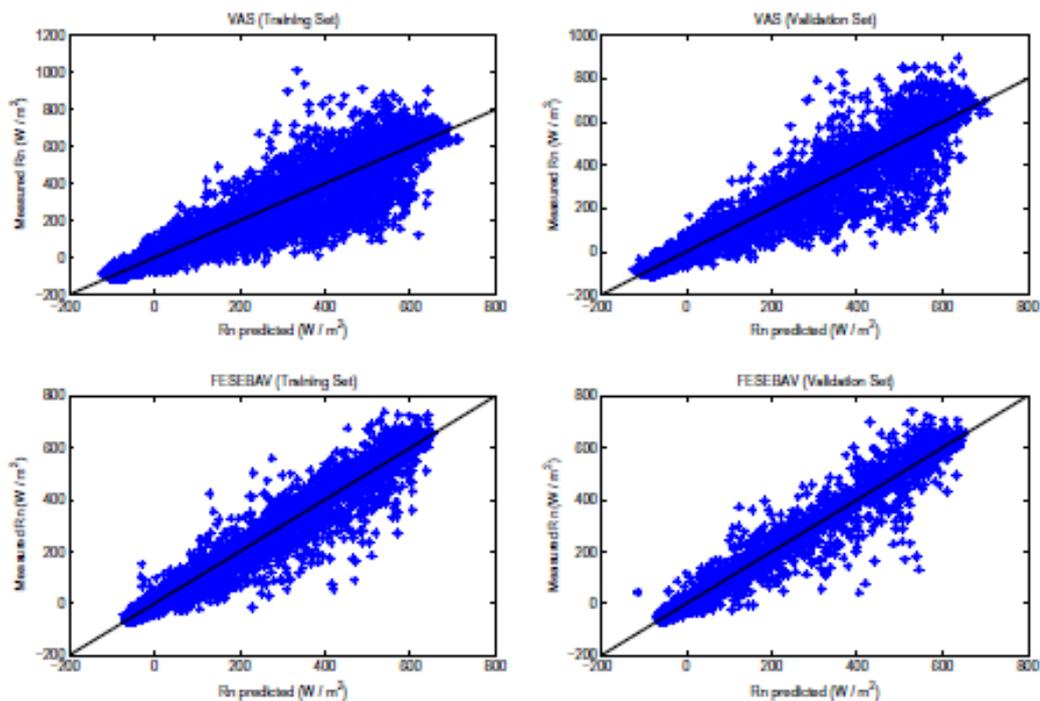


Fig. 4. Representation of net radiation predicted by the neural network model and the actual values of net radiation. In the same graphs we can see the linear regression in both data sets.

**Table 2**  
Performance indices for FESEBAV data set.

FESEBAV data set	MAE ( $W/m^2$ )	RMSE ( $W/m^2$ )	ME ( $W/m^2$ )	a	b
Training set $N = 8832$	19.46	35.56	-0.38	0.97	3.73
Validation set $N = 4416$	21.65	39.88	0.027	0.97	4.46

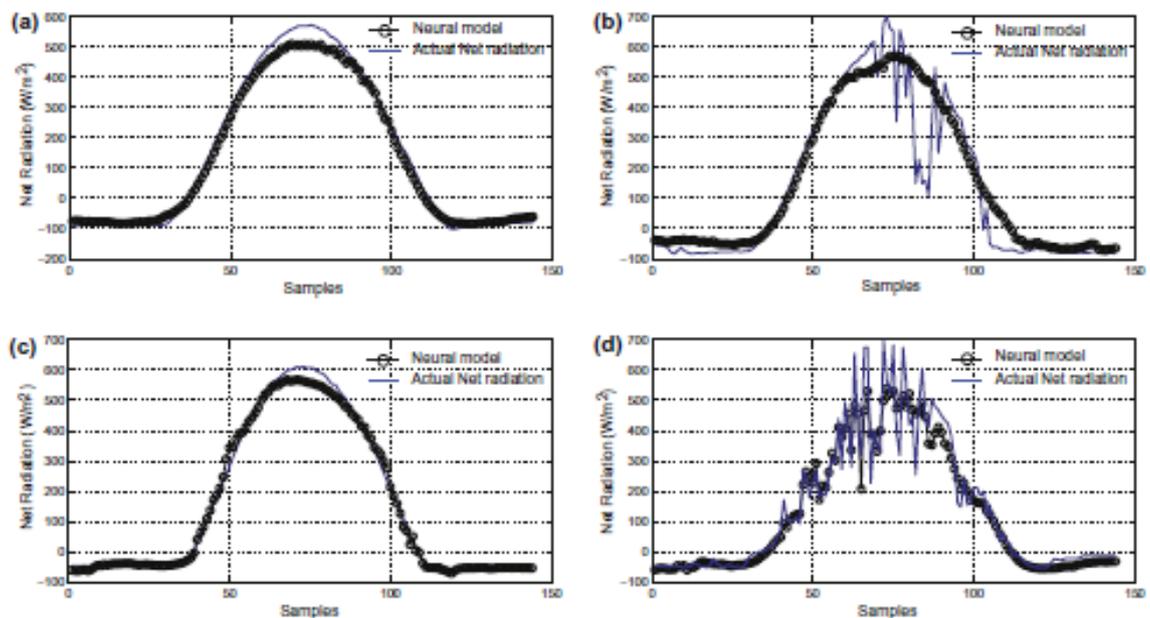
**Table 3**  
Performance indices for VAS data set.

VAS data set	MAE ( $W/m^2$ )	RMSE ( $W/m^2$ )	ME ( $W/m^2$ )	a	b
Training set $N = 15,744$	34.55	61.36	0.65	1.00	0.30
Validation set $N = 7872$	36.47	65.07	-0.26	0.99	0.46

validate remote sensing missions low spatial resolution. The station is installed in an isolate characterized by bare soil and surrounded by vineyards. Details on the VAS and meteorological parameters listed can be obtained at <http://www.uv.es/anchors/Estacion.html>. VAS data used in the study are those relating to the months of May, June and July 2007 and 2008. Wind speed is measured with a sensor model 03102 (Campbell Scientific Ltd.), temperature and humidity with a probe model 50U-44212 (Vaisala, USA), atmospheric pressure is measured with a sensor SPA-900 (Druck Limited, USA), incoming shortwave radiation and reflected solar radiation was measured with an Albedometer CM14 (Kipp & Zonen, Netherland), upwelling and downwelling of longwave radiation was measured with a pyrgeometer (CG2) (Kipp & Zonen, Netherland). These sensors are installed at 2 m over the surface. In this case the dataloggers employed were IIA Geonics, and the measurements were acquired in the same way that in data set 1. Fig. 3 show the radiometers used to measure the net radiation directly (left) or its components separately (right).

**4. Results**

In order to obtain the best neural network model, the models were trained using two hidden layers (by the Cybenko theorem it is known that two layers are necessary to establish the relationships between two data sets (Haykin, 2009)). The number of hidden neurons in each layer was varied from 2 to 20, these limits were imposed because, in all the tests, never reached the upper limits for the number of neurons using cross-validation. Moreover, since the learning algorithm is a local search algorithm on each architecture, there were a total of 100 different initializations of synaptic weights in order to avoid the problem of local minima (Bishop, 1995). The Levenberg-Marquadt algorithm was chosen using online learning because it is most appropriate in time series modeling problems. Furthermore, cross-validation was used in order to avoid the overfitting problem (Haykin, 2009). For this purpose the data set 1 and data set 2 were divided into two subsets, one for train the models (training set) and other for validate the models (validation set). The proportion selected for this division



**Fig. 5.** Measured  $R_n$  values (—) and neural model prediction (---) for: (a) cloudy free-day, 2-7-2007, VAS data set; (b) cloudy day, 21-5-2007, VAS data set; (c) cloudy free-day, 15-8-2007, FESEBAV data set; (d) cloudy day, 26-6-2007, FESEBAV data set.

**Table 4**  
Performance indices in sunny/cloudy days.

	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	ME (W/m <sup>2</sup> )
<i>FESEBAV data set</i>			
Cloudy days <i>N</i> = 8784	24.74	43.85	0.44
Sunny days <i>N</i> = 4464	11.41	17.21	-1.17
<i>VAS data set</i>			
Cloudy days <i>N</i> = 17,712	41.64	71.46	-0.34
Sunny days <i>N</i> = 5904	15.84	22.38	2.41

were 2/3 and 1/3 of each set. The input variables used to train the model were: month, day and hour of the measures (temporal information) and, wind speed, air temperature, air pressure and humidity of the air (meteorological variables). The output or target variable was net radiation. Table 1 shows the statistics of the input and output variables statistics in each analyzed data set.

The criterion used for choose the best neural model was that based on the lowest value of the mean absolute error, MAE, in the validation set, this index has been used because it is more robust to outliers than the RMSE (Root Mean Square Error). Fig. 4 shows the representation of net radiation predicted by the neural network model and the actual values of net radiation for the two stations (FESEBAV and VAS) and for training and validation sets.

Tables 2 and 3 show the statistical results obtained for the two sets using the best neural model. In these tables the values of MAE, RMSE and mean error (ME, which give an indication of possible bias on the model) can be seen. The indexes (slope and intercept) of linear regression between the measured net radiation values and the network output (the parameter *a* define the slope of the adjustment, and must be close to 1 and the parameter *b* also gives an idea of possible bias on model).

One possible source for the difference between MAE and RMSE obtained for the two sets, shown in Tables 2 and 3, is due to the quickly and high variation, in a short period of time, in net radiation that occur on specific days due to presence of clouds, mainly in the second set (VAS). In VAS dataset, the months of May and June 2008 were those in which net radiation values registered were higher than 800 W/m<sup>2</sup>, reaching up to 1011.15 W/m<sup>2</sup>, while

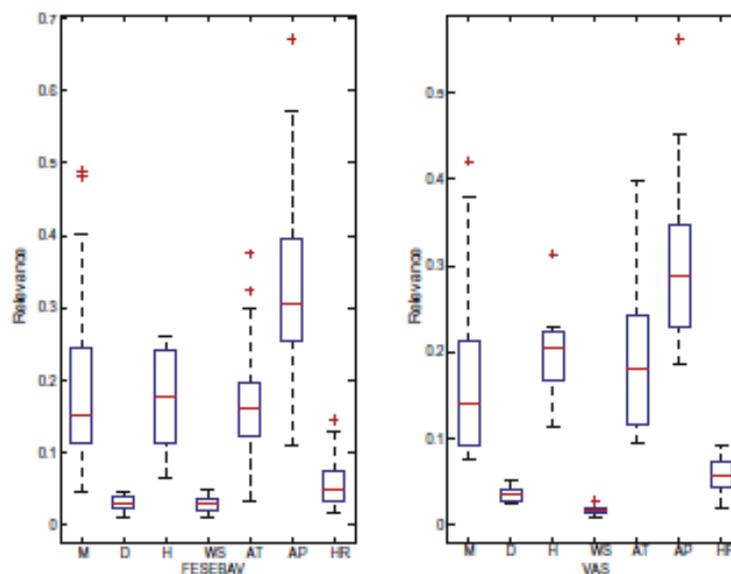
in FESEBAV dataset, the maximum net radiation value was 741.30 W/m<sup>2</sup> (see 4). Despite this difference, the errors obtained show that neural networks can be used as substitute for radiometers, mainly in clear days, because the prediction errors committed by neural networks can be assumed in the net radiation estimation (Alados et al., 2003; Carrasco & Ortega-Farías, 2008).

Fig. 5 shows the values of net radiation for sunny days (in these cases are regular profiles of net radiation) and others with cloudy sky (irregular profiles) for the two data sets. The same figure shows the prediction of neural models. It is found that the diurnal cycle of net radiation, in cloudy days, have highly irregular shape, so the prediction is quite difficult in these days; in fact most of the errors committed by the model came from these days.

Table 4 shows the difference between the predictions in cloudy days and cloudy free-days.

After evaluate the performance of the neural models using different error rates, the next step was assess the model running through a sensitivity analysis (Gomez et al., 2006) to obtain the most important variables for the model. This kind of analysis has two objectives: (a) check the validity of the conclusions derived from the model; these conclusions should be consistent with the physical theory and (b) obtain new qualitative understanding of the problem. In order to do it the variation in the model output is determined when considering or not determined input variable. If the variation is small it means that the input variable is not very important to obtain the net radiation (the output variable). In another case, if there is much difference in the model output, take into account a specific input variable, or removing it, it means that this variables is very important to the problem. The sensitivity analysis of the model was determined in a experimental procedure. In the first step was choosing the better 25 neural models. After that the input variables, for both, FESEBAV and VAS data set, were arranged in each model by its importance. Finally a boxplot of the input variables position in each of the 25 models is made, Fig. 6.

Fig. 6 shows that the most important variables for the neuronal model are: atmospheric pressure, month, hour and air temperature. However the relevance of a variable sometimes can be masked by other correlated variable, and the atmospheric pressure



**Fig. 6.** Relevance of input variables. The inputs are: Month (M), Day (D), Hour (H), wind speed, air temperature, atmospheric pressure and relative humidity.

and air temperature are correlated variables. But it is important highlight that the net radiation at surface depends on surface atmospheric pressure rather than air temperature. Atmospheric pressure is a parameter that is strongly correlated with cloud cover (low pressure indicates more clouds and high pressure indicates less cloud). Thus, atmospheric pressure is an important variable in the radiation balance at the surface because the shortwave and longwave radiation at surface are strongly dependent on cloud cover fraction (Meetschen, van den Hurk, & Drusch, 2004).

### 5. Conclusions

Net radiation measure is important for the analysis and study of climate, but the devices used to do this are very expensive and difficult to manage requiring further constant care in the field. This paper demonstrates the ability of neural models to replace the use of radiometers for the measurement of surface net radiation. Using neural models and conventional weather variables can be estimated net radiation with an acceptable error without using expensive and costly radiometers. A sensitivity analysis has been carried out in order to obtain the importance of the variables and has been demonstrated that the neural model are valid from a qualitative point of view (its quantitative performance has been demonstrated using error measures). The conclusions drawn about the importance of the variables have physical meaning and agrees with the theory about that.

### References

- Alados, L., Foyo-Moreno, I., Olmo, F. J., & Alados-Arboledas, L. (2003). Relationship between net radiation and solar radiation for semi-arid shrub-land. *Agricultural and Forest Meteorology*, 116(3–4), 221–227.
- Bennie, B. H. J., Wiltshire, A., Hill, M. O., & Baxter, R. (2008). Slope, aspect and climate: Spatially explicit and implicit models of topographic microclimate in chalk grassland. *Ecological Modelling*, 216(1), 47–59.
- Bishop, C. (1995). *Neural networks for pattern recognition*. Clarendon Press.
- Carriaco, M., & Ortega-Farías, S. (2008). Evaluation of a model to simulate net radiation over a vineyard cv. Cabernet Sauvignon. *Chilean Journal of Agricultural Research*, 68, 156–165.
- Daughtry, C., Kustas, W., Moran, M., Huter, P., Jackson, R., Brown, P., et al. (1990). Spectral estimates of net radiation and soil heat flux. *Remote Sensing of Environment*, 32, 111–124.
- Gomez, J., Martín, J. D., Soría, E., Vila, J., Carriaco, J. L., & del Valle, S. (2006). Neural networks for analysing the relevance of input variables in the prediction of tropospheric ozone concentration. *Atmospheric Environment*, 40, 6173–6180.
- Haykin, S. (2009). *Neural networks and learning machines*. Prentice-Hall.
- Ji, X., Kang, E., Zhao, W., Zhang, Z., & Jin, B. (2009). Simulation of heat and water transfer in a surface irrigated, cropped sandy soil. *Agricultural Water Management*, 96(6), 1010–1020.
- Kohlerik, W., Liebethal, C., Foken, T., Vogt, R., Oncley, S., Benschhof, C., et al. (2007). The energy balance experiment ehe-s-2000. Part II: Behaviour and quality of the radiation measurements. *Boundary-Layer Meteorology*, 123(1), 55–75.
- Li, S., Tong, L., Li, F., Zhang, L., Zhang, B., & Kang, S. (2009). Variability in energy partitioning and resistance parameters for a vineyard in northwest china. *Agricultural Water Management*, 96(6), 955–962.
- Meetschen, F. A. D., van den Hurk, B. J. J. M., & Drusch, M. (2004). Optimized surface radiation fields derived from meteosat imagery and a regional atmospheric model. *Journal of Hydrometeorology*, 5(6), 1091–1101.
- Ried, R. D., & Markis, R. J. (1999). *Neural smelting: Supervised learning in feedforward artificial neural networks*. MIT Press.