



Universidad de Valladolid

FACULTAD DE CIENCIAS

DEPARTAMENTO DE FÍSICA APLICADA

TESIS DOCTORAL:

**MEDIDA Y MODELIZACIÓN DE LOS FLUJOS DE
ENERGÍA Y CO₂ EN UNA PARCELA AGRÍCOLA
EN CASTILLA Y LEÓN**



Presentada por Nuria Pardo Gómez para optar al grado
de doctora por la Universidad de Valladolid

Dirigida por:
M^a Luisa Sánchez Gómez

Valladolid, 2015

MEDIDA Y MODELIZACIÓN DE LOS FLUJOS DE ENERGÍA Y CO₂ EN UNA PARCELA AGRÍCOLA EN CASTILLA Y LEÓN



NURIA PARDO GÓMEZ

Grupo de Contaminación Atmosférica

Universidad de Valladolid



Este trabajo de tesis doctoral ha sido realizado en el marco del Proyecto CGL2009-11979:

“Medida y modelización de los flujos de CO₂ en un cultivo de colza en Castilla y León”,

dentro del subprograma de Formación de Personal Investigador –FPI– (beca BES-2010-039319) financiado por el Plan Nacional de Investigación Científica, Desarrollo e Innovación Tecnológica (I+D+i) 2008-2011 del Ministerio de Economía y Competitividad (MINECO) de España –antiguo Ministerio de Ciencia e Innovación, MICINN– y cofinanciado con fondos FEDER de la Comunidad Europea.

El estudio se ha desarrollado en el grupo de investigación reconocido (GIR) de Contaminación Atmosférica (GCA), en el departamento de Física Aplicada de la Facultad de Ciencias de la Universidad de Valladolid.

Agradecimientos/Acknowledgements

This thesis has been developed in the framework of the project CGL2009-11979 and the pre-doctoral scholarship BES-2010-039319 supported by the Spanish Ministry of Science and Innovation (MICINN), and co-financed by FEDER funds, carried out at the Applied Physics department of the Valladolid University. I would like to acknowledge these institutions for their support and financial contribution.

El desarrollo de esta tesis ha estado bajo la supervisión de la Dra. Maria Luisa Sánchez Gómez, a quien debo agradecer en primer lugar la confianza depositada en mí para la realización de este proyecto, permitiéndome unirme al Grupo de Contaminación Atmosférica (GCA), el cuál dirige. También agradecerle su ayuda durante todo el desarrollo de la tesis, sus consejos y valoraciones.

Debo agradecer también a mis compañeros en el GCA, Isidro y M^a Angeles, por su paciencia, ayuda y ánimo constante. Gracias por resolver mis dudas cuando surgían y ofrecerme apoyo todo este tiempo.

Otros compañeros del GCA y del departamento de Física Aplicada que también deben ser mencionados en este apartado de agradecimientos son Vanessa, Beatriz, Pablo, Javier y Carlos. A Carlos agradecer la ayuda en la parte técnica y experimental, ofreciendo apoyo y/o resolviendo cualquier problema relacionado con la instrumentación, lo cual es inevitable cuando la instrumentación se encuentra expuesta a las inclemencias de las condiciones meteorológicas y animales varios.

El agradecimiento oportuno debe ir también al dueño de la finca Monte de Rocío, Jerónimo Alonso, donde la parte experimental de esta tesis se ha desarrollado. Sin su colaboración y ofrecimiento desinteresado de la parcela, este proyecto no habría sido posible.

I would like to thank the ITC, and particularly Z. Su, for making possible a short stay at the WRS department at ITC in Enschede. Moreover, I wish also to thank all the people at ITC who supported me (sorry if I forget someone): Chandra, Enrico, Mustafa, Tolga, Fouad, Yjian, Xuelong, Christian, Leonardo, Anke, Tina, and so many people there. Particularly, I greatly appreciate the help and support of Mireia and Joris, who both shared their office and knowledge with me.

Finally, I greatly appreciate the contribution of those organizations which provided us with the remote sensing and meteorological data used in several parts of this thesis: The Environmental Space Agency –ESA– for the MERIS images obtained in the framework of a CAT 1 project; The National Aeronautics and Space Administration –NASA– for the free supply of MODIS and AMSR-E images; and The European Centre for Medium-Range Weather Forecast –ECMWF– whose meteorological data were employed.

Tabla de contenido

Agradecimientos/Acknowledgements	7
Tabla de contenido	9
ACRONYMS.....	13
List of Figures	17
List of Tables	23
CAPÍTULO 1. INTRODUCCIÓN	25
1.1 Antecedentes y motivación	27
1.2 Ciclos biogeoquímicos y flujos de carbono.....	33
1.3 Eficiencia y modelos de simulación.....	34
1.4 Objetivos	38
1.5 Estructura de la Tesis	40
CAPÍTULO 2. ZONA DE ESTUDIO Y METODOLOGÍA	43
2.1 Introducción.....	45
2.2 Descripción general	45
2.3 Descripción del lugar de medida	51
2.4 Instrumentación	54
2.5 Climatología	60
2.6 Procesado de los datos EC.....	68
CAPÍTULO 3. BALANCE DE ENERGÍA.....	71
Resumen	73
Abstract.....	76
3.1 Introduction	77
3.2 Material and methods	79
3.2.1 Measuring site	79
3.2.2 Instrumentation and data	82
3.2.3 Methodology	84
3.3 Results and discussion	86

3.3.1	Description of the behavior of energy fluxes	86
3.3.2	Energy balance closure.....	89
3.3.3	Analysis of the main sources of lack of energy balance closure	93
3.3.4	Energy partitioning	97
3.4	Conclusion	103
CAPÍTULO 4. SEBS. MODELO DE UNA FUENTE		105
	Resumen	107
	Abstract.....	110
4.1	Introduction	111
4.2	Measuring site	114
4.3	Instrumentation and data	116
4.3.1	Experimental instrumentation.....	116
4.3.2	Remote sensing products and meteorological data.....	117
4.3.3	Data resolution	117
4.4	SEBS methodology	118
4.4.1	SEBS formulation	118
4.4.2	SEBS approaches/modifications	121
4.5	Results and discussion	122
4.5.1	Validation of external products	122
4.5.2	Intercomparison of R_n and G	127
4.5.3	Intercomparison of H , LE and EF	131
4.6	Conclusion	140
CAPÍTULO 5. GPP Y MODELO LUE.....		143
	Resumen	145
	Abstract.....	148
5.1	Introduction	150
5.2	Material and methods	153
5.2.1	Site description	153
5.2.2	Eddy covariance and meteorological data.....	153
5.2.3	Ancillary data (LAI).....	155
5.2.4	Remote sensing data	155
5.2.5	Model approach.....	156

5.2.6	Statistical analysis	158
5.3	Results	159
5.3.1	Meteorological driving variables	159
5.3.2	Stress indexes	162
5.3.3	FPAR MODIS retrievals	163
5.3.4	GPP-LUE model results	164
5.3.5	Inter-comparison between GPP and GPP MODIS retrievals	167
5.4	Discussion of the results.....	171
5.4.1	GPP	171
5.4.2	Maximum Light Use Efficiency, ϵ_0	174
5.4.3	Calibration of FPAR _{MODIS} using LAI ground measurements	176
5.5	Conclusions	179
CAPÍTULO 6. CONCLUSIONES		183
6.1	Conclusiones (español).....	185
6.2	Conclusions (english)	190
BIBLIOGRAFÍA		195
Curriculum Vitae.....		219
APÉNDICE I		223
APÉNDICE II		227

ACRONYMS

AATSR	Advanced Along-Track Scanning Radiometer
AEMET	Agencia Estatal de Meteorología - Spanish Meteorological Agency
AMSR-E	Advanced Microwave Scanning Radiometer for EOS
CIBA	Centro de Investigación de la Baja Atmósfera
CUE	Carbon Use Efficiency
EC	Eddy Covariance
EF	Evaporative Fraction
ECMWF	European Centre for Medium-Range Weather Forecasts
ESA	European Space Agency
FPAR	Fraction of Absorbed Photosynthetic Active Radiation (fAPAR)
GCA	Grupo de Contaminación Atmosférica - Group of Atmospheric Contamination
GHG	Greenhouse Gases
GMT	Greenwich Mean Time

GPP	Gross Primary Production
IDECYL	Infraestructura de Datos Espaciales de Castilla Y León
INE	Instituto Nacional de Estadística
IPCC	Intergovernmental Panel on Climate Change
IRGA	InfraRed Gas Analyzer
JCYL	Junta de Castilla y León
LAI	Leaf Area Index
LST	Land Surface Temperature
LUE	Light Use Efficiency
MAE	Mean Absolute Error
MAGRAMA	Ministerio de AGricultura, Alimentación y Medio Ambiente
MERIS	MEdium Resolution Imaging Spectrometer
MIP	Maximum Interest Period
MODIS	MODERate resolution Imaging Spectroradiometer
NASA	National Aeronautics and Space Administration
NBP	Net Biome Production/Productivity
NDVI	Normalized Difference Vegetation Index

NEE	Net Ecosystem Exchange
NEP	Net Ecosystem Production
NOAA	National Oceanic and Atmospheric Administration
NPP	Net Primary Production
NUE	Nitrogen Use Efficiency
PAR	Photosynthetically Active Radiation
PEM	Production Efficiency Models
PNOA	Plan Nacional de Ortofotografía Aérea
PPFD	Photosynthetic Photon Flux Density
RMSE	Root Mean Standard Error
RMSD	Root Mean Standard Deviation
RUE	Radiation Use Efficiency
SEBS	Surface Energy Balance System
SD	Standard Deviation
SIGPAC	Sistema de Informacion Geográfica de Parcelas Agrícolas
UNEP	The United Nations Environment Programme
UVA	University of Valladolid
WMO	World Meteorological Organization
WUE	Water Use Efficiency

List of Figures

Figura. 1.1. Curva de Keeling. El gráfico muestra los cambios estacionales (rojo) en las concentraciones de CO₂ y la continua tendencia de aumento (línea) para este gas, en el observatorio de Mauna Loa (Hawai). El gráfico muestra valores actualizados a fecha de mayo de 2015 obtenidos de la web de la NOAA (<http://www.esrl.noaa.gov/gmd/ccgg/trends/index.html>).....28

Figura 2.1. Evolución de la superficie destinada a los dos principales usos de suelo (forestal y agrícola) en Castilla y León para el periodo 1990-201246

Figura 2.2a. Evolución de la producción y la superficie destinada a su siembra en Castilla y León para la colza y el trigo. Elaboración a partir de los datos contenidos en los diferentes anuarios estadísticos publicados por el MAGRAMA49

Figura 2.2b. Evolución de la producción y la superficie destinada a su siembra en Castilla y León para los guisantes y el centeno. Elaboración a partir de los datos contenidos en los diferentes anuarios estadísticos publicados por el MAGRAMA50

Figura 2.3. Localización geográfica de la zona de estudio en la región de Castilla y León en España (izq.). Mapa elaborado por el Plan Nacional de Ortofotografía Aérea (der.), PNOA, de máxima resolución elaborado por el IDECYL (<http://www.idecyl.jcyl.es/hac/6/VCIG/Login.ini>).....53

Figura 2.4. Imágenes obtenidas a partir del Sistema de Información Geográfica de Parcelas Agrícolas (SIGPAC, <http://sigpac.mapa.es/fega/visor/>). Ministerio de Agricultura, Alimentación y Medio Ambiente (MAGRAMA) y Junta de Castilla y León (JCYL). Foto aérea tomada en junio de 2008 (izq.) y en julio de 2011 (der.). Situación de la parcela antes (izq.) y después de la cosecha y hasta la siguiente siembra (der.).....53

Figura 2.5. Torres meteorológica (izq.) y micrometeorológica (der.) instaladas en la parcela de medida54

Figura 2.6. Diagrama de funcionamiento del IRGA	58
Figura 2.7. Secuencia de medición del LAI	59
Figura 2.8a. Reparto mensual de las precipitaciones acumuladas y de las temperaturas promedio del aire y del suelo para todo el periodo de medidas	63
Figura 2.8b. Reparto mensual de las precipitaciones acumuladas y evolución del contenido de humedad del suelo en comparación con la precipitación mensual acumulada	63
Figura 2.9. Distribución de la dirección y velocidad de viento para la parcela de medida. Datos promediados para todo el periodo de medidas comprendido entre 2008-2011.....	64
Figura 2.10. Promedios mensuales de PAR/PPFD para valores diurnos (no se ha tenido en cuenta valores nocturnos de 0) para el periodo de medidas	64
Figura 2.11a. Comparativa de la precipitación total acumulada, para cada uno de los cuatro años de medidas, con respecto al dato promedio de la precipitación acumulada para un periodo de 35 años en Valladolid obtenido de datos registrados por la AEMET.....	66
Figura 2.11b. Comparativa de la temperatura del aire experimental, en promedios anuales para el periodo de medidas, y el valor promedio para un periodo de 35 años de la temperatura del aire obtenido para Valladolid a partir de datos de la AEMET.....	66
Figura 2.12a. Evolución temporal de los datos históricos elaborada a partir de los registros de la AEMET para la estación de Villanubla para la precipitación anual acumulada	67
Figura 2.12b. Evolución temporal de los datos históricos elaborada a partir de los registros de la AEMET para la estación de Villanubla para la temperatura media anual.....	67
Figura R.3.1. Evolución horaria de los valores promedios para el periodo de medidas de cuatro años para la radiación y el resto de flujos de energía	75

Figura R.3.2. Evolución mensual de los valores promedios para el periodo de medidas de cuatro años para la radiación y el resto de flujos de energía	75
Figure 3.1. Full Landcover map (MODIS product MCD12Q1) of Spain taken from tiles (h17v04, h17v05, h18v04 and h18v05) covering the whole country. Orange colour, surrounding the measuring site, indicates croplands.....	80
Figure 3.2. Meteorological diagram for the 2008-2011 period, where the cumulative monthly precipitation ($P_{monthly}$), and the average monthly air (T_{air_aver}) and soil (T_{soil_aver}) temperatures are displayed.....	81
Figure 3.3. Energy balance components (ensemble-average) behavior for years from 2008 to 2011. a) Hourly average pattern. b) Average monthly course. G indicates the total soil flux calculated by adding the soil heat flux (G_p) measurements and the calculated (Eq. 3.4) soil heat storage (G_s)....	88
Figure 3.4. The energy balance closure for half-hourly values including years from 2008 to 2011, using: a) G_p including the whole study period, b) G_p considering the MIP, c) G_s and G_p including the whole study period, and d) G_s and G_p considering the MIP.....	91
Figure 3.5. Seasonal pattern of the energy balance closure calculated by Eq. 3.2 (slope_ G_p) and Eq. 3.3 (slope_ G)	97
Figure 3.6. The energy partitioning for the whole four-year period and for each single year including the entire year or the MIP only. H , LE , and G denote the energy partitioning ratios H/R_N , LE/R_N , and G/R_N , respectively, considering the whole yearly period. H_{MIP} , LE_{MIP} , and G_{MIP} denote the energy partitioning ratios H/R_N , LE/R_N , and G/R_N , respectively, considering the MIP period.....	98
Figure 3.7. Monthly energy partitioning for the whole study period. Growth stages of the various crops are delimited by a box, while fallow period is outside of these boxes	102

Figura R.4.1. Intercomparación, para el caso del calor sensible, entre los datos experimentales (H_{exp}) y los obtenidos mediante la aplicación del modelo SEBS-0 (H_{SEBS}) para el periodo total de medidas cubriendo los cuatro años y cultivos..... 109

Figura R.4.2. Intercomparación, para el caso del calor latente, entre los datos experimentales (LE_{exp}) y los obtenidos mediante la aplicación del modelo SEBS-NDVI (LE_{SEBS}) para el periodo total de medidas cubriendo los cuatro años y cultivos. 109

Figure 4.1 Geographical location of the study site located in the region of Castilla y León in Spain..... 115

Figure 4.2. Correlation between observed data with those retrieved by the SEBS algorithm for a) air temperature and b) soil/surface temperature.. 125

Figure 4.3. Time series of soil moisture from 2008 to 2011. The graph represents observed data (solid line) and SEBS retrieved (from AMSR-E, dashed line). 126

Figure 4.4 Yearly pattern of net radiation, R_n , for observed values and SEBS calculated. Only observed and modelled_SEBS appear in the graph since modifications in the algorithm do not effect these variables. 130

Figure 4.5 Yearly pattern of ground soil heat flux, G , for observed values and SEBS calculated. Only observed and modelled_SEBS appear in the graph since modifications in the algorithm do not effect these variables. 130

Figure 4.6 The seasonal dynamics of observed H (solid line) and that calculated by the SEBS model using the original algorithm (SEBS-0, dotted line) and the two modified codes, one with soil moisture (SEBS-SM, dash-point line) and the other taking into account the NDVI and the T_{surf} (SEBS-NDVI, dashed line). 135

Figure 4.7 Yearly patterns of the latent heat for ground-based measurements and calculated by the SEBS model using the original algorithm (SEBS-0) and the two modified codes, one with soil moisture (SEBS-SM) and the other taking into account NDVI and T_{surf} (SEBS-NDVI) 136

Figure 4.8 Seasonal variation of EF for observed data and that calculated by the SEBS model using the original algorithm (SEBS-0) and the two modified codes, one with soil moisture (SEBS-SM) and the other taking into account NDVI and T_{surf} (SEBS-NDVI). 137

Figura R.5. Evolución estacional de la GPP y el NEE observados experimentalmente para el periodo de medidas completo abarcando el estudio de los cuatro diferentes cultivos/años 147

Figure 5.1. a) Seasonal patterns of air Temperature, T , and PAR for each crop type. b) Seasonal patterns of rainfall, R , and soil moisture, SM , for each crop type. Rapeseed, wheat, peas and rye were seeded in 2008, 2009, 2010 and 2011, respectively. Data in both Figures refer to 8-d composites. X bottom and top axes show the date and DOY, respectively 161

Figure 5.2. a) Seasonal patterns of stress indexes, evaporative fraction, EF , temperature, T_s and their product, f_{LUE} , for each crop type. b) Seasonal patterns of $FPAR_{MODIS}$ and $FPAR_{RMODIS}$ retrievals for each crop type. c) Seasonal patterns of GPP observed, GPP_{LUE} and GPP_{MODIS} calibrated retrievals for each crop type. Black dots indicate partly cloudy days during growing season, GS . Rapeseed, wheat, peas and rye were seeded in 2008, 2009, 2010 and 2011, respectively. Data in all Figures refer to 8-d composites. X bottom and top axes show the date and DOY, respectively 166

Figure 5.3. Linear fit of observed GPP versus modelled G_{APAR} for each crop type. Red, green, pink and blue symbols correspond to rapeseed, wheat, peas and rye, respectively, seeded in 2008, 2009, 2010 and 2011. The black line shows the overall linear fit for rapeseed, wheat, and rye..... 170

Figure 5.4. Linear fit of observed GPP versus GPP_{MODIS} 8-d composites for each crop type. Red, green, pink and blue symbols correspond to rapeseed, wheat, peas and rye, respectively, seeded in 2008, 2009, 2010 and 2011. The black line shows the overall linear fit for rapeseed, wheat, and rye.. 170

Figure 5.5. Linear fit of ground based LAI versus LAI_{MODIS} 8-d composites. The black line shows the overall linear fit for rapeseed, wheat, and rye. Red, green, and blue symbols show the individual data for each crop type 178

Figure 5.6. Linear fit of optimal light use efficiency, ϵ_{0N} , versus canopy height, h . ϵ_{0N} values correspond to those obtained with the LUE model using recomputed FPAR_{RMODIS} input data derived from LAI ground data. Dotted lines are the confidence intervals at 95% significance level. 178

Figure 5.7. Flow chart of the methodology followed in the estimation of the maximum light use efficiency..... 181

Figura A1. Diagrama de flujo que muestra la interrelación entre los diferentes flujos de CO₂ descritos en este apéndice. 226

List of Tables

Table 3.1. Linear regression parameters for the energy balance closure calculated by applying Eq. 3.2 and Eq. 3.3. Units of the intercept, b , are $W\ m^{-2}$. The slope, a , indicates the closure in the energy balance calculated from the 30-min average values92

Table 4.1. Summary of the remote sensing products used by SEBS 126

Table 4.2. Summary of the linear regression parameters and statistics for the relationship between observed data and SEBS results using the original SEBS (SEBS-0) algorithm and the two modifications; SEBS-SM and SEBS-NDVI..... 138

Table 4.3. Summary of fitting equations and correlation coefficients found between observed values (y) and SEBS-modelled results (x) for each single year for R_n , G , energy fluxes and EF for the original SEBS algorithm (SEBS-0) and the two modifications: SEBS-SM and SEBS-NDVI. It should be noticed that results for R_n and G are common for all the approaches of the algorithm. 139

Table 5.1. Time of seed and harvest, maximum canopy height, H and maximum ground-based LAI, LAI, for each type of crop..... 159

Table 5.2. Optimal light use efficiency, ϵ_0 , intercept, a , determination coefficient, R^2 , mean absolute error, MAE, and root mean square error, RMSE, for each crop type, rapeseed, wheat, peas and rye, seeded in 2008, 2009, 2010 and 2011. LUE and MODIS subscripts refer to the results of the LUE model and GPP_{MODIS} 8-d retrievals, respectively 169

CAPÍTULO 1. INTRODUCCIÓN

1.1 Antecedentes y motivación

En base a la multitud de estudios e indicadores evaluados relacionados con el cambio climático, cada vez es más evidente una alteración en el clima global. Las primeras conjeturas sobre los posibles efectos adversos de las elevadas concentraciones de CO₂ en la atmósfera no son recientes en contraposición a lo que pueda parecer debido a la actualidad del tema. No en vano, ya en el S.XIX, Svante Arrhenius y otros autores afirmaron que un aumento en las concentraciones de CO₂ conllevaría a la larga en un incremento de la temperatura (e. g., Crawford, 1997; Govind et al., 2015; <http://www.aip.org/history/climate/co2.htm>). Estas afirmaciones no recalaban demasiado en la opinión científica debido a la poca fiabilidad de los datos con los que contaban. Con motivo de la celebración del Año Geofísico Internacional (1957-1958), se aprobó la instalación de una estación de muestreo localizada en Mauna Loa (Hawai) a 3300 m de altitud. A esta altitud el aire está completamente mezclado y además se evitan conflictos en los muestreos debido a la contaminación local (Seoáñez, 2002). En este observatorio se llevan realizando medidas continuas desde entonces, lo cual ha servido para obtener la denominada Curva de Keeling mostrada en la Fig. 1.1 (<http://www.esrl.noaa.gov/gmd/ccgg/trends/index.html>), que sirve como indicador de la evolución de las concentraciones de CO₂.

A raíz de la preocupación impuesta por los posibles efectos adversos del cambio climático, la comunidad internacional tomó papeles en el asunto y en el año 1988 la Organización Meteorológica Mundial (WMO) y el Programa de Medioambiente de la Naciones Unidas (UNEP) crearon el Panel Intergubernamental sobre el Cambio Climático (IPCC) con el objetivo de evaluar dicho cambio climático y sus posibles consecuencias/repercusiones a todos los niveles. Un primer acuerdo común y vinculante se alcanzó en 1997 en la Cumbre de Kyoto donde los países firmantes del denominado Protocolo de Kyoto (http://unfccc.int/kyoto_protocol/items/2830.php) se comprometieron a reducir las emisiones de CO₂, entre otros compromisos y medidas de acción. Uno de esos compromisos era la cuantificación de fuentes y sumideros de carbono mediante la elaboración de inventarios

(Steffen et al., 1998; http://www.epa.ie/climate/emissionsinventoriesandprojections/nationalemissionsinventories/#.VT9o_9Ltmko), que sienta una de las bases del estudio desarrollado en esta tesis. Dicho protocolo ha sido enmendado nuevamente en 2012, para ampliar el periodo de aplicación hasta 2020. Sin embargo, a pesar del aumento en la cantidad de países adheridos en la actualidad al Protocolo de Kyoto y que han acordado esta extensión, muy pocos han ratificado la enmienda firmada en Doha en 2012.




Figura. 1.1. Curva de Keeling. El gráfico muestra los cambios estacionales (rojo) en las concentraciones de CO₂ y la continua tendencia de aumento (línea) para este gas, en el observatorio de Mauna Loa (Hawai). El gráfico muestra valores actualizados a fecha de mayo de 2015 obtenidos de la web de la NOAA (<http://www.esrl.noaa.gov/gmd/ccgg/trends/index.html>).

Los altos valores en las concentraciones de determinados gases tienen un efecto directo sobre el proceso natural denominado efecto invernadero, existente en la tierra. El efecto invernadero se encarga de mantener la temperatura de la superficie terrestre, sin embargo este efecto puede verse incrementado por causa de estas altas concentraciones, desembocando en fatales consecuencias. De entre todos los gases responsables del efecto invernadero, GHG, el vapor de agua y el CO₂ participan con alrededor de un 90% en dicho efecto (Seoáñez, 2002).

Los informes presentados por el IPCC pueden ser considerados en la actualidad un referente en el campo de la investigación sobre cambio climático. La versión más actualizada del informe se ha publicado en 2013 (IPCC, 2013) y se trata ya del quinto informe, AR5, analizando el tema, publicado por este organismo. En este informe se menciona cómo las actividades humanas pueden ser consideradas como el principal factor desencadenante del incremento global de las concentraciones de GHG en la atmósfera en la actualidad. Las dos principales actividades a destacar son el consumo de combustibles fósiles y el cambio en el uso de suelo. Para el periodo 2003-2012, el 90% ($\sim 8.6 \text{ GtC año}^{-1}$) de las emisiones de carácter antropogénico se correspondió con el consumo de combustibles fósiles, mientras que el restante 10% ($\sim 1 \text{ GtC año}^{-1}$) se atribuyó a los cambios en el uso de suelo, presentando particular importancia la deforestación. Cabe destacar que desde finales de los años 50, las emisiones atribuibles a cambios de uso de suelo se han mantenido alrededor de ese porcentaje (Le Quéré et al., 2014).

Varios indicadores son evaluados en los informes del IPCC para determinar el continuo cambio climático que actualmente está sufriendo el planeta: temperatura de la tierra y los océanos, aumento del nivel del mar, pérdida de la cobertura de hielo y nieve, y concentraciones de GHG. Algunas de las consecuencias previamente mencionadas son apreciables evaluando estos indicadores del cambio climático tales como el nivel medio del mar, cuyo valor se elevó en 0.19 m para el periodo comprendido entre 1901 y 2010, o la temperatura global promedio de superficie y océanos, cuya tendencia muestra un calentamiento de 0.85 °C para el periodo 1880-2012. Los estudios realizados en muestras de hielo han revelado

concentraciones de CO₂ en el intervalo 260-280 ppm para el periodo pre-industrial. Los estudios realizados al respecto y los resultados recogidos en el AR5 muestran un crecimiento continuo de la concentración de CO₂, alcanzando valores de 398.55 ppm en 2014 (ftp://aftp.cmdl.noaa.gov/products/trends/co2/co2_annmean_mlo.txt). El aumento promedio anual para la concentración de CO₂, estimado en el AR5 para el periodo 1980-2011, alcanzó valores de 1.7 ppm año⁻¹. Este valor se incrementó a partir de 2001 adquiriendo valores de 2.0 ppm año⁻¹, cuando el periodo 2002-2011 fue considerado. Sin embargo, estos valores globales pueden aumentar incluso más cuando el estudio se desarrolla en un ecosistema o una zona concretos como muestran los resultados publicados por Sánchez et al. (2010a) con un valor de 2.98 ppm año⁻¹ para el periodo 2000-2008 en una zona rural de Castilla y León, muy cercana a la parcela donde se han realizado las medidas para el desarrollo de esta tesis.

El actual y constante incremento en las concentraciones de CO₂ ha intensificado el número de estudios dirigidos a evaluar cómo estas altas concentraciones, con consecuencias directas en el clima, afectarán a los diferentes ecosistemas terrestres pudiendo tener influencia sobre la fotosíntesis y los ciclos vegetativos de diferentes especies (Falloon et al., 2010; Olesen et al., 2002). Entre los variados efectos que un aumento de las concentraciones de CO₂ atmosférico pueden producir se encuentra el denominado 'efecto de fertilización aérea' (Houghton, 2007) por el cual una concentración superior de CO₂ conduciría a un aumento en el crecimiento de la vegetación frente a niveles inferiores de CO₂. Este efecto es más notable en vegetación/plantas del tipo C3, puesto que las altas concentraciones de CO₂ apenas afectarían a la tasa fotosintética de vegetación/plantas del tipo C4. Sin embargo, un aumento de CO₂, que consecuentemente produciría un aumento de la temperatura, podría conducir también a un aumento en los procesos respiratorios de la vegetación lo cual conduciría a un aumento en el CO₂ liberado en estos procesos (Pilegaard et al., 2001; Qaderi and Reid, 2009; Seoáñez, 2002), puesto que un aumento en la temperatura incrementaría la respiración total del ecosistema (suelos+vegetación). Yamori et al. (2014) estudiaron la influencia que el incremento de la temperatura podría tener en la

fotosíntesis y por tanto en la asimilación de CO₂. Medrano et al. (2002) analizaron la influencia de la sequía en viñedos y otras especies, y Niu et al. (2005) evaluaron la dinámica estacional de la fotosíntesis dependiente de la disponibilidad de agua, comparando los resultados obtenidos para diferentes especies. La influencia de las elevadas concentraciones de CO₂ en la fotosíntesis de diferentes especies ha sido también estudiada por Kirschbaum (2004), así como la influencia sobre la transpiración, la cual se vería notablemente reducida ante altas concentraciones debido al cierre estomático.

La regulación del CO₂ atmosférico se basa en procesos biofísicos (Falkowski et al., 2000) entre los que podemos mencionar aquellos procesos relacionados con el ciclo del carbonato-silicato (suelos, océanos) como los estudiados por algunos autores (e. g., Sánchez-Cañete et al., 2013), y los procesos fotosintéticos (vegetación) estudiados en esta tesis. Cuando consideramos el balance global del carbono, podemos distinguir entre fuentes y sumideros. A su vez, las fuentes se pueden dividir en naturales (respiración, actividad volcánica, incendios por causas naturales) o antropogénicas (cambio de uso de suelo y deforestación, transporte, emisiones de la industria, combustión de biomasa, emisiones por la generación de energía). También los sumideros pueden ser divididos principalmente en vegetación terrestre, océanos y suelos (Reay and Grace, 2007). Algunos ejemplos numéricos que pueden dar idea de las cifras con las que nos movemos en este tipo de estudios se pueden encontrar en Figueroa et al. (2007), donde se muestra un cálculo entre la relación del CO₂ absorbido y la biomasa creada con una relación de 1 kg de madera por cada 3.67 kg de CO₂ absorbido. Aparte, los procesos fotosintéticos además de eliminar CO₂ atmosférico también producen O₂. En el mismo estudio anterior se hace un cálculo que demuestra la importancia de la superficie arbórea, dando una aproximación numérica que muestra como 1 ha de parcela arbolada urbana podría cubrir las necesidades para todo un día de 6 personas con el O₂ producido. Aunque estos ejemplos se refieren a un tipo de vegetación diferente a la estudiada en esta tesis (cultivos), estos ejemplos dan una idea de los grandes órdenes de magnitud implicados en el ciclo del carbono.

Como consecuencia directa de los acuerdos establecidos en el Protocolo de Kyoto, un numeroso grupo de estudios ha estado dirigido a la identificación y cuantificación de fuentes y sumideros, para determinar el comportamiento de diferentes ecosistemas en relación a los intercambios de CO₂ y su papel en la asimilación del CO₂ emitido por el hombre. Los diferentes ecosistemas terrestres, gracias a sus procesos fotosintéticos, tienen un papel fundamental en la asimilación de parte del CO₂ emitido a la atmósfera procedente de fuentes antropogénicas. La gran variedad de cultivos ha dado lugar a que los ecosistemas agrícolas hayan sido menos estudiados, centrándose mayoritariamente en cultivos como el maíz, el trigo, el arroz o la soja (Bhattacharyya et al., 2014; Gitelson et al., 2006; Wagle et al., 2015; Zheng et al., 2008). El cambio de uso de suelo y la inclusión de nuevos cultivos en las rotaciones de las parcelas arables en todo el continente conduce a la necesidad de abordar con profundidad el comportamiento de estos nuevos cultivos y, en concreto, su comportamiento como fuente o sumidero de carbono, aspecto de gran interés en el contexto del cambio climático. La justificación del interés que este tipo de ecosistemas merecen se demuestra evaluando los datos de ocupación de suelo. Según datos del INE (INE, 2015) y del informe estadístico que publica anualmente el MAGRAMA, España cuenta con una extensión de 505.964 km². La superficie destinada a tierras de cultivo y la superficie forestal arbolada, arbustiva y de matorral destacan como los dos principales usos de suelo dentro del territorio nacional. En valores promedio para el periodo 1990-2012, aproximadamente un 36% y un 34% de superficie total fueron destinados a la agricultura y a superficie forestal, respectivamente. Más de la mitad de esa superficie agrícola correspondió a cultivos herbáceos, similares a los cultivos estudiados en esta tesis. La tendencia de los últimos años muestra, sin embargo, un aumento de la superficie destinada a zonas arboladas, en detrimento de aquella dedicada a cultivos. Quizá, por ese motivo, existe una gran variedad de estudios desarrollados en zonas forestales. Aun así, la importancia de los cultivos no puede ser ignorada (Chen et al., 2014; Peng et al., 2013), en particular para la meseta castellana donde la superficie destinada a cultivos tiene gran relevancia económica y social.

1.2 Ciclos biogeoquímicos y flujos de carbono

El nombre de ciclo biogeoquímico se refiere al movimiento de varios elementos que están continuamente circulando y son reutilizados en el interior de un ecosistema y/o entre varios ecosistemas. Estos ciclos establecen los vínculos entre los diferentes componentes de un ecosistema. Los ciclos biogeoquímicos pueden ser divididos en tres categorías principales: ciclo hidrológico o ciclo del agua, ciclos gaseosos (carbono, oxígeno, nitrógeno, azufre), y ciclos sedimentarios o minerales (e. g., fósforo). La energía es el principal motor de todos los ciclos mencionados, particularmente del ciclo del carbono y del ciclo hidrológico. La evapotranspiración es uno de los principales procesos ligados al ciclo del agua e indirectamente al ciclo del carbono, mientras que los principales procesos en el ciclo del carbono son la fotosíntesis y la respiración (Wali et al., 2009). Por su definición, la evapotranspiración puede ser equiparada con el flujo de calor latente, LE, y por tanto este proceso puede ser estudiado mediante el cálculo de dicho flujo. Xiao et al. (2013) demostraron el acoplamiento entre la evapotranspiración y los procesos fotosintéticos, mostrando fuertes correlaciones para diversos ecosistemas en China. Mediante la fotosíntesis se genera biomasa cuya producción está gobernada por la luz y claramente limitada por el agua y los diferentes nutrientes (N, P, etc.). Todo esto prueba una vez más la clara interconexión entre los diferentes ciclos mencionados previamente (Baozhang, 2012; Govind et al. 2015). Los principales procesos relacionados con el ciclo del carbono se evaluarán mediante el cálculo y análisis de principalmente tres variables: la producción primaria neta, GPP, la respiración, RE, y el intercambio neto del ecosistema, NEE. Sin embargo, otros flujos/variables son ampliamente utilizados en este campo. Las definiciones de los flujos mencionados, procedentes de la bibliografía, se han recopilado en el Apéndice I. También en dicho apéndice se resume el criterio de signos seguido para estas variables.

Para determinar cada uno de los términos mencionados se han venido utilizando diferentes métodos (Riederer et al., 2014; Shi et al., 2008). De entre todos, el más ampliamente utilizado es la

técnica micrometeorológica denominada covarianza turbulenta, 'Eddy Covariance' -EC-, la cual está orientada a la medida de largas series temporales en diversos emplazamientos y redes internacionales. Quizá por ser la más conocida o mencionada se debe nombrar la red FLUXNET (<http://www.fluxdata.org/default.aspx>) que a su vez incluye varias redes regionales: EUROFLUX, CARBOEUROPE, AmeriFLUX, ASIANFLUX, etc. Uno de los objetivos principales de estas redes es cuantificar los flujos de CO₂ y de energía. Los valores acumulados de estos flujos, GPP ó NPP, NEE y RE, suministran un claro indicio del comportamiento de los diversos ecosistemas terrestres en relación al ciclo global del carbono. La magnitud y signo de estas variables indican el comportamiento como fuente o sumidero de CO₂ y su capacidad de emisión o absorción, respectivamente. Además, sus valores presentan una gran variabilidad dependiente de la localización y del tipo de ecosistema (Jung et al., 2011). Falge et al. (2002) encontraron un claro gradiente latitudinal cuando compararon valores de GPP y NPP a partir de diversas fuentes. Un resultado similar encontraron Valentini et al. (2000) para el estudio del NEE en bosques europeos, concluyendo que los bosques de latitudes mayores secuestraban menos carbón. Por otra parte, las diferentes condiciones climáticas o medioambientales pueden también influenciar notablemente el comportamiento de un ecosistema. De tal forma, y dependiendo del tipo de ecosistema, su comportamiento podría cambiar de fuente a sumidero de carbono o viceversa (Gilmanov et al., 2013) debido a las condiciones meteorológicas como en el caso de eventos de precipitación o presencia de sequías (Yang et al., 2011). Sin embargo, este comportamiento está mucho más marcado en ecosistemas con escasa o poco densa vegetación tal como describen Yang et al. (2011) para el caso de estepas o praderas.

1.3 Eficiencia y modelos de simulación

La eficiencia de un ecosistema puede ser analizada a través de diferentes parámetros relacionados con los principales recursos (agua, nutrientes, luz y CO₂) utilizados por la vegetación en su crecimiento. Se puede evaluar su eficiencia en el uso de la luz (LUE) o de la radiación

(RUE), del agua (WUE), del carbón (CUE), o incluso del nitrógeno (NUE). Se puede describir la eficiencia CUE a través de la relación entre NPP y GPP (Albrizio and Steduto, 2003). El valor WUE se calcula a partir de la relación entre la tasa fotosintética o GPP y la pérdida de agua (transpiración ó evapotranspiración) tal como se describe en Lee et al. (2010). Un mayor valor de WUE indicará que dicha vegetación utiliza menos agua en sus procesos de crecimiento (Figueroa et al., 2007). De hecho, existe relación directa entre el aumento en los valores de WUE y las elevadas concentraciones de CO₂ (Jianlin et al., 2008). Beer et al. (2007) desarrollaron un modelo empírico para determinar el valor de WUE en función del LAI y de la capacidad de retención de agua del suelo. Una vez calculados de manera independiente los valores de WUE, se pudieron estimar los valores de GPP. Utilizando este método obtuvieron un valor total de GPP para los cultivos en Europa de 0.7 PgC año⁻¹.

El valor LUE viene habitualmente definido a través de la relación entre la radiación fotosintéticamente activa, PAR, y la GPP (Huang et al., 2014), aunque en ocasiones se puede hablar de RUE en su lugar (Sandaña et al., 2012). Este último parámetro se diferencia del LUE en que su cálculo considera la radiación solar total interceptada en lugar de tener en cuenta el valor de PAR. Este término presenta una gran variabilidad según la especie y la localización geográfica. Por ello, una estimación precisa del valor correspondiente a cada zona y tipo de vegetación o incluso especie sería deseable (Bradford et al., 2005; Goerner et al., 2011).

Se debe destacar que, aunque la finalidad sea la misma (la caracterización de un ecosistema o de determinada vegetación), las variables o metodología utilizadas para alcanzar dicha meta son tan variadas que en ocasiones es difícil poder intercomparar los resultados reportados en la bibliografía. En efecto, algunos autores presentan valores de NPP/GPP, y, otros, valores finales de GPP, NEE, NEP o incluso NBP y, aunque esas variables están interrelacionadas (véase Apéndice I), ello dificulta la comparación de los resultados existentes en la bibliografía.

Las técnicas de medida comentadas previamente, entre las que se encuentra el método EC, para la estimación de los flujos de energía y de

CO₂ cubren áreas limitadas por el alcance de la instrumentación utilizada. Además, en ocasiones, debido a los altos costes que implica dicha instrumentación y/o a la dificultad de acceso a la zona en que se desea extraer información, este tipo de medidas resulta inviable. Ante estos inconvenientes, se comenzaron a desarrollar modelos capaces de reproducir los flujos medidos experimentalmente. El modelado de varios procesos implicados en el ciclo del carbono y los restantes ciclos biogeoquímicos es por tanto una herramienta muy útil para lograr un mejor entendimiento de esos procesos (Baozhang, 2012). Además, estos modelos basados en procesos pueden también ayudar a entender el papel de los ecosistemas en el ciclo global del carbono. Un tema clave en el desarrollo de este tipo de modelos es tener en cuenta la interacción entre los diferentes ciclos biogeoquímicos comentada en el apartado 1.2, que habitualmente no se considera (Falkowski et al., 2000). Los modelos deben ser desarrollados, evaluados y calibrados, aplicándolos a la diversidad de ecosistemas existentes. Una vez cumplimentadas estas etapas, su aplicación puede dar respuesta a los futuros cambios y a los riesgos a los que se expondrán los diferentes ecosistemas y ciclos biogeoquímicos utilizando diversos escenarios relacionados con el cambio climático (Morales et al., 2005). Varios de estos modelos, los cuales han adquirido una mayor relevancia, y son ampliamente utilizados, pueden ser divididos en diferentes categorías. Las principales categorías con las que nos podemos encontrar son: modelos de eficiencia, modelos basados en el balance de energía y modelos basados en procesos bioquímicos.

Un primer grupo de modelos ampliamente utilizados son aquellos basados en el concepto de LUE, denominados de una forma genérica como Production Efficiency Models –PEMs– (McCallum et al., 2009; Xin et al., 2013), cuyo esquema inicial fue desarrollado por Monteith (1972). Éstos son habitualmente denotados como modelos LUE (Running et al., 1999) y son utilizados para la estimación de GPP ó NPP (Xiao et al., 2004). Se basan en la relación directa entre la producción vegetal y la luz disponible para procesos fotosintéticos, y además tienen en cuenta la reducción de la eficiencia LUE originada por factores de estrés ambiental relacionados

principalmente con la humedad y la temperatura. Su expresión más común aparece definida en Yuan et al. (2014).

Un segundo grupo de modelos se basan en el balance de energía, los cuales son habitualmente divididos en dos tipos: modelos de una fuente (Tang et al., 2013), y modelos de dos fuentes (Gonzalez-Dugo et al., 2009; Kalma et al., 2008) cuya formulación fue claramente descrita por Shuttleworth and Wallace (1985). La diferencia entre ambos radica en si la influencia de la vegetación y el suelo son tenidas en cuenta de manera conjunta (una fuente) o separadamente (dos fuentes), lo que da lugar a que se introduzcan una o dos resistencias en el modelo, respectivamente.

Un tercer grupo de modelos, denominados bioquímicos, destaca por su importancia en la determinación del comportamiento de los diferentes ecosistemas en relación al ciclo del carbono. El principal objetivo es modelar la fotosíntesis de la vegetación considerando las diferentes características estructurales de las plantas. Existe gran variedad dentro de este tipo de modelos, entre los que podemos mencionar: CDMag (Zhang and Tang, 2005), SPA (Revill et al., 2013), ISBA-A-gs (Albergel et al., 2010), FvCB (Lenz et al. 2010), y 5PM (Tolk et al., 2011). Pero, sin duda, el modelo más utilizado es el descrito por Farquhar et al. (1980) del que existen diferentes variantes (Wang and Leuning, 1998).

Todos los modelos mencionados previamente pueden ser empleados independientemente. Sin embargo, dada la implicación de todos los procesos y ciclos biogeoquímicos, en los últimos años se han desarrollado modelos acoplados que calculen no sólo uno sino varios procesos en una misma simulación y que, por tanto, interrelacionen todos o varios de los modelos previamente descritos. Algunos ejemplos de estos modelos acoplados son: CTP (Kremer et al., 2008); CANOAK (Wilson et al., 2001); SiB2 (Sellers et al., 1996); ORCHIDEE (Verbeeck et al., 2011); PIXGRO (Adiku et al., 2006); BEPS (Ju et al., 2010); PROSAILH-BGC (Migliavacca et al., 2009), y MAESPA (Duursma and Medlyn, 2012).

Una mejora en el estudio o simulación de los procesos biogeoquímicos incluye la combinación de estos modelos conjuntamente

con datos satelitales. Esta combinación se ha convertido en una herramienta poderosa para ampliar la escala de los resultados modelados obtenidos. De esta manera se pueden obtener resultados desde el nivel de ecosistema hasta escala regional, o incluso escala global (Reichstein et al., 2014). El ejemplo más claro son los modelos LUE (Yan et al., 2015), citados previamente, los cuales utilizan datos satelitales de la fracción fotosintética activa absorbida por la vegetación, FPAR. También en el análisis del ciclo global del carbono es habitual la integración ó combinación de la teledetección y los modelos de procesos de los ecosistemas (Turner et al., 2004). Entre la gran variedad de sensores existentes mencionaremos el MERIS (Berberoglu et al., 2007), el Landsat (Chen et al., 2013), o el Vegetation (Xiao et al., 2004). A pesar del aumento creciente de sensores que orbitan el planeta, uno de los más ampliamente utilizados ha sido y es el MODIS a bordo de los satélites Terra y Aqua (Coops et al., 2007; Heinsch et al., 2006; Li et al., 2007; Shim et al., 2014; Sims et al., 2005).

1.4 Objetivos

Considerando la amplia extensión que ocupan los cultivos a escala planetaria, nacional y en Castilla y León, su importancia socio-económica y la aún escasa información existente, el objetivo central de esta tesis ha sido realizar medidas de los flujos de energía y de CO₂ y modelarlos en una parcela agrícola situada en la provincia de Valladolid. La parcela seleccionada ha sido un cultivo anual rotante de colza del que se ha hecho un detallado seguimiento durante cuatro años completos. El criterio anual de rotación seguido por el agricultor ha consistido en la siembra de colza, trigo, guisantes y centeno. Dicho criterio no sólo ha permitido estudiar el comportamiento de los cultivos de secano más relevantes en Castilla y León sino que además ha incluido algunos de gran importancia y de los que se dispone de escasa información. Entre ellos destacamos la colza, ya que además de haber sido poco estudiada en detalle en relación a los flujos de CO₂ (Chen et al., 2014), es una de las principales materias primas para la elaboración de biodiesel (Peterson and Hustrulid, 1998). La superficie media anual destinada en España al cultivo de colza cuenta, en promedio,

con cerca de 30.000 ha para el periodo 1990-2013. Sin embargo, tanto la superficie como la producción de este cultivo han experimentado un aumento sustancial en los últimos años, en particular desde 2007. Las cifras para la superficie destinada al cultivo de colza y su producción prácticamente han triplicado sus cifras desde 2001 en España, con datos de 42.549 ha cultivadas y 112.928 toneladas producidas para el año 2013. (MAGRAMA, 2012). Otro cultivo del que apenas existe información es el centeno.

Para cada uno de los cultivos hemos realizado medidas de los principales componentes implicados en el balance de energía: el calor sensible, H , el calor latente, LE , el flujo de calor del suelo, G , y la radiación neta, R_n , examinando la contribución de cada término a la energía total disponible. Por otra parte, hemos modelado cada término utilizando el modelo de una fuente SEBS. Dado que su formulación incluye una combinación de datos satelitales y bases de datos meteorológicos, permite la incorporación de los parámetros de entrada necesarios independientemente de la disponibilidad de datos in situ. Esto hace que este modelo sea aplicable a zonas que, por ejemplo, carezcan de instrumentación meteorológica.

En lo que respecta a los flujos de CO_2 , hemos seguido un procedimiento similar midiendo el NEE, la RE, y la GPP en cada cultivo, lo que en definitiva nos ha permitido cuantificar las fuentes y sumideros de CO_2 . En este caso los resultados de la GPP, uno de los términos de mayor interés, han sido modelados utilizando un modelo LUE, el cual nos ha permitido determinar la eficiencia óptima de cada tipo de cultivo.

Esta tesis surge como continuación de los estudios iniciados en 2008 por el GCA para el estudio específico de la colza en la parcela agrícola antes aludida. Los primeros resultados de dicho estudio se publicaron en 2012 en una monografía cuyo contenido se adjunta en el Apéndice II. En esta tesis se ha ampliado el periodo de estudio a cuatro años y extendido al análisis de otros cultivos característicos de la zona de estudio como son el trigo, los guisantes y el centeno.

Por tanto, sintéticamente los objetivos específicos de este estudio han sido:

- a) estudio del cierre del balance de energía,
- b) modelado de los flujos de energía aplicando el modelo de una fuente SEBS,
- c) identificación de cada cultivo como fuente o sumidero de CO₂ mediante el cálculo de la cantidad total de NEE y GPP, y
- d) obtención de un valor de eficiencia para cada cultivo mediante la aplicación de un modelo LUE a la GPP.

1.5 Estructura de la Tesis

Los capítulos centrales están basados en artículos publicados o remitidos para su publicación, por ello están escritos en inglés y no se han traducido. Por el contrario, los dos primeros capítulos cuyo contenido hace referencia a una introducción general y la descripción del lugar de medidas están escritos en español. Esta tesis consta de 6 capítulos cuyo contenido es resumido a continuación.

El Capítulo 1 aporta una introducción al tema de estudio, antecedentes y motivación relacionados con él. También provee del marco de trabajo en el que se desarrollarán los siguientes capítulos, dando una descripción global de la problemática y de su interés, así como la terminología que se utilizará.

El Capítulo 2 proporciona una descripción global de la zona de estudio y de la región donde está localizada la estación de medida. También se presenta una visión de conjunto de la climatología del lugar, así como una descripción de la instrumentación y técnicas empleadas.

El Capítulo 3 presenta el balance de energía de la parcela estudiada, donde todos sus componentes son evaluados, y los resultados del cierre de dicho balance. El análisis del cierre de este balance determinará la precisión de las medidas realizadas con la instrumentación EC, cuyos datos serán utilizados en capítulos posteriores. Además se determinará el reparto de energía entre los diferentes procesos que relacionan el ecosistema, la atmósfera y el suelo.

El Capítulo 4 trata el modelado de procesos biofísicos, basado en un modelo de una fuente, mediante la evaluación y calibrado del modelo SEBS. Mediante este modelo se obtienen las series temporales de los diferentes componentes que participan en el balance de energía, así como el valor de la fracción evaporativa, EF.

El Capítulo 5 calcula los principales componentes que participan en el ciclo del carbono, tales como NEE y GPP, que darán cuenta del comportamiento como fuentes o sumideros de carbono, en concreto el valor de NEE. Además, revisa las diferentes posibilidades para la obtención de GPP, particularmente aplicando un modelo LUE. La aplicación de este modelo conducirá a la obtención de un valor final característico de la eficiencia de cada cultivo estudiado.

El Capítulo 6 compendia los principales resultados y conclusiones obtenidos en el desarrollo de esta tesis.

La **Bibliografía** y los dos siguientes apéndices completan la memoria.

El Apéndice I recoge las definiciones de los diferentes flujos de carbono descritos en la bibliografía, así como el criterio de signos empleado y un diagrama de flujo que relaciona dichas variables.

El Apéndice II contiene la monografía (52 pp) titulada 'Medida y parametrización de los flujos de CO₂ en un cultivo de colza. Medidas in situ y satelitales', publicado por la editorial Academica Española en 2012 que presenta los primeros resultados obtenidos para el estudio del cultivo de colza desarrollado en este trabajo.

CAPÍTULO 2. ZONA DE ESTUDIO Y METODOLOGÍA

2.1 Introducción

La zona de estudio queda descrita y caracterizada en los siguientes apartados de este capítulo. La descripción comprende no sólo la parcela de estudio sino su valor representativo con respecto al territorio nacional. A continuación se incluye una descripción de la instrumentación utilizada en este trabajo, así como una caracterización meteorológica de la zona de estudio. Ésta mostrará las condiciones ambientales en las que se han realizado las medidas y, por ende, las condiciones en las que se ha desarrollado el ciclo vegetativo de cada uno de los cultivos estudiados. Como complemento a esta caracterización meteorológica se incluye un estudio de la tendencia en los valores de precipitación y temperatura en Valladolid durante los últimos 71 años.

2.2 Descripción general

La región de Castilla y León cuenta con una extensión de 94.226 km² (INE, 2015) y es la comunidad con mayor territorio de toda España, ocupando el 18.6% del territorio nacional. Dentro de la comunidad, aproximadamente un 39% de la superficie se destina a tierras de cultivo, prácticamente en su totalidad para cultivos herbáceos, mientras que la superficie arbolada cubre alrededor de un 29% (promedio periodo 1990-2012). La misma tendencia en el aumento de superficie arbolada que se apreciaba al estudiar el territorio nacional (Sección 1.1) se aprecia a nivel de comunidad, aunque en este caso las tierras de cultivo todavía destacan como primer uso de suelo (Fig. 2.1).

Los cultivos herbáceos mencionados se encuentran divididos en cereales grano (trigo, cebada, avena, centeno, arroz, maíz, etc.), leguminosas grano (judías, lentejas, habas, garbanzos, guisantes, etc.), tubérculos para consumo humano (patata, boniato, batata, chufa), cultivos industriales (colza, girasol, remolacha, caña de azúcar, algodón, lino, pimentón, azafrán, menta, tabaco, etc.), cultivos forrajeros, hortalizas, y flores y plantas ornamentales (Anuario MAGRAMA, 2009).




Figura 2.1. Evolución de la superficie destinada a los dos principales usos de suelo (forestal y agrícola) en Castilla y León para el periodo 1990-2012.

Los más recientes datos estadísticos muestran una extensión total empleada para el cultivo de cereales grano a nivel nacional de 6.268.026 ha (Anuario MAGRAMA, datos 2013) de cuya extensión la mayor parte está destinada al cultivo de secano (5.089.594 ha). La superficie destinada a cereales grano se ha mantenido alrededor de esta cifra desde 2001. Un dato remarcable a tener en cuenta dentro del marco del estudio que hemos llevado a cabo es que dentro de Castilla y León parte de la producción de cereales grano está dedicada a la producción de bio-combustible, aunque se trate de una pequeña parte. Esto convierte a Castilla y León, junto con Navarra, en las dos únicas comunidades españolas que destinan parte de la producción de cereal grano a la industria del bio-combustible. El territorio destinado a cultivos dentro de la comunidad de Castilla y León es de 3.526.668 ha (Anuario MAGRAMA, datos 2012) lo que la convierte en la tercera comunidad con mayor área destinada a tierras de cultivo después de Castilla La Mancha y Andalucía. Del total de superficie de Castilla y León destinada a tierras de cultivo, la

mayor extensión corresponde a los cultivos herbáceos (2.741.222 ha, MAGRAMA 2012). En particular, los cultivos de secano (2.306.460 ha, MAGRAMA 2012) representan un 65.4% del total de superficie cultivada ocupando el 24.5% de la superficie geográfica total de Castilla y León. Con estas cifras, se deduce la importancia de los cultivos, en particular los de secano, a escala regional e incluso, a escala nacional.

Dentro de la comunidad de Castilla y León nos interesa ver el papel que tiene Valladolid en relación a estas estadísticas y usos de suelo de los que estamos tratando, por encontrarse dentro de esta provincia la zona de medidas. Aunque dentro de la comunidad, e incluso a nivel nacional, Valladolid no es una de las provincias con mayor extensión de territorio, 8.111 km², más de la mitad está dedicada a tierras de cultivo (en concreto, cultivos herbáceos) ocupando el segundo puesto después de Burgos. De las 573.716 ha (JCYL, datos 2013) dedicadas a tierras de cultivo, 489.2383 ha (Anuario JCYL, datos 2013) corresponden a cultivos herbáceos y, en particular, 395.503 ha (JCYL, datos 2013) pertenecen a cultivos herbáceos de secano. Queda así demostrada la importancia de este tipo de cultivos dentro de la región y la influencia tanto ecológica como económica.

De entre todos los tipos de cereales incluidos dentro de la denominación cereal grano, el trigo es el que cuenta con una mayor superficie media a nivel nacional (2.102.191 ha) para el periodo 1990-2012. En Castilla y León, la superficie (Fig. 2.2a) destinada a este cereal es 783.746 ha (secano y regadío, MAGRAMA, datos 2012). Estas cifras convierten a Castilla y León en la comunidad con mayor superficie de cultivo de trigo en todo el territorio nacional. Del mismo modo, aunque Valladolid no se encuentre entre las primeras productoras de la comunidad, aun así, se destinan 71.488 ha para el cultivo de este cereal dentro de la provincia lo que supone aproximadamente un 9% del total de su superficie. Otros cereales incluidos en la denominación cereal grano son, como ya se ha mencionado, el centeno, la avena y el maíz. Aunque éstos cuentan con una menor superficie y producción dentro de la comunidad, aun así son cultivos a tener en cuenta por la influencia dentro de la región, en especial el centeno. Siendo este último otro de los cultivos característicos en Castilla y León, pues a pesar de que la superficie (105.866 ha, MAGRAMA, datos

2012) y producción (Fig. 2.2b) son menores en comparación con las cifras dadas para el trigo, aun así, vuelve a ser la primera comunidad en producción y superficie a nivel nacional.

Si seguimos analizando los cultivos característicos de la zona de estudio, encontramos las leguminosas grano y dentro de este tipo los garbanzos y guisantes. Habitualmente, una gran parte de la producción de guisante está destinada a consumo animal. En 2012, Castilla y León destacó nuevamente como la primera productora nacional de guisante seco con una superficie cultivada de 49.937 ha (MAGRAMA, 2012), ocupando Valladolid el primer puesto en producción dentro de la comunidad.

El último tipo de cultivo herbáceo que se tratará en detalle por su influencia dentro de la región de estudio son los cultivos industriales. Dentro de esta denominación se deben destacar el girasol y la colza. El cultivo de colza está escalando posiciones frente a otros cultivos por tratarse de uno de los cultivos que en la actualidad está catalogado como fuente de nuevas energías (bio-combustible). Este cultivo, por novedoso y escasamente estudiado, se ha convertido en el pilar fundamental de este trabajo, en el que se analiza un cultivo rotante de colza en una misma parcela para un periodo de varios años. De nuevo, al igual que ocurría con el caso de los cereales grano, Castilla y León lidera tanto en superficie de cultivo de colza (14.371 ha, MAGRAMA, 2012) como en producción a nivel nacional. Valladolid se presenta como la tercera provincia productora de este cultivo, después de Zamora y Salamanca (datos 2012), a nivel de Castilla y León, y quinta a nivel nacional tras Zamora, Navarra, Girona y Salamanca (MAGRAMA, 2012).





Figura 2.2a. Evolución de la producción y la superficie destinada a su siembra en Castilla y León para la colza y el trigo. Elaboración a partir de los datos contenidos en los diferentes anuarios estadísticos publicados por el MAGRAMA.

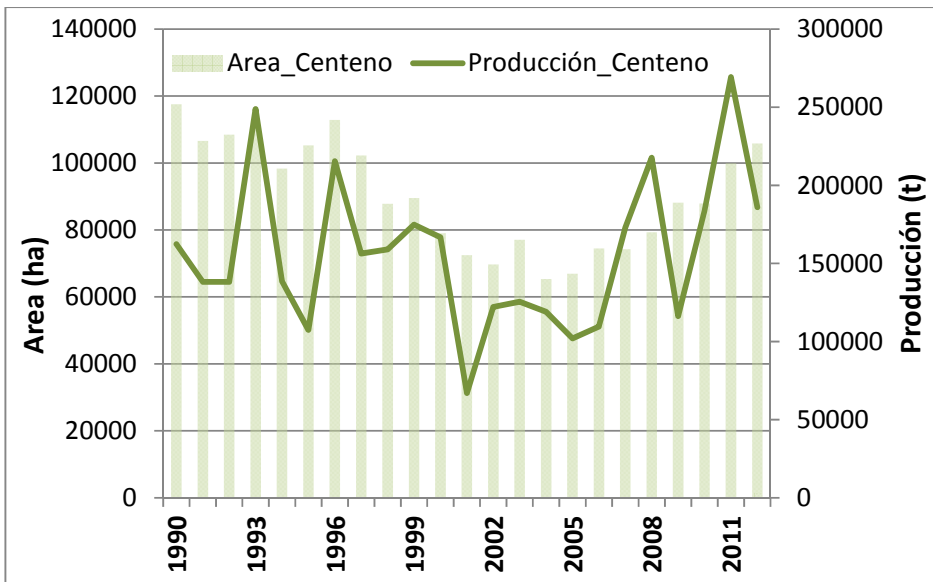



Figura 2.2b. Evolución de la producción y la superficie destinada a su siembra en Castilla y León para los guisantes y el centeno. Elaboración a partir de los datos contenidos en los diferentes anuarios estadísticos publicados por el MAGRAMA.

2.3 Descripción del lugar de medida

El lugar donde se han realizado las medidas se muestra en las Fig. 2.3 y 2.4. Se trata de una parcela agrícola (41°46'44.4" N, -4°52'19.19" W) situada a unos 30 km al noroeste de Valladolid y a una altitud de 849 m sobre el nivel del mar. El lugar está caracterizado por una amplia homogeneidad en el terreno (Pérez et al., 2006), al situarse en plena meseta y no encontrarse ningún elemento de relieve alrededor, presentando una visibilidad total en todas las direcciones. El uso de suelo en la parcela de medida está destinado al cultivo de cereales de secano, así como en la mayor parte de las parcelas adyacentes, siendo éste un uso de suelo característico de esta región como ya hemos mencionado. Se trata de una parcela de aproximadamente 36 ha donde hemos instalado dos torres de medida. El propietario utiliza el método de siembra de mínimo laboreo ('reduced tillage') para minimizar el impacto de dichas tareas sobre el cultivo y que sea lo más natural posible. Este método de siembra además reduce las emisiones de CO₂ del suelo, lo que representa un valor añadido (Sánchez et al., 2002).

El suelo está catalogado como franco-arenoso ('sandy-loam') con el siguiente contenido aproximado: 15% de limo, 20% de arcilla y 65% de arena. La cantidad de materia orgánica obtenida para el análisis del suelo está alrededor del 3%. La parcela de medida, así como las circundantes, mantiene un esquema rotante de cultivo, donde habitualmente se van intercalando vegetación de hoja ancha con vegetación de hoja estrecha. Como ya se ha mencionado, durante el periodo de medidas comprendido entre 2008 y 2011, los cultivos estudiados han sido: colza, trigo, guisantes y centeno. El periodo vegetativo característico de los cultivos de secano en esta región suele comprender desde la siembra, a mediados de septiembre o mediados de octubre, hasta la cosecha a mediados de julio. Sin embargo, dependiendo del cultivo específico y las condiciones meteorológicas, este periodo puede sufrir leves variaciones. Para los cultivos estudiados la época de siembra correspondió a septiembre (colza), noviembre (trigo), enero (guisantes) y octubre (centeno). Durante el periodo de medidas nos encontramos con una excepción al característico ciclo mencionado: los guisantes sembrados en el año 2010, que poseen un ciclo más corto

comparado con los restantes cultivos de secano estudiados. Aunque la siembra se realizó mucho mas tarde (mediados de enero), el periodo de cosecha coincide con los otros cultivos (mediados de julio). Fuera del ciclo vegetativo, el suelo no presenta vegetación aunque si un residuo vegetal que sirve como cobertura para el suelo hasta la próxima siembra y que es una característica del mínimo laboreo aplicado en la parcela.

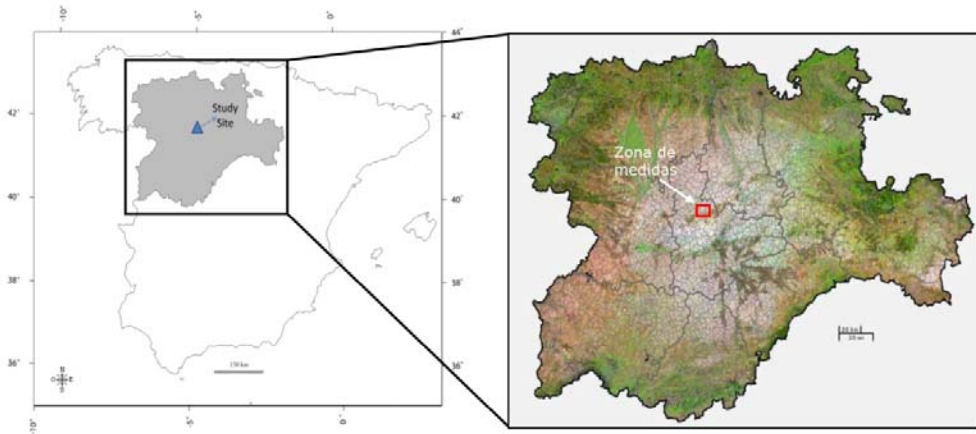


Figura 2.3. Localización geográfica de la zona de estudio en la región de Castilla y León en España (izq.). Mapa elaborado por el Plan Nacional de Ortofotografía Aérea (der.), PNOA, de máxima resolución elaborado por el IDECYL (<http://www.idecyl.jcyl.es/hac/6/VCIG/Login.ini>).



Figura 2.4. Imágenes obtenidas a partir del Sistema de Información Geográfica de Parcelas Agrícolas (SIGPAC, <http://sigpac.mapa.es/fega/visor/>). Ministerio de Agricultura, Alimentación y Medio Ambiente (MAGRAMA) y Junta de Castilla y León (JCYL). Foto aérea tomada en junio de 2008 (izq.) y en julio de 2011 (der.). Situación de la parcela antes (izq.) y después de la cosecha y hasta la siguiente siembra (der.).

2.4 Instrumentación

Las torres de medida fueron instaladas en la parcela mostrada en la Fig. 2.4 en marzo-abril de 2008, y han estado funcionando desde ese momento de forma ininterrumpida. Las dos están ubicadas aproximadamente en el centro de la parcela para obtener medidas representativas de todo el cultivo y están separadas aproximadamente unos 20 m para que las medidas registradas no se vean interferidas por la otra torre. Cada torre posee instrumentación meteorológica convencional e instrumentación micrometeorológica ó EC (Fig. 2.5), respectivamente. De aquí en adelante la nomenclatura otorgada a estas torres para futuros comentarios será torre meteorológica para aquella que contiene la instrumentación meteorológica y torre de respuesta rápida o torre EC para aquella con la instrumentación micrometeorológica.




Figura 2.5. Torres meteorológica (izq.) y micrometeorológica (der.) instaladas en la parcela de medida.

La instrumentación de la torre meteorológica aparece reflejada en la Fig. 2.5 (izq.). A mayores, dicha torre cuenta con varias sondas de suelo que no aparecen en la imagen. Toda esta instrumentación es brevemente descrita a continuación:

- Sensor cuántico (Li-190, Li-Cor Biogeosciences, Lincoln, NE, EEUU): encargado de medir la radiación fotosintéticamente activa, PAR, abarcando el rango 400-700 nm.
- Radiómetro neto (Type 8110, Ph. Schenk): mide la diferencia entre la radiación incidente y saliente para las longitudes de onda corta y larga (0.3 - > 3 μm). El posible rango de medidas oscila entre -1500 y +1500 W m^{-2} , siendo capaz de trabajar entre -40 y +60 $^{\circ}\text{C}$. Valores positivos indican una ganancia de energía por la superficie, mientras que los valores negativos denotan una pérdida de energía. El sensor está instalado a 1.5 m sobre la superficie.
- Termohigrómetro (STH-5031, Geónica, Madrid, España): se trata de un único sensor combinado que mide la temperatura y humedad, protegido por una carcasa para evitar que los sensores se vean dañados o las medidas alteradas. El rango de medida incluye temperaturas desde -30 hasta 70 $^{\circ}\text{C}$, con una precisión de ± 0.1 $^{\circ}\text{C}$. La medida de la humedad cubre valores desde 0 hasta 100%, con precisión de $\pm 3\%$ hasta valores de 90% y con precisión de $\pm 5\%$ para valores a partir de 90%.
- Anemómetro (03101 R. M. Young wind sentry anemometer): está compuesto por tres cazoletas cuya rotación genera una señal en corriente AC proporcional a la velocidad del viento.
- Veleta (03301 R. M. Young wind sentry vane): proporciona la dirección del viento. El rango de medida incluye valores desde 0 hasta 50 m s^{-1} para la velocidad del viento y de 0 a 360 $^{\circ}$ para la dirección, según especificaciones del manual.

- Sonda de temperatura de suelo (modelo STS-5031): se encuentra instalada a unos 10 cm de profundidad, en el interior de un cilindro de acero inoxidable que permite una rápida respuesta a los cambios de temperatura. El cilindro se encuentra a su vez en el interior de un cuerpo de PVC que permite el aislamiento térmico con el entorno. El rango de medida y la precisión coinciden con los mencionados para el sensor de temperatura, componente del termohigrómetro.



- Sonda de humedad de suelo (ThetaProbe type ML2x): está situada en el suelo a una profundidad de 6-10 cm y mide cambios en la constante dieléctrica del suelo registrando la humedad con una precisión de $\pm 1\%$. Comparando valores conocidos de la constante dieléctrica para diferentes superficies y tipos de suelo con el valor medido por la sonda, el contenido volumétrico de humedad de suelo oscilará entre $0 \text{ m}^3/\text{m}^3$ (suelo seco) y $1 \text{ m}^3/\text{m}^3$ (agua). Los valores de salida de la sonda oscilarán entre 0 y $0.5 \text{ m}^3/\text{m}^3$, aproximadamente. Una característica de este tipo de instrumentación es la rápida respuesta a eventos de precipitación. Habitualmente, en lugar de utilizar unidades de m^3/m^3 se suele representar la medida con valores en %.



- Platos de flujo térmico del suelo (HFP01, Hukseflux, Delft, The Netherlands - Campbell Scientific Inc.): los sensores o platos consisten en una termopila que mide las diferencias en el gradiente de temperatura. El sensor genera un pequeño voltaje de salida proporcional al flujo de calor. Este voltaje debe ser dividido por la sensibilidad ($50 \text{ } \mu\text{V}/\text{W m}^{-2}$), una constante suministrada con cada instrumento, para obtener el valor del flujo. Los platos se encuentran enterrados a una profundidad de entre 2-5 cm. Para obtener un valor más representativo de la zona de estudio, uno de los platos ha sido enterrado bajo vegetación mientras que el otro se



ha ubicado en una zona despejada, bajo suelo descubierto, manteniendo una separación entre ellos de unos 50-70 cm. Promediando los valores medidos por los dos platos se obtiene un valor final para el flujo de calor de suelo representativo de la zona de estudio. El rango de medida oscila entre -2000 y $+2000$ W m^{-2} y los sensores son capaces de trabajar en un rango de temperaturas entre -30 y $+70$ $^{\circ}\text{C}$.


- Datalogger/SAD (Meteodata 3000c, Geonica, Madrid, España): almacena los datos de toda la instrumentación meteorológica en promedios de 5 minutos. Estos datos son accesibles a posteriori mediante el uso del software TELETRANS-W3K.

La instrumentación micrometeorológica consiste en un anemómetro sónico tridimensional (USA-1, METEK, Elmshorn, Alemania) y un analizador de gases IRGA (InfraRed Gas Analyzer, Li-7500, Lincoln, NE, EEUU) tal como se aprecia en la Fig. 2.5 (der.). Ambos instrumentos trabajan con una alta frecuencia, 10 Hz. La altura de la torre EC se determina en función del área de influencia de las medidas, denominada habitualmente footprint/fetch (Moncrieff et al., 1997). Para abarcar aproximadamente toda la parcela de medidas (Fig. 2.4), la altura de dicha torre se fijó a aproximadamente 3.5 m. Además cuenta también con un datalogger (METEK) y un soporte para grabación de tarjetas de datos en el cual se almacenaron directamente los datos medidos por la torre de respuesta rápida como método de duplicación de registros para evitar huecos en la base de datos. Por otra parte, estos mismos datos instantáneos fueron transferidos mediante control remoto a la Facultad de Ciencias de la Universidad de Valladolid para ser procesados.

El anemómetro sónico mide las tres componentes de la dirección del viento y la temperatura sónica, gracias a las tres parejas de transductores que lo conforman, que se comportan como emisores y receptores de cortos pulsos ultrasónicos. Un pulso sónico se emite entre cada par de transductores. El tiempo de retardo medido en este pulso puede verse afectado por la temperatura y el radio de mezcla de los gases

atmosféricos y el vapor de agua. El rango de variación de medidas incluye temperaturas desde -40 hasta 60 °C y velocidades de 0 a 60 m s⁻¹.

El analizador no dispersivo IRGA mide densidades de CO₂ y vapor de agua. Existen diferentes tipos de analizadores IRGA (Haslwanter et al.,



2009), dependiendo del diseño y de si la trayectoria de medida es cerrada ('closed-path') o abierta ('open-path'). El analizador empleado, y mostrado en las Fig. 2.5 y 2.6, es de trayectoria o lazo abierto. El analizador IRGA contiene una fuente de luz IR en su interior (Fig. 2.6), funcionando en el rango de longitudes de onda donde el CO₂ y el vapor de agua son absorbidos. La luz emitida es recibida por un detector con una intensidad reducida con respecto al pulso inicial. Esta reducción en la intensidad depende de la concentración de CO₂ y vapor de agua. En la Fig. 2.6 se ve el camino recorrido por el rayo emitido por la fuente. El rango de operación incluye temperaturas desde -25 hasta 50 °C (Li-7500 CO₂/H₂O Analyzer. Instruction Manual. LI-COR. 2001).

Figura 2.6. Diagrama de funcionamiento del IRGA.

El LAI, Leaf Area Index, es medido con un sensor óptico (LAI-2000, Li-Cor, Lincoln, NE, USA). Este instrumento mide la diferencia entre la radiación medida sobre y bajo el dosel vegetativo, aplicando la ley de Beer-Lambert (Eq. 2.1),

$$Q_i = Q_0 \exp (-K \text{ LAI}) \quad (2.1)$$

donde Q_i y Q_0 son la radiación bajo y sobre el dosel vegetativo, y K es el coeficiente de extinción.

La atenuación de esta radiación en diferentes ángulos desde el zenith (7, 23, 38, 53 y 68°) se relaciona con la cantidad de vegetación existente. El protocolo de medida consiste en una medida sobre la vegetación (A) seguida de cuatro medidas bajo la vegetación (B), en dos repeticiones (2 A + 8B) para un mismo muestreo. Habitualmente, la serie de muestreos suele contar con un promedio de 10 medidas. Cuando el cielo está totalmente despejado, se debe utilizar un 'view-cap' para evitar la exposición directa del detector al sol. Cuando el LAI se mide sobre un cultivo, usualmente sembrado en filas, cada muestreo debería seguir los indicativos de la Fig. 2.7, para así cubrir completamente la distancia entre dos filas consecutivas del cultivo (LAI-2000 manual, 1992; Awal et al., 2006).




Figura 2.7. Secuencia de medición del LAI.

2.5 Climatología

El clima que caracteriza a esta zona, Mediterráneo-Continental (Font, 1983; Jimenez and Ibañez, 1993), cuenta con veranos cálidos y secos e inviernos fríos con abundante presencia de heladas. La temperatura media anual observada es de 11.3 °C para el periodo de medidas de 4 años (2008-2011). El rango de valores para la temperatura del aire oscila entre -10 y 36 °C, siendo éstos los valores extremos que se alcanzaron para el periodo de medidas. Como se aprecia en la Fig. 2.8, los valores más altos se alcanzan en verano mientras que los meses invernales se caracterizan por medias mensuales alrededor de 2-3 °C.

Una característica de esta zona es la irregularidad en el reparto de precipitaciones, con una mayor presencia en primavera y en otoño. Durante el periodo de medidas se ha apreciado también el aumento de precipitaciones durante el mes de diciembre para el periodo evaluado, tal como se muestra en la Fig. 2.8. La precipitación acumulada perteneciente a cada año del periodo de estudio fue 496.7 (2008), 375.3 (2009), 540.6 (2010) y 346.8 mm (2011). Considerando estos datos, se podría inferir que 2009 y 2011 presentaron una leve sequía, mientras que 2008 y 2010 se podrían considerar años lluviosos, en particular el 2010. Dado que la precipitación es uno de los factores importantes en el desarrollo de la vegetación, estos datos acumulados darían un indicativo de la producción obtenida para cada año, lo que llevaría a pensar que dicha producción debería ser menor los años para los que la disponibilidad de agua es menor. Sin embargo, el valor total de la precipitación acumulada no es el único factor que determina el desarrollo de la vegetación. El factor más influyente es quizá el reparto de las precipitaciones, puesto que los requerimientos de agua son altamente dependientes de la etapa de crecimiento en la que se encuentra la vegetación. En la Fig. 2.8 se representa el reparto mensual de precipitaciones para todo el periodo de medidas. El periodo más importante en el desarrollo vegetativo para los cultivos estudiados tiene lugar entre los meses de marzo y junio, al que denominaremos periodo de máximo interés, MIP. En este periodo el cultivo se desarrolla plenamente y, por tanto, los requerimientos de agua son mayores. Es por esto que al comparar los dos años secos, 2009 y 2011,

debemos mencionar que a pesar de que 2009 tuvo un valor total acumulado mayor que 2011, el valor acumulado para el MIP en 2009 fue mucho menor que el presente para el resto de los años. Por tanto, puede concluirse que 2009 estuvo caracterizado por una severa sequía, con consecuencias directas en el desarrollo de la vegetación.

La humedad del suelo (Fig. 2.8b), obviamente relacionada con la precipitación, sigue el mismo patrón característico que ésta, presentando valores máximos (alrededor de 40%) para el periodo primaveral. Esta es otra de las variables influyentes en el desarrollo de la vegetación puesto que representa la habilidad del suelo para retener el agua obtenida de la precipitación y que estará accesible para la vegetación a través de sus raíces.

Los promedios de la velocidad y dirección del viento están representados en la Fig. 2.9. Como se aprecia en el gráfico, la dirección predominante del viento en la zona se caracteriza por un eje WSW/SW-NE. Este eje característico se relaciona con la orografía del terreno. Las velocidades medias más altas también se presentan en este eje, con valores promedios que pueden alcanzar los 4 m s^{-1} . Las ráfagas máximas ocurren habitualmente en el periodo invernal, entre los meses de enero y marzo. Estos valores máximos pueden llegar a alcanzar entre 15 y 18 m s^{-1} , provenientes habitualmente de la dirección WSW/SW.

La última de las variables climáticas analizadas en este apartado es la radiación. Puesto que el estudio se centra en el desarrollo y caracterización de cultivos agrícolas, la radiación considerada es la comprendida en el rango 400–700 nm dentro del espectro visible, que es la utilizada para el proceso de la fotosíntesis, y por tanto para la asimilación del carbono atmosférico por las plantas. Esta radiación es denominada PAR, en unidades de W m^{-2} , y suele ser medida en forma de PPFD, en unidades de $\mu\text{mol m}^{-2} \text{ s}^{-1}$. Los factores de conversión entre ambas variables pueden encontrarse en la bibliografía (Frolking et al., 1998; http://www.licor.com/env/pdf/light/Rad_Meas.pdf). Para el periodo de medidas estudiado, la variación del PAR cada año fue similar (Fig. 2.10). Se muestran máximos de alrededor de $1000 \mu\text{mol m}^{-2} \text{ s}^{-1}$ en los meses de

julio-agosto, mientras que los mínimos, por debajo de $400 \mu\text{mol m}^{-2} \text{s}^{-1}$, se presentan de noviembre a febrero. El máximo de los promedios anuales de PAR fue muy similar para todo el periodo de medidas, siendo ligeramente más alto en 2008 y 2009. Sin embargo, si se considera el MIP, 2009 destaca como el año con mayor radiación con valores promedios levemente más altos. El incremento para la radiación en el MIP de 2009 unido a la escasa precipitación (apenas 100 mm) hace que este año quede definitivamente caracterizado por una marcada sequía, como se comentó previamente.




Figura 2.8a. Reparto mensual de las precipitaciones acumuladas y de las temperaturas promedio del aire y del suelo para todo el periodo de medidas.




Figura 2.8b. Reparto mensual de las precipitaciones acumuladas y evolución del contenido de humedad del suelo en comparación con la precipitación mensual acumulada.

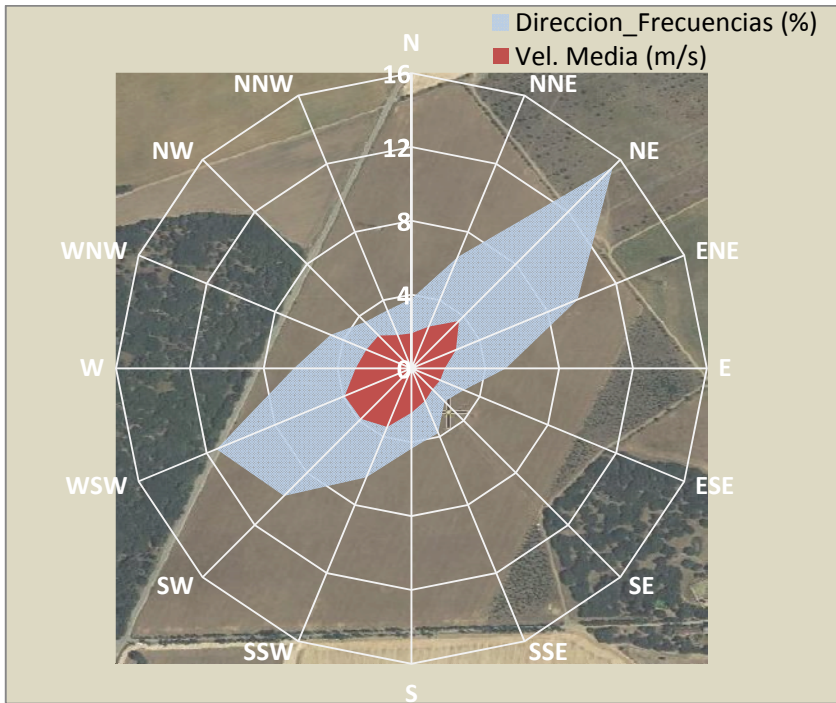


Figura 2.9. Distribución de la dirección y velocidad de viento para la parcela de medida. Datos promediados para todo el periodo de medidas comprendido entre 2008-2011.

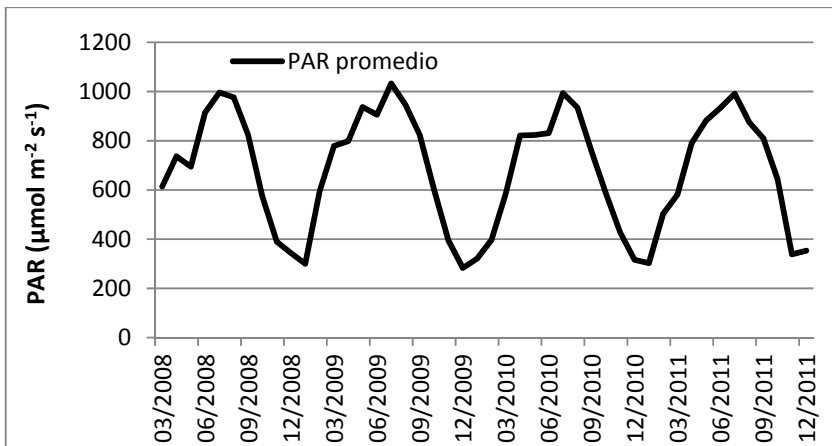


Figura 2.10. Promedios mensuales de PAR/PPFD para valores diurnos (no se ha tenido en cuenta valores nocturnos de 0) para el periodo de medidas.

Las medidas experimentales comenzaron en 2008. Sin embargo, el histórico de datos meteorológicos, de una estación cercana, registrados por el AEMET puede ser utilizado para enmarcar con mayor precisión las condiciones meteorológicas dominantes durante el periodo de medidas. Los datos utilizados pertenecen a la estación de Villanubla, a unos 8 km de la parcela de medida. Para un periodo comprendido entre 1976 y 2011 la precipitación media observada para Villanubla es de 449.697 mm y la temperatura media anual para el mismo periodo es de 11.366 °C (AEMET). La comparativa entre los valores experimentales y los promedios anuales para la precipitación acumulada y la temperatura media se representan en la Fig. 2.11. Los datos de Taire anual que aparecen representados en la figura son valores medios anuales, promediados a partir de los datos semihorarios medidos. En relación a la precipitación acumulada promedio para el periodo histórico se aprecia ,tal como ya se comentó en la primera parte de esta sección, cómo durante el periodo de medidas dos años se caracterizaron por precipitación acumulada por encima de la media mientras que los otros dos mostraron valores por debajo de dicha media. Destaca sobre todos, el año 2010 con el valor más alto de precipitación acumulada.

Si el periodo de análisis se extiende, dado que existen datos desde 1938, se puede apreciar una tendencia de descenso en la precipitación acumulada para el periodo 1939-2011 (Fig. 2.12a) con una tasa de disminución de aproximadamente 0.4 mm por año. A su vez, la tendencia para la temperatura muestra una tasa de crecimiento de aproximadamente 0.008 °C por año (Fig. 2.12b) lo que implica un aumento neto de aproximadamente 0.568 °C en un periodo de 71 años.

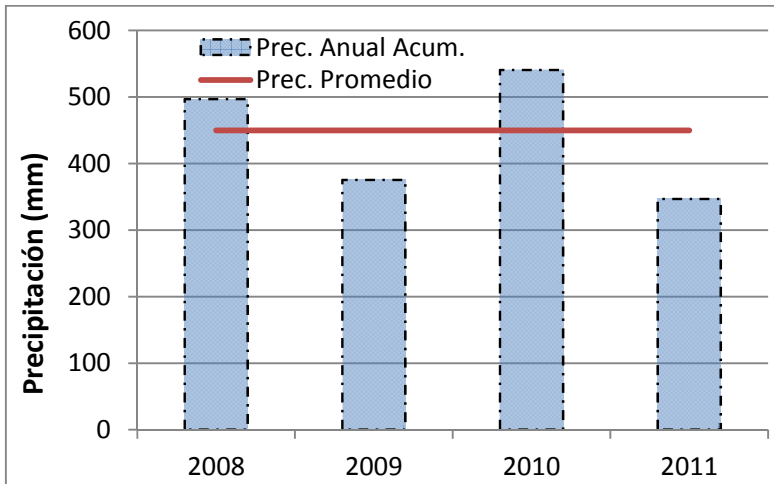


Figura 2.11a. Comparativa de la precipitación total acumulada, para cada uno de los cuatro años de medidas, con respecto al dato promedio de la precipitación acumulada para un periodo de 35 años en Valladolid obtenido de datos registrados por la AEMET.




Figura 2.11b. Comparativa de la temperatura del aire experimental, en promedios anuales para el periodo de medidas, y el valor promedio para un periodo de 35 años de la temperatura del aire obtenido para Valladolid a partir de datos de la AEMET.




Figura 2.12a. Evolución temporal de los datos históricos elaborada a partir de los registros de la AEMET para la estación de Villanubla para la precipitación anual acumulada.




Figura 2.12b. Evolución temporal de los datos históricos elaborada a partir de los registros de la AEMET para la estación de Villanubla para la temperatura media anual.

2.6 Procesado de los datos EC

El movimiento de las masas de aire dentro de la capa límite atmosférica está gobernado por la turbulencia atmosférica. Este es el principal mecanismo de transporte dentro de esta capa. Dicha turbulencia es también la base de las medidas que realiza el sistema EC para la determinación de las concentraciones/densidades de CO₂ y vapor de agua presentes en la capa de aire medida. La técnica EC se basa en calcular las diferentes correlaciones entre los cambios en la velocidad vertical del viento y diferentes magnitudes escalares para determinar el intercambio de CO₂, energía/temperatura (calor sensible) y masa/agua (calor latente). La alta frecuencia utilizada en las medidas, 10 Hz, permite obtener cada cambio en estas cantidades escalares debido a la turbulencia atmosférica.

Con relación al transporte turbulento, existe una relación básica utilizada para medidas micrometeorológicas, la descomposición de Reynolds. Esta relación es la base de la técnica EC y consiste en separar las fluctuaciones de los valores promedios:

$$a = \bar{a} + a' \quad (2.2)$$

donde \bar{a} es el valor promedio y a' es el término relacionado con las fluctuaciones en el movimiento turbulento.

El flujo vertical de una magnitud puede representarse por medio de la Eq. 2.3, donde w es la componente vertical de la velocidad de viento, y s es la concentración de una magnitud escalar. Si a las variables que participan en esta expresión se les aplica la descomposición de Reynolds, definida previamente, y se tienen en cuenta valores promedio, obtenemos la Eq. 2.4, donde ρ_a es la densidad del aire. La barra horizontal superior indica el valor medio de la variable y el símbolo $'$ indica desviaciones en los valores instantáneos. Las Eqs. 2.5 y 2.6 introducen todos los parámetros necesarios para la conversión en unidades de energía de los diferentes valores, C_p en Eq.2.5 y λ en la Eq. 2.6 (Burba and Anderson, 2005-2010).

$$\text{flux} \approx w s \quad (2.3)$$

$$\text{flux} \approx \overline{\rho_a w' s'} \quad (2.4)$$

$$H = \rho_a C_p \overline{w' T} \quad (2.5)$$

$$LE = \lambda \rho_a \overline{w' e'} \quad (2.6)$$

$$F_C = \overline{w' \rho_a c'} \quad (2.7)$$

donde ρ_a es la densidad del aire, T es la temperatura virtual, y c y e son las densidades de CO_2 y vapor de agua.

Los datos brutos son procesados utilizando un software específico desarrollado en la Universidad de Bayreuth, el programa TK2 (Mauder and Foken, 2004), para obtener promedios de 30 minutos. Además, cuando se dispone de un analizador de lazo abierto ('open-path') como el que hemos utilizado, los cambios en la temperatura y presión pueden afectar a la intensidad medida, por tanto una de las correcciones más importantes en los datos, denominada Webb-Pearman-Leuning, WPL, es aplicada durante el procesado de datos para evitar fluctuaciones en las densidades medidas (Aubinet et al., 2012). Sin embargo, estos datos procesados aún pueden presentar datos anómalos o huecos. Los huecos pueden ser rellenados mediante parametrización de los valores medidos, y los datos anómalos deben ser eliminados. Estos datos anómalos son originados por los diversos problemas que pueden aparecer durante la adquisición de datos, entre los que cabe destacar los fallos de suministro eléctrico, las labores de mantenimiento de la instrumentación, o las condiciones meteorológicas adversas tales como eventos de precipitación o heladas. Estos últimos afectan en particular a la medida del LE por parte de la instrumentación, devolviendo valores inusualmente altos en el caso de eventos de precipitación, por ejemplo. Estos datos deben ser depurados para obtener una base coherente y correcta de datos. Del mismo modo, en el caso de los flujos de CO_2 es la baja turbulencia la que puede devolver valores anómalos, en especial en periodo nocturno. Para evitarlos, se utilizó un umbral para los valores de la velocidad de fricción, también medida, por

debajo del cual los datos nocturnos de los flujos de CO₂ se consideraron no válidos. Este umbral se fijó en 0.15 m s⁻¹.

CAPÍTULO 3. BALANCE DE ENERGÍA

Based on the paper entitled

‘Energy balance and partition over a rotating rapeseed crop’,

submitted for its publication to Agricultural and Water
Management.

N. PARDO¹, M. L. SÁNCHEZ¹, I. A. PÉREZ¹, M. A. GARCÍA¹

¹Department of Applied Physics, University of Valladolid, Valladolid, Spain

Resumen

La calidad de largas series de datos EC es habitualmente evaluada mediante el estudio del cierre en el balance de energía, dado por la expresión:

$$R_N - G_p = H + LE + \sum Q \quad (3.1)$$

donde el término $\sum Q$ puede contener diferentes términos de almacenamiento de energía. El cierre en el balance de energía vendrá dado por la pendiente (a) de la regresión dada por la expresión

$$H + LE + G_p = a \times (R_N) + b \quad (3.2)$$

cuando se ignoran todos los posibles términos de almacenamiento contenidos en $\sum Q$. Cuando se tiene en cuenta algún término de almacenamiento como es el caso de la inclusión del término de almacenamiento de calor en el suelo, G_s , tenido en cuenta en este estudio, la expresión vendrá dada por

$$H + LE + G_p + G_s = a \times (R_N) + b \quad (3.3)$$

Para la serie temporal obtenida durante el periodo de cuatro años estudiado el análisis de dichos datos se realizó mediante la evaluación del cierre en el balance de energía mencionado previamente. Los cálculos se realizaron de forma independiente, por una parte para una base de datos global cubriendo los cuatro años de estudio y los cuatro cultivos, y por otra para cada una de las series de datos individuales pertenecientes al cultivo/año correspondiente. El análisis fue realizado también para el MIP. Utilizando la base de datos global se encontró que el cierre en el balance de energía alcanzó un 86%. Un valor similar del 87% se obtuvo cuando el periodo de estudio fue limitado al MIP. El cierre del balance de energía mejoró notablemente cuando el flujo G_p fue corregido añadiendo a dicho flujo el término de almacenaje de energía en el suelo (ver sección 3.2) calculado como sigue:

$$G_s = C_s \frac{\Delta T_s}{\Delta t} z = (\rho_b C_{sd} + \rho_w \theta_v C_{sw}) \frac{\Delta T_s}{\Delta t} z \quad (3.4)$$

Con esta corrección se obtuvo un cierre del 92 y 93% (Fig. 3.4), para la base de datos global y el MIP, respectivamente.

Además, el reparto de energía entre los diferentes procesos tenidos en cuenta evidenció diferentes resultados dependiendo del periodo de estudio seleccionado. Cuando la base de datos global fue considerada, H habitualmente jugó el principal papel en el reparto de la energía. Sin embargo, durante el MIP, LE se convirtió en el principal disipador de energía mientras que el cultivo alcanzó su pleno desarrollo para este periodo. Las más altas contribuciones de LE al balance de energía se encontraron para la colza y el centeno, los dos cultivos con mayor altura de entre todos los estudiados.

En las Fig. R.3.1 y R.3.2 se presentan los promedios horarios y mensuales, respectivamente, para todas las variables tenidas en cuenta en el estudio. En ambos gráficos queda comprobada la falta en el cierre de energía al quedar la línea que representa la radiación, R_N , por encima de la suma total del resto de los flujos. Por otra parte, se puede apreciar la influencia ya comentada del desarrollo de la vegetación en el reparto de energía observándose cómo va cambiando, en particular, la contribución de H y LE en el patrón estacional mostrado en la Fig. R.3.2.

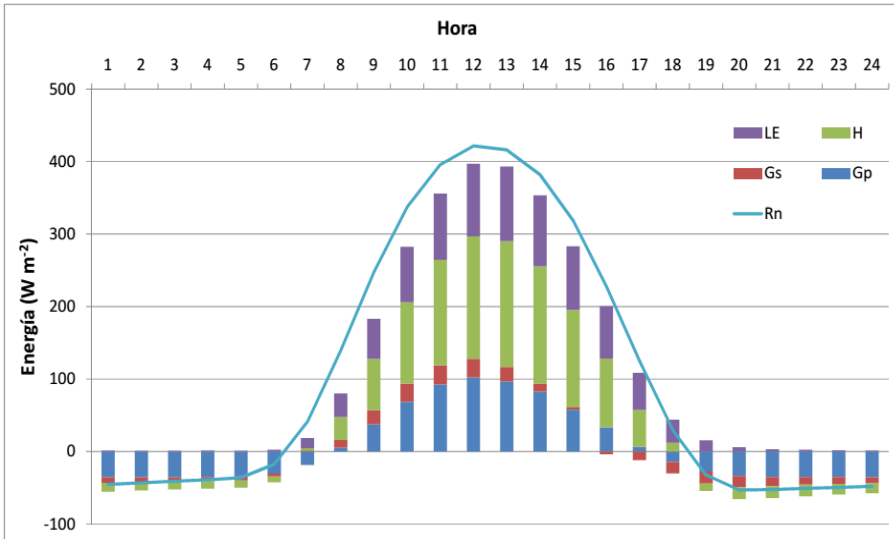


Figura R.3.1. Evolución horaria de los valores promedios para el periodo de medidas de cuatro años para la radiación y el resto de flujos de energía.




Figura R.3.2. Evolución mensual de los valores promedios para el periodo de medidas de cuatro años para la radiación y el resto de flujos de energía.

Abstract

The quality of long-term eddy covariance data was evaluated by calculating the energy balance closure. The study was conducted in a single plot over four different years and crop types (rapeseed, wheat, peas, and rye) included in a rotation scheme governed by rapeseed. Calculations were made separately for a global dataset covering the whole four year/crop period and for each individual dataset belonging to each year/crop. The analysis was also carried out for the crop growing season (hereafter referred to as the maximum interest period –MIP–). An imbalance of 14% was found when using the global dataset. A similar value of 13% was also obtained when the study period was limited to the MIP. A marked improvement was found in the energy balance closure when soil heat flux, G_p , was corrected for soil energy storage. With this correction, a 92% and 93% closure emerged when the global dataset and MIP were studied, respectively. In addition, the energy partitioning in the various processes evidenced different results depending on the selected study period. When the global dataset was considered, sensible heat, H , usually played the main role in the energy partitioning. However, if only the MIP was selected, latent heat, LE , became the main driver dissipating energy while the crop reached full development for this period. The highest LE contributions to the energy balance were found for rapeseed and rye.

Keywords: Rapeseed, Eddy Covariance, Energy Balance, Energy Balance Closure, Energy Partitioning

3.1 Introduction

Agricultural croplands play an important role in the global carbon cycle due to photosynthetic processes. Identifying their behavior as sinks (e.g., Bhattacharyya et al., 2014; Dufranne et al., 2011; Hollinger et al., 2005; Lei and Yang, 2010a) or sources (e.g., Béziat et al., 2009; Zeri et al., 2011) of CO₂, and quantifying stored C have thus become the main challenges in recent years. For this purpose, micrometeorological techniques are employed, with the eddy covariance (EC) technique being the most widely used of all the available micrometeorological methods. The most important feature of an EC system is measuring CO₂, energy, and water exchange between ecosystem and atmosphere. Quality evaluation of these EC data is thus the main concern, and is usually assessed by evaluating the energy balance closure (Barr et al., 2006).

The energy balance closure is based on energy conservation. This should lead to the available energy in an ecosystem equaling the energy involved in the various processes that transport energy between the surface, ecosystem, and atmosphere. This principle is described by the following equation,

$$R_N - G_p = H + LE + \sum Q \quad (3.1)$$

where R_N is the net radiation, G_p is the soil heat flux at measurement depth, and H and LE are the sensible and latent heat fluxes, respectively. Particularly, over a vegetated surface the residual term $\sum Q$ might include energy storage terms such as soil heat storage term (G_s), energy storage related to photosynthetic and respiratory processes (Shuttleworth, 2012), heat storage in the air and biomass (Meyers and Hollinger, 2004), or advection terms (Heusinkveld et al., 2004). $\sum Q$ not taken into account in Eq. 3.1 but related to ecosystem processes might thus lead to a lack of closure. Difficulties in measuring or calculating these terms, coupled with the fact that their influence on the energy balance varies enormously depending on canopy features, usually leads to them being ignored in energy balance studies (Shuttleworth, 2012). However, in recent years, greater importance has been given to calculating these storage terms due

to their involvement in the energy balance calculated by Eq. 3.1. Of all the storage terms, the most widely considered factor has been the soil energy storage term, particularly when high soil moisture is present (McCaughey, 1985).

For an accurate evaluation of EC data quality, long-term periods are usually selected. Several ecosystems and locations have been studied as a means of evaluating the energy imbalance, and analyzing the influence that different ecosystems and geographical locations have on it. Much research has been conducted over forests (e. g., Barr et al., 2006; Kidston et al., 2010; Oliphant et al., 2004; Sun et al., 2010) although less over grasslands/steppe/dunes or similar (e. g., Chen et al., 2009; Hammerle et al., 2007; Heusinkveld et al., 2004; Runkle et al., 2014). Several studies have also been carried out over different crops, including maize and soybean (Meyers and Hollinger, 2004), wheat/maize (Lei and Yang, 2010b), and corn/sunflower (Liu et al., 2008).

In this study, we aim to evaluate the energy balance over crops which have rarely been studied, such as rapeseed (Guy et al., 2014) or rye (Hauggaard-Nielsen et al., 2012). Today, rapeseed is one of the most widely used feedstocks in biofuel production, said production from agricultural crops like rapeseed having increased substantially in recent years. At present, biofuels are used as an alternative to fossil fuels (Xue et al., 2013) whose adverse impact on the environment has been widely documented (IPCC, 2013). Biofuel crop contribution to the carbon cycle can thus be considered of great importance, and a more detailed study of these crops might prove helpful in later studies. Furthermore, Europe is one of the world's leading rapeseed producers (faostat.fao.org/site/339/default.aspx). In Spain in particular, rapeseed production and the area devoted to growing it have increased since 2007, with 2011 production figures doubling those of 2007. Moreover, the region of Castilla y León, where this study was performed (Fig. 3.1), has headed national rapeseed production since 2007 (MAGRAMA, 2013). This leads to increasing interest in understanding the global behavior of this crop, not only as regards energy but also water and carbon budgets.

The studied rotating scheme for rapeseed included other crops which are also characteristic of the studied region and even the whole country such as rye, peas, and wheat. In the literature, wheat has relatively frequently been analyzed, although rapeseed, peas, and rye have thus far received little attention. This adds interest to the present study, since a full analysis for all these crops is here described for a continuous long-term period.

The main objectives that this chapter seeks are to:

- 1) assess and quantify all components of the energy balance over an agricultural rotating crop field using a long-term data series.
- 2) evaluate the energy balance closure for the studied ecosystem.
- 3) compare the energy balance closure results for a full year versus the growing season (MIP) data.
- 4) analyze some of the most studied sources affecting the energy balance closure.
- 5) characterize energy partitioning for several crop types and varying environmental conditions.

3.2 Material and methods

3.2.1 Measuring site

The study area where measurements were conducted (41°46'44.4" N, 4°52'19.19" W, 849 m a.m.s.l) is located in the upper Spanish plateau, some 30 km from Valladolid in the region of Castilla y León (Fig. 3.1). This semi-arid region is characterized by a Mediterranean-Continental climate (Font, 1983; Jimenez and Ibañez, 1993).




Figure 3.1. Full Landcover map (MODIS product MCD12Q1) of Spain taken from tiles (h17v04, h17v05, h18v04 and h18v05) covering the whole country. Orange colour, surrounding the measuring site, indicates croplands.

The meteorological diagram depicted in Fig. 3.2 shows monthly cumulative precipitation, and average monthly soil and air temperature throughout the study period. Minimum temperatures were recorded in winter, particularly in January or December, and maximum temperatures in July and August. Interannual variability of air and soil temperature was small during the 4-years study period, with annual mean air and soil temperatures of 11.3 °C and 13.2 °C, respectively. Extreme air temperature values can drop as low as -10 °C or reach up to around 36 °C (not shown).

As shown in Fig. 3.2, precipitation was not evenly distributed throughout the year, but occurred mainly in spring (April to June) and again in October, November, or December depending on the year. The meteorological diagram also evidences the lack of precipitation in summer. The highest precipitation appeared in April-May 2008, December 2009, and December 2010. Average annual accumulated precipitation was 449.7 mm

for a period covering 1976-2011 (Spanish Meteorological Agency, AEMET). Cumulative annual precipitation during the study period varied widely with values of 496.7 (2008), 375.3 (2009), 540.6 (2010), and 346.8 mm (2011).




Figure 3.2. Meteorological diagram for the 2008-2011 period, where the cumulative monthly precipitation (P_monthly), and the average monthly air (Tair_aver) and soil (Tsoil_aver) temperatures are displayed.

The MIP, defined in this study from March to June, was considered the most important period in plant growth. During this time, the crop reaches full development, with water availability thus being one of the main factors influencing said development. Monthly precipitation distribution during this period also varied widely depending on the year of study. Cumulative values for this period were: 236.8 (2008), 105.6 (2009), 202.3 (2010), and 160.8 mm (2011). As regards accumulated precipitation during the MIP, 2009 was the driest year. As depicted in Fig. 3.2, this might be mainly influenced by the lack of precipitation in March 2009, as well as low

precipitation the rest of the period, compared to the same period of the other years in the study.

The farmland where the study was performed covers about 400 ha, and has no surrounding relief elements. The studied farmland is divided into single plots. The sampling plot (Fig. 3.1 and 2.4) where the instrumentation was installed covers about 36 ha. Land use consists of non-irrigated crops. Soil composition is sandy loam with an organic content of between 60-65% sand, 20% clay, about 15% silt, and about 3% organic matter. Land management involves reduced tillage practices.

The studied rotation cycle included the most representative crop types in the region: rapeseed, wheat/barley, peas, and rye. These non-irrigated crops were seeded in late September (rapeseed), early November (wheat), late January (peas), and late October (rye). Harvest was about mid-July the following year depending on crop development and growth. Crop height varied depending on crop type. The tallest crops were rapeseed and rye, 1.30 and 1.60 m, respectively, while wheat (around 0.70 m) and peas (around 0.50 m) were the shortest. Since each crop took only a few months to grow, in the fallow period, which spanned harvest to the following seed time, the soil only presented residue coverage. This is one of the main characteristics of the reduced tillage used in the studied farmland.

3.2.2 Instrumentation and data

Measurements have been conducted continuously in the sampling area since March 2008, employing an EC system and meteorological instrumentation. Data were steadily recorded throughout the whole study period with the exception of July to September 2011, when EC instrumentation was not operating, and only meteorological data were recorded.

The EC system was located on a tower 3.5 m above surface. This system consists of a three-dimensional sonic anemometer (USA-1, METEK), measuring wind velocity and sonic temperature, and an open-path IRGA (InfraRed Gas Analyzer, LI-7500, Li-Cor) measuring CO₂ and water vapour concentration, with a sampling frequency of 10 Hz. TK2 software

(Mauder and Foken, 2004) developed by Bayreuth University was used on raw data to ensure initial data quality, by applying the WPL (Webb–Pearman–Leuning) correction to avoid density fluctuations (Webb et al., 1980). After this correction, reliable LE and H together with CO₂ exchange were obtained from the measured EC data as half-hourly averages from instantaneous data.

The other two components of the energy balance, R_N and G_p , were measured with a net radiometer (type 8110, Ph. Schenk) at 1.5 m above surface, and two soil heat flux plates (HFP01, HukseFlux Inc.) buried about 5 cm below the soil surface, respectively. The G_p value was obtained by averaging measurements of both plates, one buried under bare soil and the other under vegetation.

Ancillary meteorological data were also measured: air temperature and humidity (model STH-5031, Geónica and model 41003 multi-plate radiation shield, R. M. Young Company), soil moisture (Type ML2x, ThetaProbe), soil temperature (model STS-5031, Geónica), wind speed and direction (Wind sentry model 03002, Young, Campbell Scientific, Inc.), and photosynthetically active radiation (PAR) measured with a quantum sensor (LI-190Sz, Li-Cor Inc.).

3.2.3 Methodology

Several methods have been described to calculate the energy balance closure in the literature (Wilson et al., 2002a) although the most widely employed is the one used in this study. This method relies on Eq. 3.1 and consists of linear regression analysis which calculates the relationship between energy fluxes and available energy. As referenced in the literature (Baldocchi et al., 2004; Berbigier et al., 2001; Heusinkveld et al., 2004; Lindroth et al., 2010), this relationship is given by

$$H + LE + G_p = a \times (R_N) + b \quad (3.2)$$

The sum of H , LE , and G_p was plotted against the R_N , and the slope (a) and the intercept (b), characterizing the energy balance closure, were calculated.

To test the contribution of the soil heat storage (G_s) to the energy balance, this term was added to Eq. 3.2 and the energy balance closure was calculated once again by applying the new equation,

$$H + LE + G_p + G_s = a \times (R_N) + b \quad (3.3)$$

The G_s term is strongly related to soil temperature and moisture, and is usually calculated from an equation as follows (Liu et al., 2008; Meyers and Hollinger, 2004; Shao et al., 2008),

$$G_s = C_s \frac{\Delta T_s}{\Delta t} z = (\rho_b C_{sd} + \rho_w \theta_v C_{sw}) \frac{\Delta T_s}{\Delta t} z \quad (3.4)$$

where the temporal interval is denoted by Δt (1800 s), and the depth at which G_p is measured directly with the plates is 0.05 m (denoted by z). C_s is the soil heat capacity, ρ_b (1300 kg m⁻³) is the bulk density of the soil, ρ_w (1000 kg m⁻³) is water density, and, C_{sd} (840 J kg⁻¹ K⁻¹) and C_{sw} (4190 J kg⁻¹ K⁻¹) are the specific heats of dry mineral soil and soil water, respectively. Soil temperature, T_s , and volumetric water content, θ_v ,

were measured experimentally and soil/water physical parameters in Eq. 3.4 are typical values found in the literature for sandy loam soils (Cook et al., 2004).

The final value for the total ground heat flux, G , was hence obtained by adding the calculated G_S to the measured G_P .

Since the dataset contained half-hourly average data from all the instantaneous measurements for all variables, these data were used directly in the linear regression (Eq. 3.2 and 3.3). Data for the whole day -daytime and nighttime- were used after exhaustive dataset processing where LE values belonging to precipitation events, instrumentation failures, or remaining noisy values, were removed from the dataset. Gap filling was only applied for isolated half-hourly points in the dataset by interpolating the previous and following values. Longer gaps were not filled so as not to introduce further uncertainties into the dataset (Wilson et al., 2002b). Half-hourly data used to calculate the energy balance closure by linear regression were only those for which all components of the energy balance were available.

Given the importance of the role played by the various components of the energy balance, particularly during the growing stages of the crop, various periods were evaluated. Hence, these periods included the 4-year study global period, each yearly period, and the MIP. Finally, the energy partitioning was performed among all the components of the energy balance. This method was used to compare the importance of the various processes related to the ecosystem. The energy transported by the various fluxes was thus calculated for the whole period and for each single year. Furthermore, the energy partitioning was also calculated for the MIP so as to evaluate the contribution of each energy flux over this period.

3.3 Results and discussion

3.3.1 Description of the behavior of energy fluxes

The behavior of the components involved in the energy balance is shown in Fig 3.3. In these graphs, average values have been calculated from the four-year half-hourly dataset used in this study, and ensemble-average hourly and seasonal patterns are shown in Fig 3.3a and Fig. 3.3b, respectively.

Maximum hourly average values (Fig. 3.3a) for R_N and G were reached at 11:00 h (GMT), whilst H and LE peaked one hour later at 12:00 h (GMT), yielding about 422 W m^{-2} (R_N), 131 W m^{-2} (G), 173 W m^{-2} (H) and 103 W m^{-2} (LE). A further feature in the hourly behavior of these components is the characteristic sign which appears during the day. During the daytime period, $PAR > 0$, all components displayed positive values, which indicated: H and LE fluxes away from the surface, energy absorbed by the soil in the case of G , and net heating in the case of R_N . Negative values were usually recorded during the nighttime period, $PAR = 0$, which on average covered the time period between 18:00 and 05:00 h (GMT), although these hours might vary depending on the season. Minimum values were found in this period for R_N (around -53 W m^{-2}), G (approximately -51 W m^{-2}), and H (about -17 W m^{-2}). Values taken for LE during nighttime were close to 0, with mean values rarely being negative, giving values around 2 W m^{-2} .

Regarding the seasonal pattern (Fig. 3.3b), maximum R_N and LE values were reached in June, coinciding with the final growing stage of the crop. However, maximum values for H and G were found later, in July. Maximum average values for R_N and LE were around 190 and 80 W m^{-2} , respectively. It should be noted that the maximum average value for LE reached in June was similar for May and was a little lower in April. These months might be considered the most important in crop development since crop reaches its full growth. Particularly, flux behavior during the MIP period reflects the environmental conditions in which the crop is growing together with its development, which have a major influence on final yield.

In late June and early July, the crop commences its senescence period which was reflected in the behavior of the energy fluxes, particularly in the H and LE courses. Maximum H value was reached in July after harvest with a value around 107 W m^{-2} , coinciding with lower LE values. Minimum average values were found in winter for all energy components except LE, which reached its minimum in August. High H values, as well as minimum LE values (around 10 W m^{-2}) in summer, were observed due to dry conditions for this period because of lack of precipitation and cover vegetation, and high temperatures (Fig. 3.2).

G values evidenced no major variation in magnitude during the year as depicted in Fig. 3.3b, ranging from -9 to 21 W m^{-2} approximately, although a slight increase was evident in summer, peaking in July. It should be noticed that G seems to show another peak in April with values around 13 W m^{-2} , showing a slight decrease in magnitude in May, likely because of the full development of the canopy which intercepted the most radiation (Clothier et al., 1986). During the early stages of crop development in winter, average G values became negative, due to adverse meteorological conditions. For these months, soil and air temperatures decreased (Fig. 3.2) and frost events had a major influence on G values as shown in Fig. 3.3b. This evidences the key influence of temperature on G values, since soil released more energy (more negative values), due to low air temperatures that might drop below soil temperature in this period, as shown in Fig. 3.2.

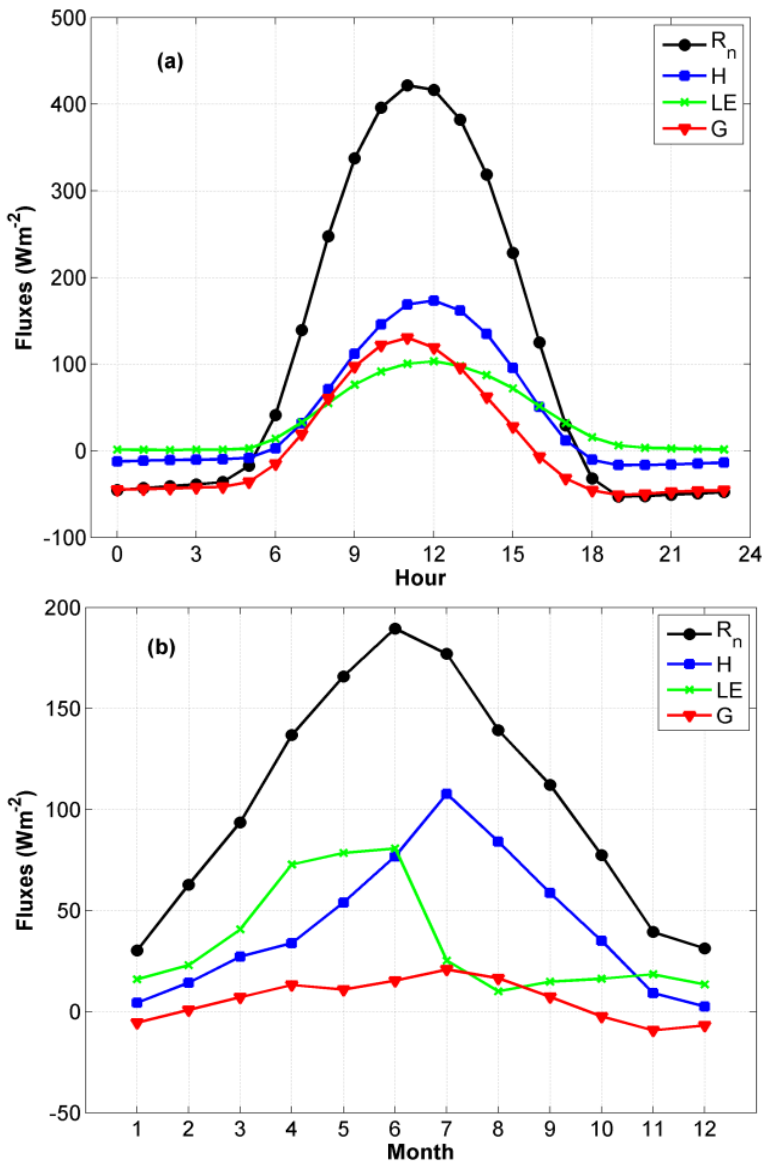


Figure 3.3. Energy balance components (ensemble-average) behavior for years from 2008 to 2011. a) Hourly average pattern. b) Average monthly course. G indicates the total soil flux calculated by adding the soil heat flux (G_p) measurements and the calculated (Eq. 3.4) soil heat storage (G_s).

3.3.2 Energy balance closure

Following the methodology described in Section 3.2.3, the energy balance closure was calculated by Eq. 3.2 and Eq. 3.3 and evaluated over two different periods: the whole year (Fig. 3.4a, 3.4c) and the MIP (Fig. 3.4b, 3.4d).

The results displayed in Fig. 3.4a and Fig. 3.4b revealed similar energy balance closure whether the study was performed for the whole year (0.86, $R^2=0.95$) or the MIP (0.87, $R^2=0.95$). An imbalance of around 14 and 13%, respectively, thus represents the amount of energy not partitioned in either process taken into consideration in Eq. 3.2. As regards a comparison between the two study periods, the slope found for the MIP increased slightly compared to the value found for the whole year fit, although said increase only represented an improvement of 1 percentage point (pp).

When applying the correction to G_p (Eq. 3.3) by adding the storage term G_s (Eq. 3.4), a new and improved energy balance closure was obtained. These results are shown in Fig. 3.4c (whole period) and Fig. 3.4d (MIP). In the whole four-year period, a closure of 0.92 was obtained, meaning an improvement of 6 pp in the energy balance closure. The same improvement was obtained when the MIP was studied, with a closure of 0.93.

Furthermore, due to the wide variety of crops and environmental conditions considered during the study period, an evaluation of each single year/crop was performed. The similar results obtained for the whole period and the MIP (Table 3.1) suggest that crop development had no major influence on the energy balance closure, agreeing with results reported by Wilson et al. (2002a) which revealed that vegetation height did not influence the closure values.

As shown in Table 3.1 and Fig. 3.4, a lack of closure was found regardless of the study period. This lack of energy balance closure has been also reported in previous studies for agricultural ecosystems. In a wide study performed by Wilson et al. (2002a), twenty-two sites were evaluated, and among those sites two agricultural lands can be found.

Results obtained included a mean slope of 0.79 and a mean intercept of 3.7, with a mean correlation coefficient, R^2 , of 0.86.

A double cropping system (irrigated wheat/maize) was evaluated by Mo et al. (2012), the imbalance for each studied year showing values ranging between 23-36%. Hernandez-Ramirez et al. (2010) calculated the energy balance closure for soybean and corn for a long-term dataset with mean slope values of 0.74 (corn) and 0.75 (soybean) over a four-year period. Liu et al. (2008) analyzed the energy balance closure for a cropland (corn/sunflower) in China during the daytime period with a mean imbalance of about 22%.

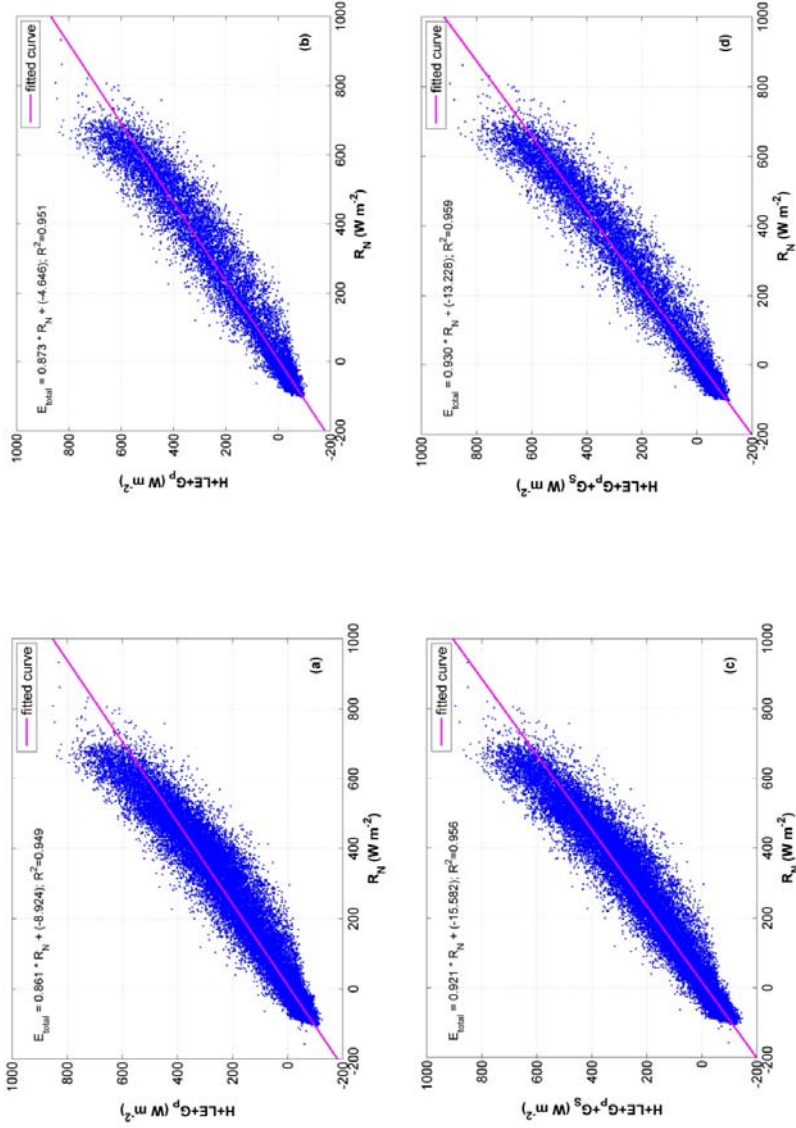


Figure 3.4. The energy balance closure for half-hourly values including years from 2008 to 2011, using: a) G_p including the whole study period, b) G_p considering the MIP, c) G_s and G_p including the whole study period, and d) G_s and G_p considering the MIP.

Table 3.1. Linear regression parameters for the energy balance closure calculated by applying Eq. 3.2 and Eq. 3.3. Units of the intercept, b , are $W\ m^{-2}$. The slope, a , indicates the closure in the energy balance calculated from the 30-min average values.

			2008	2009	2010	2011
$H + LE + G_p = a \cdot R_N + b$	Yearly Period	a	0.89	0.90	0.83	0.82
		b	-2.68	-10.13	-10.44	-11.61
		R²	0.96	0.96	0.95	0.93
	MIP	a	0.91	0.91	0.84	0.84
		b	1.30	-6.02	-3.81	-8.64
		R²	0.97	0.96	0.96	0.94
$H + LE + G_p + G_s = a \cdot R_N + b$	Yearly Period	a	0.95	0.96	0.90	0.87
		b	-9.03	-17.16	-18.13	-16.93
		R²	0.96	0.97	0.96	0.94
	MIP	a	0.95	0.97	0.92	0.89
		b	-4.74	-14.67	-15.15	-16.50
		R²	0.97	0.97	0.97	0.94

3.3.3 Analysis of the main sources of lack of energy balance closure

The usual imbalance found in all energy balance closure studies necessitates an explanation for this lack of closure. In this section, we aim to evaluate several different sources proposed in the literature to explain the imbalance, also found in this study as described in Section 3.3.2.

3.3.3.1 Source 1: Uncertainties in EC/ Error in EC measurements

One of the main sources cited in the literature was underestimating turbulent fluxes measured by EC instrumentation due to sampling errors, or the various corrections that might be applied to the raw data such as the WPL correction commented in Section 3.2.2 (Foken, 2008; Mudge et al., 2011).

Snow, rain, frost, fog, or dirtiness in the IRGA window might also impact the measurements. As commented in Section 3.2.3, anomalous values belonging to these events were removed in order to not impact the measurements or the energy balance closure.

The footprint (Sánchez et al., 2010b) characterizing EC measurements might also impact on the measurements. As stated in Section 3.2.1, the sampling plot owns horizontal homogeneity. Besides, the EC tower was placed in the middle of the plot and its height led to obtain a footprint covering the whole plot. Therefore surrounding elements or vegetation should not impact the measurements.

3.3.3.2 Source 2: Weak turbulence

Another explanation for the imbalance is weak turbulence, particularly at nighttime, which might lead to EC measurement underestimating the overall flux and proving less accurate data (Tanaka et al., 2008; Wilson et al., 2002b). One common criteria for filtering EC data to ensure their quality relies on discarding nighttime data under low friction

velocity values, u_* , since said low turbulence strongly influences H, LE, and CO₂ fluxes (Gilmanov et al., 2007). Previous research has studied the influence of u_* values on the energy balance closure (e. g., Tanaka et al., 2008), in particular at nighttime (Barr et al., 2006). In this chapter, the influence of u_* on the energy balance was analyzed by applying a threshold to the dataset. All data whose $u_* < 0.15 \text{ m s}^{-1}$ during the nighttime period (PAR=0) were thus removed. A slight improvement of less than 1 pp was found regarding the values obtained in Section 3.3.2. Similar results were obtained when the threshold selected was 0.20 m s^{-1} . This result suggests the slight influence of low turbulence events on energy balance during the nighttime. This might be due to the low values of all the energy balance components during that period, which makes these values have less weight in the final balance compared to daytime values. As R_N takes small negative values during this period, underestimating turbulent fluxes might not affect the energy balance closure to a large degree, as is evidenced in the results for this study. Particularly, the energy balance closure differs in about 2 pp whether the calculation is made together for diurnal and nocturnal values or only for diurnal values (not shown), which suggests the better energy balance closure for the daytime data.

3.3.3.3 Source 3: Unrepresentativeness of the soil heat measurements

The well known lack of representativeness of soil heat flux plates for measuring G_p has been also argued as a source of imbalance (Bi et al., 2007; Wilson et al., 2002a). Because of this issue, G_p values are usually underestimated and might thus influence the energy balance closure. G_p underestimation measured with plates could reach over 20% compared to other methods (Ochsner et al., 2006), and might therefore lead to a worse energy balance closure.

The area influencing the soil heat flux plate measurements is smaller regarding the source area or footprint for the net radiometer or EC instrumentation. This fact might lead to a horizontal unrepresentativeness of the soil heat measurements, with likely influence on the energy balance

closure. Likewise, due to the measuring device composition, the instrumentation can not be placed directly at the soil/air interface, and therefore a vertical unrepresentativeness does also exist.

3.3.3.4 Source 4: Missing storage values

A further widely studied source of imbalance concerns missing storage values taken into consideration in the energy balance equation (Eq. 3.1). These terms are rarely available for most sites.

McCaughey (1985) summarized the various empirical equations that might be employed to calculate the various storages terms. However, several of them require data that are not available in this study such as biomass temperature or vegetation mass. Besides, of all the possible storage terms that might be considered in Eq. 3.1, the soil storage term shows the strongest overall influence (Foken, 2008; McCaughey, 1985; Oliphant et al., 2004). The remaining storage terms might have a greater influence over tall canopies (Sánchez et al., 2010b) than in croplands. Therefore, in this study the influence of storage terms has relied on calculating the soil storage term.

As evidenced by results obtained in Section 3.3.2, addition of G_S to the energy balance (Eq. 3.3) had a large impact on the energy balance closure. By considering this storage term, only a small part of the energy balance closure (8% in the whole four-year period, and 7% in the MIP case) remains without explanation.

Zeri et al. (2011) reported similar results for other biofuel crops with a closure of 0.88 for soybean and an intercept around -22 W m^{-2} , when considering G_S and the photosynthesis storage term; although the period chosen for evaluation in that study was shorter than the one selected in this thesis. Satisfactory results were found by Lindroth et al. (2010) over a forest ecosystem, and Sánchez et al. (2010b) also reported a significant improvement of 6 pp in the energy balance closure over a forest by adding this soil storage term to the energy balance.

If the various storage terms are considered separately, their contribution to the energy balance is small regarding turbulent and soil heat fluxes (Zeri et al., 2011). However when several of them are taken into account in Eq. 3.1, the imbalance in the energy balance might remain small, as reported by Meyers and Hollinger (2004). They found a marked improvement in closure taking various storage terms (ground, biomass, and photosynthesis) into consideration in the energy balance over maize and soybean.

3.3.3.5 Source 5: Seasonality and environmental conditions

To assess the influence of environmental conditions on the energy balance closure, a monthly energy balance closure was also performed (Fig. 3.5).

On a monthly basis, seasonal variation of closure was similar to the R_N seasonal pattern. Average monthly closure (Fig. 3.5) ranged from around 0.60 to near 1. Furthermore, a similar energy balance closure pattern is obtained across crops (not shown). As regards the results obtained in Section 3.3.2 (Table 3.1) and Fig. 3.5, closure was seen to be more influenced by environmental conditions than by crop type or crop development. This explanation is supported by similar values for the energy balance closure obtained for each different year/crop (Table 3.1), and also by high closure values in summer whilst the lowest values were found in December (Fig. 3.5). The best (maximum) closure was found in July and August, whereas it drastically decreased in the remaining months, particularly in winter, under adverse conditions like snow, frost, or fog. These results agree with those reported by Wilson et al. (2002a) showing the effect of seasonality on the energy balance closure.




Figure 3.5. Seasonal pattern of the energy balance closure calculated by Eq. 3.2 (slope_G_p) and Eq. 3.3 (slope_G).

3.3.4 Energy partitioning

As pointed out earlier, the energy balance closure is usually used as a tool to assess the quality of EC and meteorological data, the energy imbalance therefore emerging as an interesting quality control value. However, the energy partitioning in different processes related to ecosystem, surface, and atmosphere is of even greater interest, since it determines how all of them interact with one another and impact on climate.

Fig. 3.6 displays the energy partitioning ratios, H/R_N , LE/R_N and G/R_N . A comparative analysis of the energy partitioning was performed over the whole yearly period and the MIP. Further analysis for each single year was also evaluated and is depicted in the graph, as has the 4-year average. One of the main findings from this graph is the well known complementary role played by H and LE, depending on the study period and crop development.




Figure 3.6. The energy partitioning for the whole four-year period and for each single year including the entire year or the MIP only. H, LE, and G denote the energy partitioning ratios H/R_{nr} , LE/R_{nr} , and G/R_{nr} , respectively, considering the whole yearly period. H_MIP, LE_MIP, and G_MIP denote the energy partitioning ratios H/R_{nr} , LE/R_{nr} , and G/R_{nr} , respectively, considering the MIP period.

On a four-year basis, H played the main role in the energy balance with a ratio of 52%. LE accounted for 40% of the energy, with soil heat flux contributing around 8% to the energy balance. These values changed during the MIP. For this period, LE played the main role, using over half of the available energy (51%) in evapotranspiration processes. The G/R_N ratio also underwent an increase during the MIP (11%), probably due to favorable environmental conditions which made soil able to store energy during this period. Conversely, H decreased its contribution to the energy balance during the MIP, accounting for 38% of the energy transport. Similar results for the energy partitioning were described in the literature. Chen et al. (2009) evaluated a cropland in China and showed that over 85% of the energy was partitioned into LE and H, while G contribution to the energy balance was lower. That study also reported the opposite role played by LE and H during the growing or non-growing season, agreeing with the results obtained in the present study.

On a yearly basis, a similar pattern was followed in 2010 and 2011, although different behavior could be found in 2008 and 2009. In 2008, LE played the main role, regardless of whether the selected period was the whole year or the MIP, with values greater than the four-year average. Nevertheless, in 2009 H consumed more energy than the remaining fluxes whether the study period was the whole year or the MIP.

As displayed in Fig. 3.6, maximum LE contributions to the energy balance were found during full crop development. These results concur with those from Lei and Yang (2010b) for wheat and maize, as well as the behavior of the H/R_N ratio. The largest contribution of LE to the energy balance was found during the rapeseed MIP in 2008 with an LE/R_N ratio of 71%, together with the lowest contribution of H (21%) found for the same period. A high value for LE/R_N (52%) was also found for the rye MIP in 2011, the H contribution (40%) not being as low as the value found for rapeseed. The lowest LE/R_N value (30%) was found for wheat in 2009, concurring with the largest H/R_N value (59%).

High LE/R_N ratios should mainly be related to water availability and vegetation coverage. The highest water availability related to precipitation distribution (Fig. 3.2) and cumulative values should hence lead to the

highest LE/R_N ratio, since the crop/soil might have a larger amount of water to be used in evapotranspiration processes. Likewise, a lack of water should lead to a lower LE contribution to the energy balance. The results observed in 2009 for wheat (Fig. 3.6) support the interpretation given. For this year, cumulative precipitation was low, particularly during the MIP (105.6 mm). This year thus appeared as the driest year compared to the remaining study years. This lack of precipitation during the wheat growing season led to incomplete crop development as suggested by a lower than usual canopy height. This might explain the low evapotranspiration, reflected as the lowest LE/R_N and the highest H/R_N values in Fig. 3.6. In fact, the H/R_N value was much greater than the four-year average. Therefore, under these conditions, H and G contributions displayed their maximum values compared to the remaining years/periods analyzed. Higher LE/R_N ratios were obtained for the other study years for which water availability was not a problem. However, comparative results for 2008, 2010, and 2011 evidenced large differences in LE/R_N , indicating that other factors could probably affect this value (Hernandez-Ramirez et al., 2010).

In 2010, which presents the highest values for cumulative yearly precipitation, the LE/R_N ratio (37%) was even lower than the average value for the four-year period (40%). Moreover, 2011 recorded lower cumulative annual precipitation than the remaining years. However, the LE/R_N ratio for this year (48%) was higher than values observed for the four-year average and 2010. This suggests that crop features such as leaf size/shape or canopy height, might even have a greater influence on the energy partitioning than water availability (Pallardy, 2008). A significant height implies a large amount of leaves and branches able to evapotranspire and might lead to higher LE/R_N values. The results observed for rapeseed and rye, the tallest crops among all those in the study period, support this idea. Conversely, lower crops like wheat and peas led to lower LE/R_N values. Moreover, the highest value obtained for rapeseed in 2008 indicates that leaf features might also have an effect on the LE/R_N ratio, since rapeseed presents broad leaves unlike rye, wheat, and peas. Further, the high evapotranspiration found in 2008 is consistent with the main rapeseed features (Grierson, 2001).

G/R_N behavior remained almost constant over the various study periods, showing a slight increase for the MIP but always with a lower contribution (below 15%) to the energy balance compared to H and LE values. In contrast to the MIP, G/R_N values over the whole period indicated that winter had a major influence on the final yearly ratio. During this season, soil released stored energy, mainly in spring and summer, evidenced by negative values as can be seen in Fig. 3.3 and Fig. 3.7. Therefore, those negative values influenced the final yearly G/R_N ratio, which showed lower values (Fig. 3.6) compared to the MIP values.

Finally, the low G/R_N value in Fig. 3.6 for 2011 merits comment. During summer, the crop had already been harvested with only a residue coverage remaining on the soil. This made it possible for more radiation to reach the soil and therefore be stored. Hence, G contribution to the energy balance played an important role during this period. Since instrumentation was not available (Section 3.2.2), H and LE values were missing and G values for that period were not taken into consideration when calculating the energy partitioning. This led to a lower G/R_N ratio and probably impacted H/R_N and LE/R_N ratios. The effect of the missing fluxes might have underestimated H contribution in 2011 compared to that shown in the same period of the other years, since the period for which data were missing had a major influence on the H/R_N ratio when considering the remaining years.

To assess more accurately the influence of each crop growth stages on the energy partitioning, Fig. 3.7 displays the monthly pattern of the energy partitioning; showing the behavior of each flux for the different crops. The flux behavior previously explained above is once again supported by this graph. However, this figure makes more evident the individual flux behavior corresponding to each crop. Regarding Fig. 3.6 and Fig. 3.7, the energy partitioning was markedly dependent on the growing stages of the crop, and in a lesser extent, on the meteorological conditions. Furthermore, the G contribution to the energy balance, releasing energy from November to January, is much marked in this graph that in the previous figures.

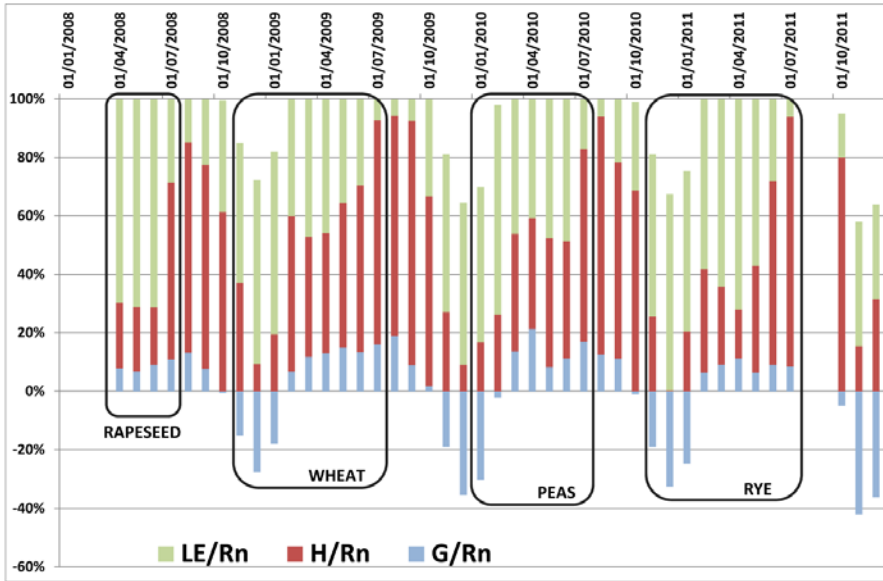


Figure 3.7. Monthly energy partitioning for the whole study period. Growth stages of the various crops are delimited by a box, while fallow period is outside of these boxes.

3.4 Conclusion

In this chapter, the energy balance closure and partitioning have been evaluated over a non-irrigated agricultural crop including four different years and crop types.

The energy balance closure was of 0.86 for the global four-year period. A similar closure value was found whether the study period covered the whole year or the MIP. The results did not reveal major discrepancies in the energy balance closure among different crops, since yearly closure values were quite similar, with values over 0.80. On a monthly basis, the best results were found during summer months with closure near 1, and lower values, around 0.6, during winter under adverse meteorological conditions.

Measured G_p was corrected by adding a calculated soil storage term. This correction showed to be an important factor to obtain a better energy balance closure. This correction led to a closure of 0.92 (0.93 for the MIP) for the agricultural ecosystem studied in this thesis, which represents an improvement of around 6 pp.

The opposite role played by LE and H was shown in the seasonal course, regarding crop development. This behavior was also found in the energy partitioning obtained. LE became the main energy consumer in the MIP whilst H was dominant when a global-yearly analysis was performed. Furthermore, G behavior was markedly seasonal, releasing energy during winter and storing it mainly during spring and summer, its contribution to the energy balance being below 15%. The energy partitioning displayed two noticeable characteristics. Firstly, the high participation of LE in the energy balance in 2008 and 2011, for rapeseed and rye, respectively. Throughout the whole study period, the highest LE/ R_N ratios were found during the rapeseed MIP (71%) and rye MIP (52%). The high LE/ R_N value observed for rapeseed is consistent with one of the main rapeseed features, high evapotranspiration. Secondly, the highest contributions of H (59%) and G (14%) to the energy balance were found for wheat in 2009, the driest year of all those in the study period.

CAPÍTULO 4. SEBS. MODELO DE UNA FUENTE

Based on the paper entitled

‘SEBS validation in a Spanish rotating crop’

published in Agricultural and Forest Meteorology. 2014. 195-196,
132-142

Nuria Pardo^a, M. Luisa Sánchez^a, Joris Timmermans^b, Zhongbo

Su^b, Isidro A. Pérez^a, M. Angeles García^a

^aDepartment of Applied Physics, University of Valladolid, Valladolid, Spain

^bDepartment of Water Resources, Faculty of Geo-Information Science and Earth Observation (ITC), University of Twente, Enschede, The Netherlands

Resumen

Como ya se mencionó en el apartado 1.2, la energía es considerada el principal factor que rige los diferentes procesos biofísicos y del clima. Por ello, se han desarrollado una gran variedad de modelos, basados en la Eq. 3.1. Su finalidad no sólo abarca el estudio del balance de energía de los diversos ecosistemas, sino el modelado de las variables que participan en el mismo, entre otros. Este es el caso de variables como la evapotranspiración o la EF. Este capítulo se centra, por tanto, en el cálculo de la EF y en los principales componentes del balance de energía mediante la aplicación del modelo SEBS, en combinación con datos satelitales y productos meteorológicos, sobre una tierra de cultivo rotante para el periodo 2008-2011.

Como ya hemos citado, el modelo SEBS está englobado dentro de los denominados modelos de una fuente, descritos en el apartado 1.3. SEBS ha sido diseñado para trabajar con una gran variedad de sensores tales como MERIS, MODIS, AATSR, Landsat, NOAA/AVHRR y AMSR-E.

La validación del modelo se realizó, para EF y los flujos de energía, comparando los resultados modelados y los datos medidos experimentalmente con la instrumentación EC y meteorológica instalada en la parcela de estudio, y ha incluido los cultivos más representativos de Castilla y León: colza, trigo, guisantes y centeno. Tres variantes diferentes del modelo fueron evaluadas: SEBS-0 (algoritmo original), SEBS-SM (algoritmo modificado con la humedad del suelo), y SEBS-NDVI (SEBS-0 modificado con el NDVI y la temperatura de la superficie de la tierra, LST). Este último algoritmo ha sido propuesto en esta tesis para ser aplicado a la zona de estudio o a zonas similares, dada la estrecha relación entre EF y NDVI. La nueva versión ha sido pues desarrollada para perfeccionar, en particular, los resultados modelados de EF y LE. Este capítulo presenta los resultados de las tres versiones diferentes del modelo SEBS empleadas en el estudio.

La evaluación de SEBS-0 mostró una clara subestimación de los valores de H ($R^2 = 0.54$), tal como se muestra en la Fig. R.4.1, y una marcada sobreestimación de los valores de EF. Las principales discrepancias se obtuvieron durante el verano, cuando el suelo está muy seco debido a la

casi ausencia de precipitaciones y prácticamente desnudo tras la recolección de la cosecha. La comparación de los resultados del modelo con los datos experimentales alcanzó la mejor correlación cuando la versión SEBS-NDVI fue aplicada, evitando la sobreestimación de EF y LE obtenida con las versiones anteriores, SEBS-0 y SEBS-SM. Los resultados mostraron que la nueva versión propuesta del modelo, SEBS-NDVI, usando un factor de escala relacionado con los valores de NDVI y LST, es capaz de reproducir satisfactoriamente el patrón estacional de EF ($R^2=0.65$) y de LE ($R^2=0.70$) mucho mejor que las versiones anteriores para la parcela estudiada en esta tesis. La buena correlación obtenida para el caso del LE se muestra en la Fig. R.4.2.

Uno de los principales logros de este trabajo reside en las largas series temporales analizadas, 4 años, y en la variedad de cultivos estudiada durante el período completo de crecimiento vegetativo, aspecto poco explorado en la bibliografía. Este modelo presenta además la ventaja adicional de calcular EF, un parámetro que interviene en la formulación de los modelos LUE para cuantificar la dinámica evolutiva de la GPP.




Figura R.4.1. Intercomparación, para el caso del calor sensible, entre los datos experimentales (H_{exp}) y los obtenidos mediante la aplicación del modelo SEBS-0 (H_{SEBS}) para el periodo total de medidas cubriendo los cuatro años y cultivos.

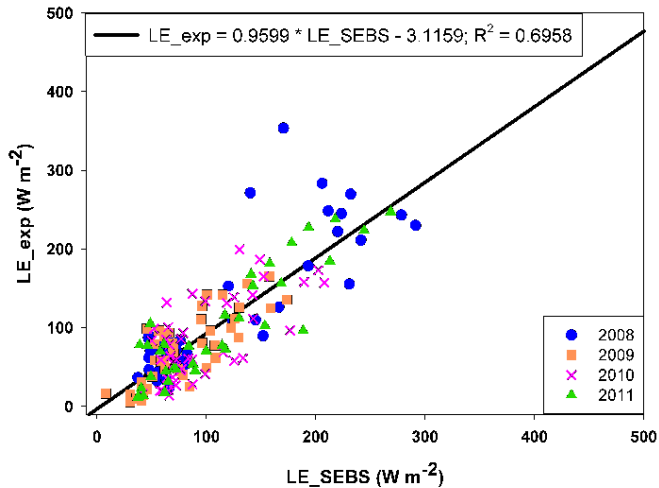


Figura R.4.2. Intercomparación, para el caso del calor latente, entre los datos experimentales (LE_{exp}) y los obtenidos mediante la aplicación del modelo SEBS-NDVI (LE_{SEBS}) para el periodo total de medidas cubriendo los cuatro años y cultivos.

Abstract

This chapter focuses on calculating Evaporative Fraction (EF) and energy balance components, applying the Surface Energy Balance System (SEBS) model combined with remote sensing products and meteorological data over an agricultural rotating cropland from 2008 to 2011. The model is validated by comparing SEBS results with observed EF and surface fluxes obtained using an Eddy Covariance (EC) technique together with meteorological instrumentation. Three different approaches of the model are evaluated: SEBS-0 (original algorithm), SEBS-SM (algorithm modified with soil moisture), and SEBS-NDVI (SEBS-0 modified with the Normalized Difference Vegetation Index -NDVI- and the Surface Temperature $-T_{surf}$ -). Based on current knowledge of the close relationship between EF and NDVI, a modified SEBS-0 algorithm, SEBS-NDVI, is proposed in this chapter. This new approach is developed so as to improve results for EF and latent heat flux (LE), and this chapter presents the results of all three SEBS approaches used in this study. Modelled R_n is found to be in good agreement with observed data ($R^2=0.75$), although SEBS-calculated G gave less satisfactory results ($R^2=0.38$) and its seasonal dynamics shows discrepancies with observed data. An evaluation of SEBS-0 shows a clear underestimation of H ($R^2=0.54$) and a marked overestimation of EF and LE. Comparison with ground-based data yielded the best correlation applying SEBS-NDVI, avoiding overestimation of EF and LE obtained with SEBS-0 and SEBS-SM. Results show that the proposed SEBS-NDVI, using a scale factor related to NDVI and T_{surf} , is able to reproduce satisfactorily the EF ($R^2=0.65$) and LE ($R^2=0.70$) seasonal pattern better than the two previous approaches for our study plot.

Keywords: Surface Energy Balance System (SEBS), Remote Sensing, Energy Balance, Eddy Covariance, Evaporative Fraction, Normalized Difference Vegetation Index

4.1 Introduction

Energy is the most fundamental factor governing climate and biophysical processes, and is why energy balance is one of the most widely studied subjects. In recent years, the challenge facing energy balance studies has focused on developing models able to parameterize all atmospheric fluxes from meteorological and ecophysiological parameters as well as deriving other important variables such as EF or evapotranspiration. Almost all these ecological or biophysical models have the energy balance equation or radiation as a key component in their development. The most common approach of this equation is defined as follows,

$$R_n = H + LE + G + P \quad (4.1)$$

where R_n is net radiation, G is soil heat flux, H and LE are sensible and latent heat flux, respectively, and P is a residual term usually related to different processes such as photosynthesis or ecosystem respiration (Foken, 2008; Wilson et al., 2002a).

Some studies assessing energy balance simply ignore this P -term (Cava et al., 2008), and the final equation used lacks the residual term. The main energy balance components are thus radiation, sensible and latent heat fluxes, and soil heat flux, and the most common equation defining surface energy balance is given by

$$R_n = G + H + LE \quad (4.2)$$

In previous studies, various models for estimating energy fluxes using remote sensing products have been developed based on the above equation (Kustas et al., 1996; Li et al., 2009). These models seek to evaluate atmosphere-surface interactions including energy, water, and CO_2 exchange. They can be divided into one-source (single-source) and two-source models (Gonzalez-Dugo et al., 2009; Kalma et al., 2008). The main difference between one and two-source models depends on whether the fluxes corresponding to canopy and soil are considered separately or as

one. As a result, two resistances characterizing the ecosystem must be calculated in two-source models where partitioning is taken into account (Norman et al., 1995), while only one resistance is needed in one-source models, since canopy and soil are considered to be a single system (Abtew and Melesse, 2013). Some well-known models are SEBAL –Surface Energy Balance Algorithm for Land– (Bastiaanssen et al., 1998; Bastiaanssen, 2000; Tang et al., 2013; Timmermans et al., 2007), SSEBI –Simplified Surface Energy Balance Index– (Roerink et al., 2000), TSEB –Two Source Energy Balance– (Timmermans et al., 2007), SVAT –Soil-Vegetation-Atmosphere-Transfer Model– (Gentine et al., 2007), TSEBPS –Two-layer Surface Energy Balance Parameterization Scheme– (Xin and Liu, 2010), and SEBS –Surface Energy Balance System– (Su, 2002).

In this thesis, the single-source SEBS model is implemented for a rotating agricultural cropland. One cropland selected for this study is rapeseed, since it is one of the main feedstocks used for biofuel production today and thus has a major influence on carbon and energy cycles in a context of ongoing climate change studies. Since SEBS is a model that uses remote sensing, all the biophysical parameters needed for formulation are provided from satellite imagery. By combining several satellites/sensors, a full description can be obtained for all the fluxes involved in the energy balance, not only for the plot studied but for a larger area surrounding it. The SEBS algorithm was developed to work with a wide array of sensors such as MERIS (Elhag et al., 2011), MODIS (Lu et al., 2013; Wang and Li, 2011), AATSR (Jia et al., 2003), Landsat (Ma et al., 2012), NOAA/AVHRR (Jin et al., 2005), and AMSR-E (Gökmen et al., 2012). The most common source for meteorological parameters is usually the ECMWF (European Centre for Medium-Range Weather Forecasts), although other sources such as VIIRS (sensor on board FY3A satellite) (Wang et al., 2013) are available. One of the main challenges involved in using this algorithm is to obtain energy balance components as well as EF for the specific field studied and for surrounding areas which have similar vegetation, and to perform intercomparisons of these data with observed data. Previous studies have reported uncertainties and modifications in the SEBS model, with particular interest focusing on H calculation (Gibson et al., 2011), such studies having

been conducted in order to validate and improve this SEBS model. In previous studies, a wide variety of locations, periods, and ecosystems have been considered, with studies ranging from the Nile Delta to the Tibetan Plateau, and embracing different types of vegetation. Furthermore, previous research has focused on validating one component of the energy balance (usually H) and, when all the components have been studied, selected study periods have tended to involve mainly short campaigns or selected clear days.

As hardly any previous studies apply the SEBS model over long-term and continuous periods, the study performed in this chapter might contribute to a better understanding of the algorithm. This chapter presents an evaluation of the SEBS model over our study area (Fig. 4.1) for all the energy balance components and EF for a continuous four-year period, the ecosystem studied being representative of the whole region, since non-irrigated agricultural rotating crops are one of the most common in the area. Furthermore, a modified version of the SEBS algorithm applying a new scale factor to EF has also been developed in this study. The new scale factor is proposed in order to improve results for EF and LE calculated by SEBS since our aim is to obtain improved results for these variables. Therefore, the EF obtained by SEBS might be applied in later studies to a Light Use Efficiency (LUE) model to obtain maximum light use efficiency of the studied ecosystem (Xiao et al., 2004; Yuan et al., 2007).

Hence, the principal objectives of this chapter are:

- (1) to validate the main variables from remote sensing and meteorological databases used by SEBS through correlation with observed measurements,
- (2) to evaluate the SEBS model for agricultural croplands over four years, and
- (3) to compare and relate EC tower-based measurements of EF and energy fluxes with SEBS model results.

4.2 Measuring site

The measuring site is a farmland located almost in the centre of the upper Spanish plateau, some 30 km north west of Valladolid in the region of Castilla y León (Fig. 4.1). The farmland is located in a semi-arid region with a Mediterranean-Continental climate characterized by low temperatures in winter months and warm and dry summers. The study area (41°46'44.4" N, 4°52'19.19" W, 849 m a.m.s.l) covers about 400 ha. Land use consists of non-irrigated crops. Maximum temperatures occur in July or August, with values reaching around 36 °C. Minimum temperatures usually occur in January or December, and may fall to as low as -10 °C. Seasonal precipitations are a further feature of this region. Precipitation is not evenly distributed throughout the year, but is present mainly in spring (April to June) and again in October, November, or December depending on the year. Average annual accumulated precipitation is about 450 mm. During the period studied, accumulated precipitation and yearly distribution varied widely. The wide variability in the accumulated precipitation for the whole four-year study period includes one year with precipitation similar to the yearly average (2008, 496.7 mm), one rainy year (2010) with a total value of 540.6 mm, and two years below the accumulated yearly average, these being 2009, with a total value of 375.3 mm, and 2011 with 346.8 mm. Moreover, after our having defined the crop growing season from March-June, the accumulated precipitation for this period is: 236.8 (2008), 105.6 (2009), 202.3 (2010), and 160.8 (2011) mm, with 2009 emerging as the driest overall year for the growing season.

Since the measuring site is located on a very wide plateau and relief elements are not present, horizontal homogeneity is ensured. The ecosystem studied is a rotating agricultural cropland inside the farmland, and includes the most representative types of crops in the region. Land management involves reduced tillage practices. The rotation cycle includes rapeseed, wheat/barley, green peas and rye. Soil composition is sandy loam with an organic content of between 60% to 65% sand, 20% clay, about 15% mud, and about 3% organic matter.

The farmland studied is divided into single plots. The rotation scheme not only includes the different types of crop but also the single plots. The sampling plot where the instrumentation was installed covers about 36 ha. Measurements were continuously performed throughout the whole year. Non-irrigated crops (rapeseed, wheat/barley, green peas, rye) are usually seeded about mid-September and harvested about mid-July the following year depending on crop development and growth, with the exception of green peas, which are seeded in January. Each crop takes only a few months to grow. Therefore, the soil has no crops or vegetation for the remainder of the time, only a residue coverage, which is present after harvest due to reduced tillage practices.




Figure 4.1 Geographical location of the study site located in the region of Castilla y León in Spain.

4.3 Instrumentation and data

4.3.1 Experimental instrumentation

Two measuring towers were installed in the study plot in order to measure energy fluxes, water vapour, and CO₂ exchange, as well as all the meteorological variables needed to describe the ecosystem in full. Measurements have been conducted continuously in the sampling area since March, 2008.

The tower incorporating the EC system, which is 3.5 m above the surface, is equipped with a 3D sonic anemometer (USA-1, METEK, Germany) that measures wind speed and direction, and an open path infrared gas analyzer –IRGA– that measures energy and water exchange (LI-7500, Li-Cor Inc., Lincoln, NE, USA) with a 10 Hz sampling frequency. Raw data are stored by a datalogger as averages of all half-hourly values (from instantaneous data). TK2 software (Mauder and Foken, 2004) is then used for data processing. This software package ensures the quality of the turbulent fluxes measured. The tower housing the meteorological instrumentation, which is 2.5 m above the surface, is equipped with a wind anemometer and vane (Wind sentry Model 03002, Young, Campbell Scientific, Inc.), a thermohygrometer measuring air temperature and humidity (model STH-5031, and model 41003 multi-plate radiation shield, Geónica, Spain), a net radiometer (type 8110, Ph. Schenk), a soil moisture sensor (Model 6545, Type ML2x, ThetaProbe), a soil temperature probe (model STS-5031, Geónica, Spain), a quantum sensor (LI-190Sz, Li-Cor Inc., Lincoln, NE, USA) measuring PAR (Photosynthetically Active Radiation), and two soil heat flux plates (HFP01, HukseFlux, Delft, The Netherlands) about 5 cm below surface. The soil heat flux is averaged from the two plates, one of which is buried under vegetation and the other under bare soil.

H and LE measurements provided by the EC system are used to calculate EF as follows:

$$EF = \frac{LE}{LE+H} \quad (4.3)$$

where EF values range between 0 and 1.

4.3.2 Remote sensing products and meteorological data

As mentioned before, remote sensing products and meteorological data are used as inputs by the SEBS algorithm. All these variables participate direct or indirectly in calculating the various fluxes and radiation as described in the following section (Section 4.4) or in the literature (Ershadi et al., 2013; Su, 2002). Further information about the remote sensing products or their calculation can be found in the website of the various sensors (<http://modis-land.gsfc.nasa.gov/>; <http://earth.esa.int/handbooks/>) or in the literature (Lucht et al., 2000; Ogawa and Schmugge, 2004). Table 4.1 summarizes the most relevant information related to the remote sensing products used in this study. As seen in this table, the same products are simultaneously obtained from different sources, particularly, NDVI, biophysical parameters such as LAI or fapar, and LST (hereafter referred to as T_{surf}). Due to the temporal resolution, cloud/aerosol presence, or instrumentation failures, it is difficult to retrieve a dataset from remote sensing without gaps. These products are thus duplicated in order to avoid such gaps, since the study performed in this chapter covers a long-term continuous period.

The main meteorological variables influencing the SEBS calculations are soil/surface temperature, air temperature, dew temperature, surface pressure, sea level pressure, radiation components, and wind speed. All these variables, with a temporal resolution of 3 h and spatial resolution of $1.5^{\circ} \times 1.5^{\circ}$, are retrieved from the ECMWF website (<http://data-portal.ecmwf.int/>).

4.3.3 Data resolution

SEBS results and ground-measurements present a different temporal resolution. All remote sensing products are retrieved during

satellite overpass (for a temporal range from 10.00–13.30 h (GMT), depending on the satellite). Since SEBS results are constrained by satellite overpasses they can be considered instantaneous measurements and representative for the daytime period. SEBS final results thus include one value per day for all energy balance components and EF for a spatial distribution covering a wider area than is evaluated with ground-measurements. Moreover, observed data are continuously measured and averaged into half-hourly aggregates. All in-situ measurements used in this study have been thus constrained to a daytime period so as to maintain uniformity between SEBS and observed datasets. As a result, only observed data whose $H > 50 \text{ W m}^{-2}$ were used for later comparisons with SEBS results. Finally, in order to obtain a common temporal resolution so as to compare the two datasets, data have been aggregated into 8d composites, which can help to prevent noise (Vinukollu et al., 2011).

4.4 SEBS methodology

As pointed out earlier in Section 4.1, the SEBS model calculates all energy balance components as well as EF using meteorological and biophysical parameters. All these parameters are supplied from remote sensing and meteorological sources as described in Section 4.3.2, and the model methodology is described below. Further detailed information and formulation can be found in Su (2002).

4.4.1 SEBS formulation

R_n is calculated as the sum of net shortwave radiation and net longwave radiation, since this is the conventional method.

$$R_n = R_n(\text{SW}) + R_n(\text{LW}) \quad (4.4)$$

Components of the R_n equation are calculated with typical equations found in the literature, as follows:

$$R_n(SW) = (1 - \text{albedo}) \cdot R_{SWd} \quad (4.5)$$

$$R_n(LW) = \text{emissivity} \cdot R_{LWd} - \text{emissivity} \cdot \sigma_{SB} \cdot T_{surf}^4 \quad (4.6)$$

where R_{SWd} and R_{LWd} are downward shortwave and downward longwave radiation, respectively, and σ_{SB} is the Stefan–Boltzmann constant. emissivity, albedo, and T_{surf} are obtained from remote sensing. R_{SWd} and R_{LWd} are retrieved from ECMWF.

Of all surface balance components, the most widely studied relationship is that between R_n and G . Several studies have explored the relationship between these two variables and have evidenced a good agreement with observed measurements. One of the simplest equations used in the literature is a linear relationship between G and R_n , although other relationships might be used (Qian et al., 2010; Santanello and Friedl, 2003). In this study, a non-linear equation has been used relating G , R_n , and LAI as follows (Kustas et al., 1993):

$$G = R_n \cdot C \cdot \exp(-\beta \cdot LAI) \quad (4.7)$$

where C and β are the amplitude of LAI and the extinction coefficient with values of 0.27 and 0.32, respectively. These parameters have been fitted for this study using a Marquardt algorithm applied to observed R_n and G . The LAI values used are those obtained from remote sensing (Table 4.1).

The similarity theory is used when calculating H as described in Su (2002) by applying the following equations,

$$u = \frac{u_*}{k} \left[\ln \left(\frac{z-d_0}{z_{om}} \right) - \Psi_m \left(\frac{z-d_0}{L} \right) + \Psi_m \left(\frac{z_{om}}{L} \right) \right] \quad (4.8)$$

$$\theta_0 - \theta_a = \frac{H}{ku_* \rho C_p} \left[\ln \left(\frac{z-d_0}{z_{oh}} \right) - \Psi_h \left(\frac{z-d_0}{L} \right) + \Psi_h \left(\frac{z_{oh}}{L} \right) \right] \quad (4.9)$$

where u is the wind speed, u_* the friction velocity, k is the von Karman constant with a value of 0.4, z is the height above the surface, d_0 is the

zero-plane displacement height, z_{0m} and z_{0h} are the roughness height for momentum and heat transfer, respectively, and θ_0 and θ_a are potential temperatures. The stability correction functions for momentum and heat transfers are given by Ψ_m and Ψ_h , respectively, and L is the Obukhov length. z_{0h} is calculated by

$$z_{0h} = \frac{z_{0m}}{\exp(kB^{-1})} \quad (4.10)$$

where the parameter kB^{-1} depends on the fractional canopy and soil coverage.

H is recalculated iteratively using Monin–Obukhov stability parameters until the lowest error is obtained. Actual/instantaneous sensible heat H is calculated by the SEBS algorithm taking into account that these values must be constrained between H values in dry and wet limits. EF is also calculated by studying these two limit cases in the energy balance equation. First, the dry-limit is considered, in which LE can be considered zero since soil moisture is not present (due to lack of water), and H reaches its maximum value. The second limit studied is the wet-limit, in which evaporation is not limited by available water but by available energy and the minimum value for H is found, with evaporation taking place at potential rate. Therefore, relative evaporation can be calculated as

$$\text{rel}_{\text{evap}} = 1 - \frac{(H - H_{\text{WL}})}{(H_{\text{DL}} - H_{\text{WL}})} \quad (4.11)$$

where H_{WL} and H_{DL} are the sensible heat at the wet and dry limit, respectively, and EF can be obtained as follows

$$\text{EF} = \text{rel}_{\text{evap}} \cdot \frac{(R_n - G - H_{\text{WL}})}{(R_n - G)} \quad (4.12)$$

LE is finally obtained as a residual term of the energy balance equation (Eq. 4.2), once EF is calculated.

4.4.2 SEBS approaches/modifications

Apart from the original algorithm described in Section 4.4.1, two further approaches have also been evaluated in this study. Firstly, a modification in the algorithm is applied using a scale factor taking into account soil moisture (SEBS–SM). This is one way to correct underestimation of H proposed by Gökmen et al. (2012) to avoid overestimating LE and EF. This scale factor is applied when calculating the parameter kB^{-1} , involved in estimating z_{0h} (Eq. 4.10):

$$\text{scale}_{\text{factor}} = \left[a + \frac{1}{(1 + \exp(b - c * SM_{\text{rel}}))} \right] \quad (4.13)$$

$$SM_{\text{rel}} = \frac{SM - SM_{\text{min}}}{SM_{\text{max}} - SM_{\text{min}}} \quad (4.14)$$

$$\text{new_kB}^{-1} = kB^{-1} * \text{scale}_{\text{factor}} \quad (4.15)$$

where a , b , and c are fixed parameters fitted for our study area with values of $a = 0.1$, $b = 1.8$, and $c = 3$. Calculating these parameters has been optimized by evaluating BIAS values for H, LE and EF.

Secondly, a new SEBS approach (SEBS–NDVI) considering the influence of temperature and vegetation over fluxes by applying a scale factor depending on T_{surf} and NDVI is proposed as a means of improving LE and EF results:

$$\text{scale_EF} = (\text{scale_T}_{\text{surf}}^a) * [\exp(b * NDVI)] \quad (4.16)$$

$$\text{scale_T}_{\text{surf}} = \frac{(LST_{\text{max}} - T_{\text{surf}})}{LST_{\text{max}}} \quad (4.17)$$

where LST_{max} is fixed at 320.15 K, and parameters in scale_EF are fitted for this study using a Marquardt algorithm ($R^2 = 0.65$) with values of $a = 0.65$ and $b = 1.99$. This scale factor is applied to the EF calculated by SEBS prior to calculating LE.

$$EF = \text{old_EF} * \text{scale_EF} \quad (4.18)$$

Furthermore, since LE has been calculated using the rescaled EF (Eq. 4.18), in order to obtain closure in the energy balance, H should also be rescaled using EF as follows,

$$\text{rescaled_H} = (1 - \text{EF}) * (R_n - G) \quad (4.19)$$

4.5 Results and discussion

As stated in Section 4.2, full homogeneity in our fieldwork is ensured. However, due to the low spatial resolution of the various remote sensing products, the defined pixel covers a greater area than our study area. Uncertainties associated with pixel-size or cloud/aerosol presence might account for differences between observed data and SEBS results. Such uncertainties are evaluated by analyzing some of the main variables, which influence the SEBS calculations, and these results are shown in Section 4.5.1.

Moreover, one practical advantage of the SEBS algorithm lies in the use of remote sensing, which makes it possible to study a larger area than is studied using EC instrumentation. This means that all SEBS results consist of a spatial distribution of all variables calculated by the algorithm at satellite overpass. However, in this study, SEBS is used at a local scale (in a selected plot) to evaluate the model by comparing the final results of R_n , G , turbulent fluxes, and EF from SEBS with available observed data. Results of this comparison are shown in Sections 4.5.2 and 4.5.3, where an overall study is carried out for the whole study period in order to obtain a relationship between observed data and SEBS results. This relationship could be used in further studies when observed data are not available.

4.5.1 Validation of external products

Air temperature, T_{surf} , and soil moisture are the external products evaluated. Air temperature and soil moisture have ECMWF (ERA-Interim) and AMSR-E, respectively, as their sole source. However, in order to avoid

missing values owing to cloud/aerosol presence (Shen and Leptoukh, 2011), T_{surf} is primarily obtained from LST-MODIS, and possible gaps are filled with LST from AATSR, or ECMWF (ERA-Interim) skin temperature products.

Linear fit regression graphics for air temperature and T_{surf} are shown in Fig. 4.2. The best correlation is obtained for air temperature (Fig. 4.2a) showing patterns of observed and ECMWF data that are approximately the same, and an average slope near 1 ($R^2 = 0.98$; slope = 0.96; BIAS = 1.58 K; RMSD = 1.97 K). Results for T_{surf} (Fig. 2b) present lower values for the correlation coefficient and slope, although acceptable agreement is still found ($R^2 = 0.93$; slope = 0.74; BIAS = 6.54 K; RMSD = 7.47 K). Unlike air temperature, overestimation in SEBS retrieved values is more marked in the case of T_{surf} as shown in BIAS and RMSD values, which are higher for T_{surf} analyses. This overestimation increases in the summer of 2009 and 2011 compared to the same period of the two other years. It should be mentioned that the relationship between in-situ soil temperature and T_{surf} is obtained by a comparison between soil temperature, measured with a probe buried below surface (Section 4.3.1), and T_{surf} retrieved by remote sensing (Section 4.3.2). This might explain the large BIAS found and the significant overestimation in the T_{surf} retrieved from SEBS. Moreover, when analysing SEBS results for energy balance components and EF (see following sections), we should bear in mind the large BIAS and RMSD obtained when validating external products, particularly temperature, since this might induce uncertainties in the model and influence the final results.

As regards soil moisture, observed values (Fig. 4.3, solid line) can show changes in soil moisture more accurately than the AMSR-E sensor (Fig. 4.3, dashed line). AMSR-E is seen to fit ground measurements properly, and a good agreement as well as a similar seasonal pattern is present between the two databases ($R^2 = 0.52$; slope = 0.67; BIAS = 7.11%; RMSD = 10.89%), although AMSR-E overestimates soil moisture values. A major difference appears in Fig. 4.3 for May–June and again in December–January between AMSR-E and observed data for all four years coinciding with increased precipitation. This difference might be attributed to cloud

presence, a case for which AMSR-E introduces the highest overestimation for soil moisture values. It should be remembered that ground-based soil moisture measurements are carried out at a single point where the probe is installed and measurements are performed continuously, whilst AMSR-E soil moisture products have a spatial resolution of 25 km and measurements are performed about once a day coinciding with satellite overpass. The studied plot is surrounded by others which have a similar land use. Validating AMSR-E values with ground-based measurements for this area should thus prove fairly reliable, despite the spatial resolution of AMSR-E products compared to the studied plot. Further, soil moisture is directly influenced by precipitation events, soil composition and, more significantly, ground-based measurements may differ enormously depending on measurement depth. In agreement with our results, previous studies suggest that AMSR-E products are able to provide reliable information concerning soil moisture at the same temporal scale as ground measurements, clearly showing rain events in the same way as experimental instrumentation is able to (Chakraborty et al., 2012; Gruhier et al., 2008).

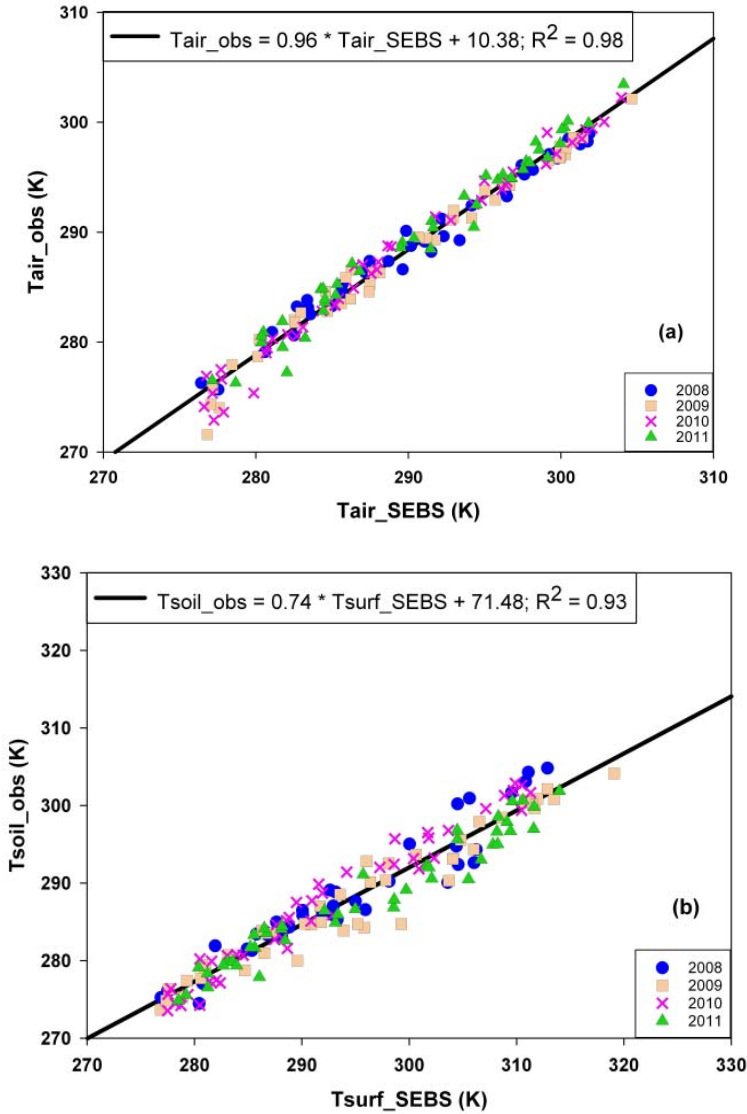


Figure 4.2. Correlation between observed data with those retrieved by the SEBS algorithm for a) air temperature and b) soil/surface temperature.

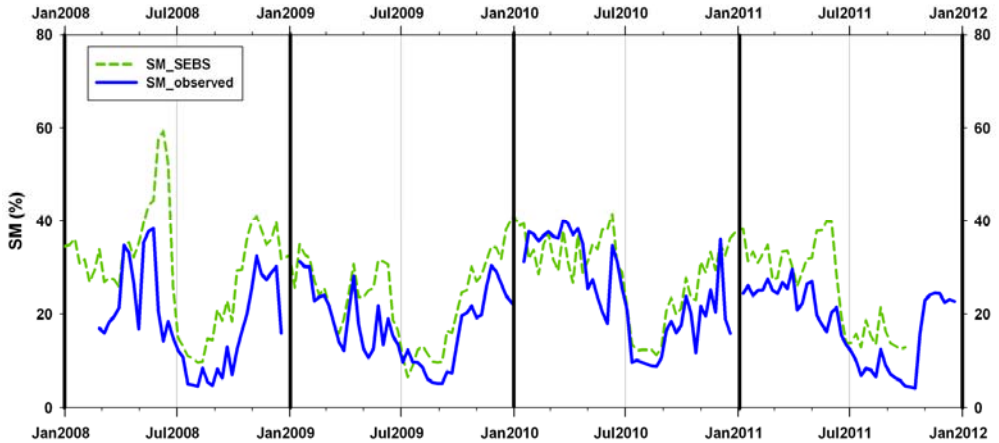


Figure 4.3. Time series of soil moisture from 2008 to 2011. The graph represents observed data (solid line) and SEBS retrieved (from AMSR-E, dashed line).

Table 4.1. Summary of the remote sensing products used by SEBS.

SENSOR	SATELLITE	SOURCE/Full Sensor Name	PRODUCTS	NAME	RESOLUTION
MODIS ¹	AQUA	http://ladsweb.nascom.nasa.gov/data (Collection 5, tile h17v04)	MCD15A2	LAI/FPAR	1000m/8days
	TERRA		MCD43B3	Albedo	1000m/16days
		¹ Moderate Resolution Imaging Spectroradiometer	MOD11A1	LST and Emissivity	1000m/daily
			MOD13A2	NDVI	1000m/16days
MERIS ²	ENVISAT	MERCI Interface	MER_RR__2P	NDVI, fAPAR, LAI	1000m/2-3days
		² Medium Resolution Imaging Spectrometer			
AATSR ³		³ Advanced Along-Track Scanning Radiometer	ATS_NR__2P	LST	
AMSR-E ⁴	AQUA	ftp://hydro1.sci.gsfc.nasa.gov/data/s4pa/WAOB ⁴ Advanced Microwave Scanning Radiometer-Earth Observing System	LPRM-AMSR_E_L3	Soil Moisture	0.25°x0.25°/daily

4.5.2 Intercomparison of R_n and G

At an initial stage, the algorithm calculates R_n and G as the first components of the energy balance. As regards Eq. 4.5 and Eq. 4.6 in the SEBS formulation paragraph, R_n is dependent on radiation components, albedo, emissivity, and T_{surf} . Observed and SEBS-based modelled R_n are displayed in Fig. 4.4 where the similar seasonal pattern followed by the two variables is shown. Maximum values peaked in July with values up to 600 W m^{-2} for the modelled SEBS (Fig. 4.4, dashed line) and were slightly lower ($\sim 500 \text{ W m}^{-2}$) for observed data (Fig. 4.4, solid line). In winter, minimum values are reached for both variables, SEBS-based and observed. However, in this case, SEBS values are lower than observed ones. Results show that R_n estimated by SEBS correlates well with observed data (Table 4.2), concurring with previous results found in the literature (Träger-Chatterjee et al., 2010; Szczypta et al., 2011). During winter, SEBS values depicted in Fig. 4.4 are strongly underestimated compared to ground-based data. Major differences can thus be found in this period. Such differences might possibly be reflected as slightly high values for intercept, BIAS, and RMSD, as shown in the summary of the statistical results in Table 4.2. These low values obtained for SEBS- R_n might be attributed to low albedo, since this parameter, retrieved from remote sensing, is used to calculate the radiation (Eq. 4.5). Since T_{surf} is also used to calculate R_n , the large BIAS and RMSD found when analyzing this external product (Section 4.5.1) might be responsible for the large BIAS and RMSD found in the R_n analysis. These high values, particularly for RMSD, might also influence the validation of H, LE and EF performed and described in the following section. In Table 4.3, the results for the correlation between experimentally observed and SEBS-based R_n for each year can be found, and the same good correlation is seen for each linear fit as the one obtained for the global fit showed in Table 4.2. However, large intercepts are also found for each single-year analysis, probably due to uncertainty introduced by T_{surf} (Section 4.5.1).

The seasonal pattern of G is displayed in Fig. 4.5. Average seasonal behaviour for G measurements (Fig. 4.5, observed) reveals high values during the crop-growing period (Feb–Apr) and a marked decrease during

the senescence period (late May/early July) when LE becomes the main component of the energy balance rather than G or H. Again, high values are reached after harvest (late July–Aug) when the plot is uncovered and soil is dry. Finally, minimum values are found during winter. Further, the SEBS-based modelled G follows the same seasonal pattern found for R_n (Fig. 4.4, dashed line) as is drawn in Fig. 4.5 (dashed line), since G is calculated from R_n using Eq. 4.7, and maximum values are reached around July. Results show a less satisfactory agreement for the G comparison between the two databases (Table 4.2) than is obtained for R_n despite being calculated from it. This result is consistent with other results reported for G over similar crops (Mo et al., 2012).

The poorer agreement might be due to a combination of factors; firstly, the influence of the phenology and the growing stages of the crop types studied in the observed evolution of G. The major discrepancies between observed and modelled seasonal courses, which are particularly marked in April–July 2011 over rye (Fig. 4.5, solid line), the crop which reached the maximum height, appear to support the interpretation given; secondly, differences in spatial resolution or unrepresentativeness of the two heat plates may have an impact. G calculated by SEBS is derived using remote sensing in a wider pixel (Lu et al., 2013) whereas G observed is measured at a local scale using two plates. The measurements performed with the two plates might not have provided a sufficient description of G (Bi et al., 2007) due to the unequal root distribution of crops. Thirdly, errors linked to instrumentation (Wilson et al., 2002a). Although the devices used here are those typically employed, previous studies report that plates can lead to an underestimation of over 20% compared to alternative methods (Ochsner et al., 2006). Finally, the influence of the other experimental sources of uncertainties, such as instrumentation sensitivity to environmental conditions, the number of plates installed (Evetts et al., 2012; Kustas et al., 2000), and the depth at which plates are buried (Evetts et al., 2012; Hydrology Handbook, 1996) may also prove to be a factor. Moreover, it should be taken into consideration that SEBS-G is calculated at the surface, whereas the observed G is measured at 0.05 m depth without considering heat storage above the soil. Therefore, a

temperature profile (not available for this study) should be used to convert observed G to surface values.

Furthermore, Table 4.3, where a single year linear fit between observed and SEBS-calculated G is presented, shows how the best correlation of G is for 2009. For this year, not only was accumulated yearly precipitation low compared to other years but also the precipitation accumulated during the crop growing stage was the lowest of all four years, reflected in lower values of observed LE as is shown in Fig. 4.7 (solid line) compared to values measured in the same period for the other years.




Figure 4.4 Yearly pattern of net radiation, R_n , for observed values and SEBS calculated. Only observed and modelled_SEBS appear in the graph since modifications in the algorithm do not effect these variables.




Figure 4.5 Yearly pattern of ground soil heat flux, G , for observed values and SEBS calculated. Only observed and modelled_SEBS appear in the graph since modifications in the algorithm do not effect these variables.

4.5.3 Intercomparison of H, LE and EF

The behaviour of H is shown in Fig. 4.6 (solid line), where it reached its maximum values in July with values about 250–300 W m⁻². High values are observed during the whole summer season, although H evidences a slight and constant decrease in value until reaching a minimum of about 80 W m⁻² during the winter period. Observed LE and EF values are shown in Fig. 4.7 and Fig. 4.8 (solid line), respectively. The behaviour of the two variables is the same, and is opposite to H. LE and EF reach their maximum values during the crop growing season (March–June) and rarely present high values in early July when crop is in its senescent period. These variables suffer a drastic decrease in their values, reaching a minimum just after harvest (mid July). For the whole period between harvest and the next seeding, LE shows values of about 40 W m⁻² (or lower), evidencing a slight and continuous increase in values as of late October or November. The same seasonal pattern is shown by EF.

Seasonal dynamics for turbulent fluxes, H and LE, and EF exhibit the same trend followed each year. This constant seasonal dynamics presents the highest values for H when soil is uncovered, and maximum LE and EF values during the growing season. Since evapotranspiration is high in the growing period, this leads to high LE values. However, both the maximum values and when they are reached depends to a large extent on crop type. Hence, rapeseed seeded in 2008 characterized by high evapotranspiration leads to maximum LE values compared to the remaining years.

When the SEBS-0 algorithm is applied over our study plot, a large underestimation of H (Fig. 4.6, dotted line) is found (Table 4.2, SEBS-0). This underestimation of H leads to an overestimation of LE and EF (Table 4.2, SEBS-0) as shown in Fig. 4.7 and Fig. 4.8 (dotted grey line), respectively. Overestimation in LE and EF is more marked in summer and autumn, when soil is dry and lacks vegetation coverage. The explanation for the weak positive correlation observed using SEBS-0 might be found with an evaluation of the results for each single year during the study period. An overview of these results is presented in Table 4.3, where linear fit equations are shown for the correlation between observed values and

SEBS-based results. All years analyzed present different environmental conditions, particularly with regard to precipitation. Indeed, greater differences can be found in precipitation between all the years studied as mentioned in Section 4.2. Table 4.3 shows how the worst correlation and significant discrepancies between SEBS-0 and observed values correspond to 2009 and 2010, a dry year and the rainiest year, respectively. Thus, two extreme conditions regarding precipitation (slight drought and rainy conditions) lead to poor agreement between ground-based data and SEBS-0. The difference in the amount of precipitation is one of the main factors modifying canopy development, particularly with regard to the growing season of the crop. The lack of water during the 2009 growing season limited canopy growth, leading to lower crop evapotranspiration compared to the other years. This can be seen in Fig. 4.7 (solid line) which shows how 2009 evidences the lowest LE values of all the four years studied. However, although 2010 is considered a rainy year, LE values increase only slightly compared to 2009. As a result, not only moisture but also crop type can influence SEBS results.

To evaluate the influence of soil moisture on SEBS results the SEBS-SM algorithm has been applied, as a means to avoid underestimating H. An improvement in H is shown in Fig. 4.6 for the dry period (dash-dot line). Underestimating H is partially solved (Table 4.2, SEBS-SM) and a better correlation coefficient and lower BIAS and RMSD are obtained. Results for LE and EF (Table 4.2, SEBS-SM) also show a slight improvement, although overestimation is still present as reflected in Fig. 4.7 (dash-dot line) for LE and Fig. 4.8 (dash-dot line) for EF. Values for modelled LE and EF (Fig. 4.7 and 4.8, modelled SEBS-SM) after harvest (late July) are still higher than expected for the period. As regards Table 4.3, where fitting results are shown for each year, the worst results are again found for 2009 and 2010, although environmental conditions are known to differ for those years. These results show that this new scale factor depending on soil moisture is not accurate enough for our study ecosystem due to the wide variability of LE and EF in this type of agricultural cropland, although a clear improvement in H values is noticeable when applying this algorithm.

The influence of precipitation or soil moisture on the SEBS-0 algorithm was evaluated by applying SEBS-SM, the poor results for 2009 and 2010 evidencing that other factors impact SEBS results. As stated earlier, not only do meteorological conditions vary but different types of crops are also evaluated for the four years analyzed. In 2009 and 2010, wheat and green peas, respectively, were grown with a canopy height, h_c , of about 0.70 m (wheat) and 0.50 m (green peas). In the other two years, rapeseed and rye were seeded, reaching heights of about 1.30 and 1.60 m, respectively, and better correlations were found for these years between SEBS and observed data.

Differences in crop architecture and features lead to different values in the biophysical parameters and vegetation indices characterizing these crops. The influence of vegetation growth on EF and LE can thus be assumed with NDVI variation (Szilagyi et al., 1998), and this parameter might be evaluated to predict seasonal vegetation development. By closely following the well-defined NDVI pattern, crop development and the duration of the growing season, for which NDVI values reach their maximum values, can be determined clearly. In addition, including NDVI values might improve EF calculation (Yang and Wang, 2011). Lower values for all biophysical parameters can be found for 2009 and 2010 together with higher ones for 2008 and 2011. Since the worst results of applying SEBS-0 and SEBS-SM were obtained for 2009 and 2010, this suggests the strong influence of crop type on the SEBS algorithm, in particular, biophysical factors (h_c , LAI) related to the different crops, since these have a major influence on roughness heights for momentum transfer. SEBS sensitivity to h_c and NDVI has been studied in previous research (Gibson et al., 2011) as has the influence on EF or LE values caused by temperature, soil moisture, and NDVI (Wang et al., 2006). When a crop is growing, evapotranspiration is the dominant component in the energy balance and maximum values for LE and EF can be reached when the crop is fully developed (Vinukollu et al., 2011). However, after harvest, H rather than LE takes the leading role, bringing about lower LE values (Fig. 4.7, observed), whilst the plot can be considered bare/dry soil until the next seed time. Therefore, LE and EF emerge as the most sensitive variables to

changes in vegetation development (Hua et al., 2008), whilst H is more influenced by temperature.

Dependence of biophysical parameters/vegetation indices on SEBS results is thus evaluated by applying the SEBS-NDVI algorithm. Rescaling EF has a positive effect on LE and EF values (Fig. 4.7 and Fig. 4.8, modelled SEBS-NDVI). Seasonal patterns for these two variables are more similar to observed ones, once the rescaling factor has been applied. With this modification in the algorithm, it can now be seen how SEBS-NDVI results reproduce the LE and EF pattern correctly, showing minimum values for these two variables in July and August when vegetation is not present and soil can be considered as bare, and maximum values when the crop is fully developed (Fig. 4.7 and Fig. 4.8, dashed-line). With this change, a good correlation is therefore found for LE and EF (Table 4.2 and 4.3, SEBS-NDVI). Results for the rescaled H also improved regarding values obtained in the two previous approaches (Table 4.2 and 4.3, SEBS-NDVI). Therefore, the underestimated H values found with SEBS-0 are avoided.




Figure 4.6 The seasonal dynamics of observed H (solid line) and that calculated by the SEBS model using the original algorithm (SEBS-0, dotted line) and the two modified codes, one with soil moisture (SEBS-SM, dash-point line) and the other taking into account the NDVI and the (SEBS-NDVI, dashed line).




Figure 4.7 Yearly patterns of the latent heat for ground-based measurements and calculated by the SEBS model using the original algorithm (SEBS-0) and the two modified codes, one with soil moisture (SEBS-SM) and the other taking into account NDVI and (SEBS-NDVI).




Figure 4.8 Seasonal variation of EF for observed data and that calculated by the SEBS model using the original algorithm (SEBS-0) and the two modified codes, one with soil moisture (SEBS-SM) and the other taking into account NDVI and (SEBS-NDVI).

Table 4.2. Summary of the linear regression parameters and statistics for the relationship between observed data and SEBS results using the original SEBS (SEBS-0) algorithm and the two modifications; SEBS-SM and SEBS-NDVI.

		R_n	G	H	LE	EF
SEBS-0	slope	0.51	0.61	0.95	0.35	0.65
	intercept	193.32	29.75	79.84	18.15	-0.13
	R²	0.75	0.38	0.54	0.19	0.12
	BIAS	-13.21	-0.79	-77.31	126.07	0.41
	RMSD	80.52	23.83	86.46	151	0.45
SEBS-SM	slope	-	-	0.57	0.56	0.77
	intercept	-	-	83.4	-12.47	-0.15
	R²	-	-	0.72	0.52	0.49
	BIAS	-	-	-35.29	95.94	0.31
	RMSD	-	-	60	113.46	0.34
SEBS-NDVI	slope	-	-	0.53	0.96	0.94
	intercept	-	-	47.26	-3.12	0.02
	R²	-	-	0.82	0.7	0.65
	BIAS	-	-	41.64	6.38	0
	RMSD	-	-	67.13	37.69	0.11

Table 4.3. Summary of fitting equations and correlation coefficients found between observed values (y) and SEBS-modelled results (x) for each single year for R_n , G, energy fluxes and EF for the original SEBS algorithm (SEBS-0) and the two modifications: SEBS-SM and SEBS-NDVI. It should be noticed that results for R_n and G are common for all the approaches of the algorithm.

		2008	2009	2010	2011
R_n	SEBS	$y = 0.52x + 188.85$ $R^2 = 0.67$	$y = 0.46x + 196.71$ $R^2 = 0.84$	$y = 0.43x + 213.87$ $R^2 = 0.73$	$y = 0.62x + 166.71$ $R^2 = 0.83$
	G	$y = 0.54x + 22.66$ $R^2 = 0.47$	$y = 0.81x + 15.23$ $R^2 = 0.71$	$y = 0.38x + 53.05$ $R^2 = 0.21$	$y = 0.68x + 27.59$ $R^2 = 0.32$
H	SEBS-0	$y = 0.83x + 86.92$ $R^2 = 0.36$	$y = 0.89x + 84.68$ $R^2 = 0.60$	$y = 1.31x + 67.50$ $R^2 = 0.66$	$y = 1.00x + 72.42$ $R^2 = 0.51$
	SEBS-SM	$y = 0.56x + 84.60$ $R^2 = 0.82$	$y = 0.57x + 86.30$ $R^2 = 0.74$	$y = 0.48x + 83.99$ $R^2 = 0.75$	$y = 0.68x + 78.33$ $R^2 = 0.67$
	SEBS-NDVI	$y = 0.47x + 61.30$ $R^2 = 0.76$	$y = 0.53x + 49.50$ $R^2 = 0.86$	$y = 0.47x + 50.29$ $R^2 = 0.87$	$y = 0.69x + 26.18$ $R^2 = 0.84$
LE	SEBS-0	$y = 0.64x - 24.49$ $R^2 = 0.41$	$y = 0.14x + 43.24$ $R^2 = 0.06$	$y = 0.11x + 58.30$ $R^2 = 0.04$	$y = 0.50x - 6.56$ $R^2 = 0.35$
	SEBS-SM	$y = 0.82x - 38.85$ $R^2 = 0.82$	$y = 0.33x + 14.45$ $R^2 = 0.34$	$y = 0.37x + 16.49$ $R^2 = 0.40$	$y = 0.62x - 24.75$ $R^2 = 0.53$
	SEBS-NDVI	$y = 0.97x + 7.50$ $R^2 = 0.70$	$y = 0.90x - 0.15$ $R^2 = 0.63$	$y = 0.83x + 4.17$ $R^2 = 0.47$	$y = 0.97x - 8.23$ $R^2 = 0.81$
EF	SEBS-0	$y = 0.57x - 0.01$ $R^2 = 0.07$	$y = 0.62x - 0.15$ $R^2 = 0.19$	$y = 1.31x - 0.70$ $R^2 = 0.22$	$y = 0.48x - 0.02$ $R^2 = 0.07$
	SEBS-SM	$y = 0.81x - 0.11$ $R^2 = 0.61$	$y = 0.72x - 0.16$ $R^2 = 0.54$	$y = 0.99x - 0.30$ $R^2 = 0.72$	$y = 0.63x - 0.06$ $R^2 = 0.22$
	SEBS-NDVI	$y = 0.92x + 0.06$ $R^2 = 0.71$	$y = 0.74x + 0.08$ $R^2 = 0.56$	$y = 1.07x - 0.03$ $R^2 = 0.61$	$y = 1.09x - 0.05$ $R^2 = 0.72$

4.6 Conclusion

In this chapter, one-source model SEBS results have been evaluated on an agricultural cropland over four consecutive years and four different crop types under varying environmental conditions, particularly with regard to precipitation. Components of the energy balance and EF obtained from SEBS and observed data have been compared and a relationship between them has been found.

SEBS validation was performed using products from remote sensing and external meteorological databases as input for the algorithm in order to obtain SEBS results which are totally independent from observed data for later comparisons between the two databases. These external parameters have also been evaluated, and a satisfactory agreement between them and in situ measurements has been found. Using these parameters rather than local ground measurements makes it possible to obtain maps of the different variables calculated by SEBS for a larger region than the EC system is able to cover. Achieving this is one of the advantages of using the SEBS algorithm when a wide area needs to be studied. The main conclusions to emerge from this study show that combining remote sensing with SEBS can provide reliable results for all the components of the energy balance and EF.

Modelled R_n showed the same seasonal dynamics as the observed one, and a good agreement with observed data was found. However, modelled G showed less satisfactory results compared to the observed database, displaying discrepancies in its seasonal pattern compared to observed values. Results obtained for these two variables are common for all approaches of SEBS evaluated in this study.

The original algorithm (SEBS-0) and two modified approaches (SEBS-SM and SEBS-NDVI) have been evaluated. Results obtained for SEBS-0 showed an underestimation for H values and a poor agreement for LE and EF compared to observed data. Lower correlation values were obtained for the two years with extreme precipitation conditions, 2009 (dry) and 2010 (rainiest). The algorithm (SEBS-0) was modified by applying a soil moisture dependent scale factor to kB^{-1} calculation

(SEBS-SM) or by applying an $\text{NDVI-T}_{\text{surf}}$ dependent scale factor to EF calculation (SEBS-NDVI). SEBS-SM provided improved results for H and the underestimation obtained with SEBS-0 was corrected. However, LE and EF results still showed a weak agreement with observed values although a slight improvement did emerge. Large discrepancies between SEBS results and the observed database are found particularly in summer when soil is dry and vegetation is absent. The solution proposed in this study is to apply a new scale factor depending on NDVI and T_{surf} rather than the scale factor influenced by soil moisture. Results for LE and EF retrieved from the new approach proposed in this thesis (SEBS-NDVI) reproduce reliable values for these variables for the whole study period, and a satisfactory correlation between the two databases was found. Since the new scale factor proposed (SEBS-NDVI) is applied to EF, not only LE but H is rescaled and underestimating H values obtained with SEBS-0 is avoided. SEBS-based H followed the same pattern as observed values, and the correlation between the two databases is in good agreement.

This study has proved that the SEBS model is the most sensitive to vegetation development (NDVI can be considered the main driving factor) when LE and EF are calculated. Results from this research show significant differences in LE and EF values when using each of the approaches evaluated. However, no considerable changes are found if different approaches are employed when calculating H, R_n , and G. Furthermore, reliable results obtained for EF make it possible to introduce these values into a LUE model to obtain efficiency in the various ecosystems studied.

CAPÍTULO 5.

GPP Y MODELO LUE

Based on:

1) the paper entitled

‘GPP and maximum light use efficiency estimates using different approaches over a rotating biodiesel crop’,

submitted for its publication to Agricultural and Forest Meteorology

M.L. Sánchez, N. Pardo, I.A. Pérez and M.A. García

2) la monografía titulada

‘Medida y parametrización de los flujos de CO₂ en un cultivo de colza. Medidas in situ y satelitales’.

52 páginas. Publicado por la editorial Académica Española.

ISBN: 978-3-659-03319-3

M.L. Sánchez, N. Pardo, I.A. Pérez and M.A. García

Resumen

Mediante el procesado de los datos medidos directamente con la instrumentación EC se obtuvieron valores del NEE. Parametrizando sus valores nocturnos mediante una ecuación de Van't Hoff modificada, utilizando SM y T, se calculó la RE (Eq. 5.7). El valor de la GPP vendrá determinado por la diferencia entre los valores de NEE y RE (Eq. 5.6). Una vez conformada la base de datos global se pueden determinar los valores acumulados de las variables previamente mencionadas. Los valores anuales para el NEE fueron -373, -157, -98, -511 g C m⁻² para la colza, el trigo, los guisantes y el centeno, respectivamente. Equivalentemente, los valores acumulados para la GPP fueron 1684, 714, 733 y 1409 g C m⁻². La evolución estacional de ambas variables puede verse en la Fig. R.5. La cantidad total de NEE representa alrededor de un 13% a un 36% del valor total obtenido para la GPP, dependiendo del tipo de cultivo, tal como se ve al comparar los valores totales de ambas variables. Las diferencias más grandes entre las cantidades totales de NEE y GPP implican altas tasas de respiración para alguno de los cultivos estudiados como puede ser el caso del centeno o la colza. Sin embargo, como conclusión debemos destacar que todos los cultivos estudiados en esta tesis se comportaron como sumideros de carbono, aunque existen notables diferencias en la cantidad total de CO₂ secuestrado por cada uno de los cultivos, dependiente claramente de las condiciones ambientales y de sus características estructurales. Estas diferencias se aprecian mejor al comparar los valores obtenidos para el trigo y los guisantes frente a los obtenidos para la colza y el centeno, alcanzando los primeros una menor altura que la que lograron los dos últimos.

En este capítulo también se presentan los resultados obtenidos al aplicar un modelo LUE a los datos experimentales de la GPP:

$$GPP_{LUE} = \epsilon_0 f_{LUE} APAR = \epsilon_0 G_{APAR} \quad (5.2)$$

El modelo utiliza como datos de entrada los valores experimentales de PAR, en combinación con datos de 8 días de FPAR del sensor MODIS. En el modelo se incluye también un factor de estrés, f , con valores entre 0 y 1, que da cuenta de la reducción del valor de eficiencia máximo, ϵ_0 , para la conversión de PAR en función de las condiciones ambientales limitantes. En este estudio, los valores de f , f_{LUE} , fueron considerados dependientes de la temperatura del aire, T , y de la fracción evaporativa, EF , que puede ser considerada como una aproximación a la disponibilidad de agua. El valor de ϵ_0 , un parámetro clave en los modelos LUE, dependiente del uso de suelo y vegetación, fue derivado a través de los resultados del ajuste de la regresión lineal entre la GPP experimental y las estimaciones concurrentes de G_{APAR} definida como el producto de PAR, $FPAR_{MODIS}$ y f .

En conjunto, ϵ_{0LUE} alcanzó un valor de 3.331 ± 0.104 g C MJ⁻¹ aunque este valor varió dependiendo de la estructura del cultivo, de la fenología y de las condiciones meteorológicas predominantes. Cultivo-a-cultivo, ϵ_{0LUE} varió desde 2.738 ± 0.171 hasta 3.954 ± 0.195 g C MJ⁻¹ para los guisantes y el centeno, respectivamente, alcanzando valores intermedios para la colza y el trigo, 2.916 ± 0.182 y 2.859 ± 0.230 g C MJ⁻¹, respectivamente.

La intercomparación de los resultados experimentales de la GPP con aquellos concurrentes obtenidos del satélite MODIS, GPP_{MODIS} , permitió obtener una nueva serie de valores para la eficiencia, ϵ_{0MODIS} , alcanzando un valor de 2.128 ± 0.098 g C MJ⁻¹ para el conjunto total, mientras que cultivo-a-cultivo varió desde 1.278 ± 0.173 hasta 2.412 ± 0.117 g C MJ⁻¹ para el trigo y la colza, respectivamente. El mejor ajuste correspondió a cultivos que se desarrollaron con una buena disponibilidad de agua, la colza y los guisantes, y el peor ajuste fue para el trigo. La relación $\epsilon_{0LUE}:\epsilon_{0MODIS}$, 1.56, fue consistente con el radio $f_{LUE}:f_{MODIS}$, 0.69, revelando el importante papel de la formulación de f en los modelos LUE y, por tanto, en el valor de ϵ_0 obtenido para un específico bioma. En conjunto, el modelo LUE proporcionó resultados satisfactorios, $R^2=86.3\%$, mejorando significativamente las estimaciones de GPP_{MODIS} , $R^2=71.8\%$. Las incertidumbres en GPP_{MODIS} han sido ante todo atribuidas a diferencias en el factor de estrés f involucrado en su formulación, f_{MODIS} , dependiente del déficit de vapor de presión, D , y T , que no describió plenamente las condiciones de estrés ambiental para el lugar de medida.




Figura R.5. Evolución estacional de la GPP y el NEE observados experimentalmente para el periodo de medidas completo abarcando el estudio de los cuatro diferentes cultivos/años.

Abstract

This chapter presents: a) results of GPP 8-d estimated values, GPP_{LUE} , using a Light Use Efficiency Model, LUE, in a non-irrigated rotating rapeseed crop in the upper Spanish plateau, and b) inter-comparison results of observed GPP 8-d, GPP , with those concurrently retrieved by MODIS, GPP_{MODIS} . The rotation scheme over the four-year study comprised rapeseed, wheat, peas and rye. Rapeseed, peas and, in part, rye grew under well-watered conditions whereas wheat was dominated by drought.

Input data for the LUE model were the FPAR 8-d products supplied by MODIS, $FPAR_{MODIS}$, in situ PAR measurements, and a scalar f , varying between 0 and 1, to take into account the reduction of the maximum PAR conversion efficiency, ϵ_0 , under limiting environmental conditions. In this study, f values, f_{LUE} , were assumed to be dependent on air temperature, T , and the evaporative fraction, EF , which was considered a proxy of water availability. ϵ_0 , a key parameter in LUE models, which varied according to land use, was derived through the results of a linear regression fit between GPP and concurrent G_{APAR} estimates defined as the product of PAR, $FPAR_{MODIS}$ and f . Overall, the LUE model provided satisfactory results, $R^2=86.3\%$, significantly improving GPP_{MODIS} estimates, $R^2=71.8\%$. GPP_{MODIS} uncertainties have primarily been attributed to differences in the f stress factor involved in its formulation, f_{MODIS} , depending on vapour pressure deficit, D , and T , which did not fully describe the environmental stress conditions at the measuring site.

Overall, ϵ_{0LUE} yielded 3.331 ± 0.104 g C MJ⁻¹ although this varied depending on crop architecture, phenology and prevailing meteorological conditions. Crop-to-crop ϵ_{0LUE} ranged from 2.738 ± 0.171 to 3.954 ± 0.195 g C MJ⁻¹ for peas and rye, respectively, yielding intermediate values for rapeseed and wheat, 2.916 ± 0.182 and 2.859 ± 0.230 g C MJ⁻¹, respectively. ϵ_{0MODIS} , derived from the linear fit of GPP versus GPP_{MODIS} , yielded 2.128 ± 0.098 g C MJ⁻¹ and crop-to-crop ranged from 1.278 ± 0.173 to 2.412 ± 0.117 g C MJ⁻¹ for wheat and rapeseed, respectively. The best linear fits corresponded to crops growing under well-watered conditions, rapeseed and peas, and the worst fits were for wheat. The $\epsilon_{0LUE}:\epsilon_{0MODIS}$ ratio, 1.56, was consistent with the $f_{LUE}:f_{MODIS}$ ratio, 0.69, revealing the central role of f

formulation in LUE models and therefore in the ε_0 value obtained at a specific biome. GPP annuals were 1684, 714, 733 and 1409 g C m⁻² for rapeseed, wheat, peas and rye, respectively.

Keywords: biofuel crops, rapeseed rotation crops, GPP, LUE models, MODIS GPP calibration

5.1 Introduction

Climate warming is an indisputable fact, as evidenced by changes in various indicators over the last 100 years (IPCC, 2007, 2013). At present, there is reasonably wide consensus that observed changes might be attributed to an increase in greenhouse atmospheric concentrations caused by human activities due to a rise in emissions and land use changes (Houghton, 1999). Atmospheric CO₂ concentrations, the major greenhouse contributor, increased from the pre-industrial value, 278 ppm, to 398.6 ppm in 2014, the longest temporal series recorded in Mauna Loa (<http://www.cmdl.noaa.gov>) showing a steadily increasing trend. In this context, predicting gross primary production, GPP, the total amount of CO₂ assimilated by plants, is of crucial importance.

GPP is indirectly derived by eddy covariance flux towers as the difference between net ecosystem exchange, NEE, and respiration, RE, during daylight. NEE is measured directly and RE may also be measured using chambers or may be parameterized using NEE nocturnal data on soil or air temperature. The increasing number of covariance flux towers in different biomes around the world has provided insights into significant NEE and consequently GPP geographical variability (Baldocchi et al., 2001; Baldocchi, 2008; Lafont et al., 2002; Reichstein et al., 2007; Running et al., 1999). Among existing predictive methods, light use efficiency models, LUE, are considered a robust tool since they describe GPP spatial and temporal variation. These models are based on the original concept of Monteith who suggested that GPP or NPP, net primary productivity, of well-watered crops was linearly related to the amount of photosynthetic radiation absorbed by vegetation, APAR, the product of photosynthetic active radiation, PAR, by the fraction of PAR absorbed, FPAR. A PAR conversion efficiency factor, ϵ , translates APAR into GPP or NPP carbon units. FPAR can be measured directly or retrieved by remote sensing. The increasing number of orbiting satellites able to supply land vegetation products offers a powerful tool to estimate GPP at a global scale. Among these satellites, EOS MODIS (Moderate Resolution Imaging Spectroradiometer) from NOAA directly computes FPAR, FPAR_{MODIS}, with a typical spatial resolution of 1km x 1km, thus affording an excellent

opportunity to derive GPP and calibrate the results obtained in a specific geographical biome using ground measurements. The MODIS satellite also retrieves GPP 8-d composites, GPP_{MODIS} , thereby providing an additional advantage to inter-compare and validate these results with those derived from ground measurements (Fensholt et al., 2006; Gebremichael and Barros, 2006; Turner et al., 2003; Turner et al., 2005).

ε depends on vegetation type and suboptimal climate conditions, such as water stress. In order to quantify ε , one common approach involves considering optimal light use efficiency, ε_0 , and including a suitable scalar f with values ranging from 0 to 1 to take account of constraints in climate conditions:

$$\varepsilon = \varepsilon_0 f \quad (5.1)$$

ε_0 values, a key point in LUE models, differ enormously depending on their formulation. For instance, MODIS default values for 11 global biome classes vary from 0.604 to 1.259 g C MJ⁻¹ (Running et al., 2000), whereas the C-fix model (Veroustraete et al., 2002) considers a universal value of 1.1 g C MJ⁻¹. Formulating LUE models also depends on how environmental stress constraints, namely f , are determined (Fensholt et al., 2006). Thus, the MODIS algorithm considers a multiplicative combination of two factors depending on the vapour pressure deficit, D , and air temperature, T , each ranging from 0 to 1 (Leuning et al., 2005). The D scalar consideration is based on the fact that high D , typically above 20 hPa, have usually been linked with inducing stomata closure in non-irrigated plants. However, it has also been argued that the constraint imposed by D does not always adequately describe water availability of plants, and several authors (Yuan et al., 2007) have proposed substituting the D factor by the evaporative fraction, EF . Other models include a third multiplicative factor, e.g., a soil moisture index (Prince and Goward, 1995) or a leaf phenology index (Li et al., 2007; Wang et al., 2010; Xiao et al., 2005).

Crops are of increasing concern in terrestrial ecosystems. The enormous potential of crops in greenhouse mitigation has recently been

emphasized (Smith, 2004; Smith et al., 2008). Although crops are estimated to be the largest biospheric source of carbon lost to the atmosphere, current estimates remain uncertain and their behaviour as both a CO₂ source (Schulze et al., 2009) or sink (Gilmanov et al., 2013; Jaksic et al., 2006; West et al., 2010) has been reported. Different management practices, such as tillage type, rotation schemes, irrigation and cropland expansion might be some of the reasons why crops are sources or sinks in different regions around the world (Tao et al., 2011). Climatic conditions are another driver involved in observed inter-annual variations (Pei et al., 2013).

The general aim of this chapter is to present the most relevant results of GPP seasonal evolution over four years in a non-irrigated rotating biodiesel rapeseed crop in the upper Spanish plateau. The reasons for selecting this crop type are: 1) The large increase in cultivated areas in recent years due to the environmental benefits attributed to biodiesel fuels. 2) Biodiesel from rapeseed predominates in Europe, EU25 (Reijnders and Huijbregts, 2008). In Spain, rapeseed production and the planting surface approximately doubled from 2007 to 2011 and, specifically, the upper Spanish plateau has headed national rapeseed production since 2007 (MAGRAMA, 2013). The rapeseed rotation cycle, which typically extends over four or five years, thus provides a good opportunity to describe the behaviour of the different crops seeded at the same plot. The rotation cycle presented in this study consists of the non-irrigated annual rotation of rapeseed, wheat, peas and rye. The inclusion of rye, a crop rarely studied, offers an added benefit.

The specific objectives of this chapter are:

- 1) To present and compare crop-to-crop seasonal evolution of observed GPP 8-d composites, GPP.
- 2) To derive both an overall and a crop-to-crop LUE model. Particular attention is devoted to obtaining overall and crop-to-crop ϵ_{0LUE} values.
- 3) To calibrate MODIS GPP 8-d composites, GPP_{MODIS} overall and crop-to-crop.

- 4) To calibrate and assess the accuracy of the MODIS FPAR 8-d product, $FPAR_{MODIS}$, using LAI ground-based measurements, LAI, performed during the growing season, GS.

5.2 Material and methods

5.2.1 Site description

The experimental site is on the Monte de Rocío agricultural farm, which covers an area of 400 ha, and is located in the centre of the upper Spanish plateau (41° 46' 44.4" N, 4°52' 19.19" W, 849 m a.m.s.l.). The region is semi-arid with a Mediterranean-Continental climate characterized by low temperatures in winter months and warm and dry summers. The overall annual mean rainfall recorded at Villanubla Airport (close to the farm) is 450 mm. The land use of the farm is a mosaic of rotating cereal crops, with wheat and barley predominating. The selected plot covers 36 ha and has its own electrical facilities in the centre, a feature which, combined with the very flat terrain of the area, offered extremely suitable conditions for micrometeorological measurements and hence, for providing accurate NEE and GPP results. Agricultural practices at the selected plot applied during the period of measurements, 2008-2011, consisted of annual rotation of non-irrigated rapeseed, wheat, peas and rye crops, respectively. Reduced tillage practices were used which, as already reported (Sánchez et al., 2002), contribute to reducing CO₂ soil efflux. Soil composition is sandy loam with an organic content between 60 to 65% sand, 20% clay, about 15% silt, and about 3% organic matter.

5.2.2 Eddy covariance and meteorological data

CO₂ and water vapour fluxes were measured using a typical eddy correlation system consisting of a Licor 7500 infrared analyzer and a METEK USA-1 sonic. The system operated at 10 Hz and was installed on a mast 3.5 m above the soil. Raw data were dually stored on a data logger and on a PC. These data were transferred daily by remote control to the Faculty of

Sciences at the University of Valladolid and processed as 30-min averages. Raw data processing was performed by means of the TK2 software developed by the University of Bayreuth (Mauder and Foken, 2004). The processing steps included despiking, coordinate rotation, time lag correction, frequency response correction and WPL correction (Paredes, 2013). A second mast measuring 2.5 m was installed and equipped with slow response probes, a quantum sensor to measure PAR (LI-190Sz, Li-Cor Inc., Lincoln, NE, USA), net solar radiation (model 8110, Ph. Schenk), relative humidity and air temperature, T, (model STH-5031), wind speed and wind direction (wind sentry, model 03002, Young, Campbell Scientific, Inc.). Two soil heat flux plates (HFP01, HukseFlux, Delft, The Netherlands) and one soil moisture probe, SM, (model 6545, type ML2x, ThetaProbe) completed the instrumentation. All these data were continuously recorded on another data logger (Model Meteodata, Geónica), transferred daily by remote control to the Faculty of Sciences and finally processed as 30-min mean values.

NEE eddy correlation measurements commenced at the beginning of March 2008. The slow response meteorological probes were fully operational at the beginning of April in the same year. NEE 30-min diurnal gaps were filled using the Michaelis Menten equations fitted using PAR as input data on a monthly or fortnightly basis, the latter being used during the GS (from March to June). Nocturnal NEE gaps were filled using the results of the respiration fit equation (see below, Eq. 5.7). The large gap, from November 2007 to February 2008, was filled using the results of a linear regression between GPP and concurrent LAI_{MODIS} 8-d composites (see 5.2.4). Most meteorological data gaps from October 2007 to March 2008 were filled using the records from another station located some 10 km from the measuring site, which can be considered representative enough at the plot site due to the flat terrain and homogeneity in the meteorological conditions prevailing in the study area. The exception to this rule was SM and soil flux data, which were not available at the second station. The SM gaps in March 2008 were filled using the results of the linear regression between diurnal SM and diurnal EF obtained by averaging the 30-min concurrent records from April to October. From the relatively satisfactory correlation found between both variables, the determination coefficient R^2

was 64%. Important inaccuracies in the RE calculation in March were neither expected nor detected after a detailed examination of the data set.

5.2.3 Ancillary data (LAI)

Except for peas, concurrent measurements of the canopy height and of the effective LAI evolution were performed during the GS. LAI measurements were carried out using a LAI-2000 (Plant canopy analyzer, Li-Cor) following Licor manual guidelines. Two series of five readings, with a sequence one above the canopy and four below the canopy, were performed in ten plants regularly distributed on a diagonal transect. Measurements were performed during daylight using a 270° view cap. Readings were processed using the software provided by the manufacturer. Finally, the results obtained in individual plants were averaged each day of measurements. The number of measurements, limited to green canopy phenology, was 20, 7 and 12, for rapeseed, wheat and rye. Whenever several measurements per week were performed, as in the case of rapeseed, LAI 8-d composites concurrent with LAI_{MODIS} were obtained by averaging available ground data.

5.2.4 Remote sensing data

MODIS/Terra 8-d products, MOD15 for FPAR_{MODIS} and LAI_{MODIS} and MOD17 for GPP_{MODIS}, were loaded from <http://reverb.echo.nasa.gov/> during the whole period of study. From all the data extracted, in this study we used those retrieved in the central pixel. To minimize the impact of noise, each final 8-d composite was obtained by averaging the corresponding data and the two neighbouring 8-d ones. Available MODIS data sets correspond to the V005 collection and have a spatial resolution of 1 km x 1 km. Although the spatial resolution of the pixel is higher than the plot size, due to the excellent MODIS geolocation accuracy, around 50 m (Hashimoto et al., 2012; Wolfe et al., 2002; Wolfe et al., 2012), the very flat terrain and the location of the eddy-covariance system, centered in the plot, only minor inaccuracies could be expected in the borders of the pixel. This issue is

addressed using the LAI ground measurements performed as described in section 5.4.3.

5.2.5 Model approach

The methodology used in this chapter is shown in the flow chart included in the Fig. 5.7. A detailed description is given below.

GPP_{LUE} was computed as follows:

$$GPP_{LUE} = \varepsilon_0 f_{LUE} APAR = \varepsilon_0 G_{APAR} \quad (5.2)$$

where APAR was determined using $FPAR_{MODIS}$ retrievals and direct ground PAR measurements. In this study, the stress f factor considered, f_{LUE} , is the product of two indexes, EF, and a factor T_s depending on T:

$$f_{LUE} = f(EF, T_s) \quad (5.3)$$

EF is:

$$EF = \frac{LE}{LE+H} \quad (5.4)$$

where LE and H represent the latent and sensible heat concurrently measured in the eddy covariance tower. Low EF values, usually associated to low available LE, are expected to be linked to water stress, and moderate or high values to sufficient water availability. EF can be derived using models based on satellite imagery (Elhag et al., 2011; Lu et al., 2013; Pardo et al., 2014; Venturini et al., 2008; Wang et al., 2006), which represents an additional advantage for upscaling purposes.

T_s index is given by

$$T_s = \frac{(T - T_{min})(T - T_{max})}{[(T - T_{min})(T - T_{max})] - (T - T_{opt})^2} \quad (5.5)$$

T is the air temperature and T_{\min} , T_{\max} , T_{opt} the maximum, minimum and optimum air temperatures. In this study, T_{\min} and T_{\max} considered were 0 and 36 °C. Negative T values were set to zero. For T_{opt} , we followed the same criteria as proposed by Albergel et al. (2010) based on the assumption that maximum efficiency is reached at the same temperature as GPP peaks. The optimum value was 18 °C, a result that is slightly lower than others reported in the literature, which range from 22 °C (Patel et al., 2010) to 20.3 °C (Yuan et al., 2007).

GPP were obtained by subtracting direct NEE measurements obtained by the eddy covariance tower and the respiration term, RE:

$$\text{GPP} = -\text{NEE} + \text{RE} \quad (5.6)$$

Since GPP only occurs during daytime, RE was computed using NEE nocturnal 30-min data by means of a modified Van't Hoff equation depending on T, which also takes SM into account:

$$\text{RE} = a \text{ SM exp}(bT) \quad (5.7)$$

Both unknowns, a and b, were estimated using the Marquard algorithm for each type of crop during the period March-October. For the remaining months of the year, no distinction was made between crop type, and a similar simplified equation only dependent on T was used. SM was excluded in this case because it did not lead to any improvement in the non-linear fit. Nocturnal NEE 30-min observations were filtered using a friction velocity, u^* , threshold of 0.15 m s⁻¹. This threshold was determined using a combination of visual methods based on the analysis of nocturnal NEE statistical results at different u^* intervals and the optimization of determination coefficients, R^2 , of non-linear fits (Papale et al., 2006; Reichstein et al., 2005). Diurnal RE 30-min were computed using nocturnal fitted equations by considering diurnal T and SM 30-min data. 8-d composites were determined by averaging 30-min data in each 8-d time period. For EF 8-d composites, EF, the same procedure was applied. Finally,

ϵ_{OLUE} was derived through the slope of the linear regression fit of the GPP values against concurrent G_{APAR} estimates.

5.2.6 Statistical analysis

To evaluate the performances of the GPP_{LUE} , $\text{GPP}_{\text{MODIS}}$ and inter-comparison results in general, we used the following metrics in this study:

-The coefficient of determination, R^2 , which represents how much variation in the observations is explained by the model.

-The mean absolute error, MAE. It gives the average magnitude of the errors in a set of forecasts without considering their direction. It is computed by the following equation:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - o_i| \quad (5.8)$$

where y_i and o_i are the simulated and observed values, respectively

-The root-mean-square error, RMSE. This metric, one of the most frequently used, gives the standard deviation of the model simulated error using the following equation:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - o_i)^2} \quad (5.9)$$

Since the errors are squared before being averaged, RMSE gives a relatively high weight to large errors.

5.3 Results

Table 5.1 shows the period of seed of each crop type. As derived from this Table, seed time varied and ranged from mid September for rapeseed to late January in the case of peas. Harvest was always in mid July (from 12th to 18th).

The maximum canopy height of rapeseed, wheat and rye was 1.30, 0.60 and 1.60 m respectively, the values being reached at the end of May. Although no measurements were performed in the pea crop, according to the farmer's information the maximum height was approximately 0.45-0.50 m, a typical value for this crop in the upper Spanish plateau.

Table 5.1. Time of seed and harvest, maximum canopy height, H and maximum ground-based LAI, LAI, for each type of crop.

Crop	Time of seed	Time of Harvest	H (m)	LAI
Rapeseed	20/09/2007	18/07/2008	1.30	2.56
Wheat	06/11/2008	14/07/2009	0.60	2.17
Peas	25/01/2010	12/07/2010	~ 0.45-0.50	-
Rye	22/10/2010	13/07/2011	1.60	2.28

5.3.1 Meteorological driving variables

Fig.5.1a shows the patterns of daily T 8-d, T, and PAR 8-d, PAR, over the study period. Mean T was 11.5 °C and extreme values were -1.8 °C and 24.2 °C. Maximum and minimum values were reached in July-August and in December-January. PAR mean and extreme values were 56.3, 7.0 and 106.4 MJ m⁻². 2008 was the most temperate year, with extreme values of 0.0 and 21.0 °C, and also the cloudiest, especially in May. The remaining years displayed similar seasonal features. Fig.5.1b depicts the rainfall 8-d, RF, and SM 8-d, SM, patterns. RF patterns show the typical seasonal variation in the studied area featured by two peaks,

the first in spring, April-May, and the second in autumn-winter, from October to January, depending on the years. RF in summer, July-August and to some extent September, is normally very weak. From the comparison between RF year-to-year patterns, substantial variability is in evidence. 2008 was a "normal" year, with the yearly accumulated rainfall being 447 mm, although it was also the rainiest in the GS (March-June, DOY 57-177), with an accumulated rainfall of 252 mm. 2010 was the rainiest year, with an accumulated yearly rainfall of 517 mm which dropped dramatically to 336 mm in 2009. This latter year was dominated by drought. In the GS, accumulated rainfall dropped to 106 mm in contrast to 2010, 220 mm. 2011 can be considered as a "normal-dry" year, with the accumulated yearly rainfall and in the GS being 426 and 161 mm, respectively. As expected, year-to-year SM patterns were consistent with those for RF; 2010 exhibited the highest SM records and 2009 the lowest, particularly in spring, with mean annual values being 25.4 and 17.6%, respectively. Extreme SM values ranged from 3.7 to 40.8%. The very low values recorded in mid summer, July-August, and even the first fortnight of September reveal the low soil water availability due to the increased temperature, lack of vegetation after harvest and weak rainfall at the measuring site. Another interesting feature is the similarity in SM and rainfall events. SM peaks tended to occur in phase with RF events. The SM lags occasionally found, e.g. mid September 2008 (DOY 265) and early June 2010 (DOY 153), might be attributed to heavy or moderate rainfall occurring over the last few days of the 8-d composite. The lack of agreement of peaks sometimes found in late spring or summer could be due to the local character of rainfall. One example is mid July, 2009 (DOY 193), in which rainfall was not measured at Villanubla station, yet when an increase in SM, indicative of rainfall occurrence, was recorded at the measuring site.




Figure 5.1. a) Seasonal patterns of air Temperature, T, and PAR for each crop type. b) Seasonal patterns of rainfall, R, and soil moisture, SM, for each crop type. Rapeseed, wheat, peas and rye were seeded in 2008, 2009, 2010 and 2011, respectively. Data in both Figures refer to 8-d composites. X bottom and top axes show the date and DOY, respectively

5.3.2 Stress indexes

Fig.5.2a depicts the seasonal course of EF, T_{s_r} , and f_{LUE} over the study period. The comparison between the EF year-to-year patterns reveals certain analogies and differences. Amongst the analogies, the systematic increase in EF during autumn and winter (October-January) is worthy of note, reaching maximum values of 0.6. This behaviour is consistent with the increase in SM resulting from increased rainfall. Abrupt visible peaks, as in the case of SM, tended to occur in phase with rainfall events or with an eight-day delay (see Fig.5.1b). Another common feature was the EF decline during summer, from July to September, dropping by up to around 0.1. These low values are a result of the dramatic decline in LE (values rarely exceeded 60 W m^{-2}) and the increase in H (values above 520 W m^{-2}).

Despite the similarities between EF seasonal patterns in the GS, seasonal EF courses evidenced substantial variability. Rapeseed, the crop with the highest evapotranspiration, showed the greatest EF value, 0.73, as well as a marked seasonal pattern. EF progressively rose from March to early May, reached a plateau until approximately mid June (DOY 169) and then declined sharply. Rye behaved in a similar manner, with the EF peak reaching 0.69, although the decline was earlier, and occurred in mid May (DOY 129). Differences in the seasonal shape of both crops are in agreement with prevailing environmental conditions, especially rainfall, as well as their different architecture and phenology. Although both crops grew under well-watered conditions, May 2008 was the rainiest month, with a rainfall of 130 mm, whereas May 2011 was significantly drier, with rainfall being 23 mm. The higher and lower accumulated rainfall during the rapeseed and rye growing period, might have contributed to significantly delaying and bringing forward the senescence period, respectively. Rapeseed commenced the flowering period in early April, pod formation started in early June, and senescence was clearly visible in late June. During these phenological stages, LE remained relatively high (upper quartiles, 241 and 298 W m^{-2} in May and June as compared with those for H, 143 and 172 W m^{-2}), resulting in elevated EF values in May and most of June. Rye behaved similar to conventional grain crops at the measuring site. Heading took place in early May, and the onset of senescence was

visible in early June, particularly in the lower and mid canopy. The LE upper quartiles were 236 and 224 W m^{-2} in April and May, exceeding those for H, 100 and 187 W m^{-2} .

In contrast, wheat and especially peas did not show such an evident EF seasonal variation during growing. Peaks were significantly lower, 0.54 and 0.57, and were recorded in mid April 2009 (DOY 105) and mid-late April 2010 (DOYS 105, 113), respectively. In the case of wheat, EF likely remained lower than the expected values in well-watered conditions due to drought in 2009. Maximum LE values tended to be below 250 W m^{-2} (upper quartile, 155 and 142 W m^{-2} in April and May) and were generally lower compared to H, (upper quartile, 172, 255 W m^{-2} the same months). The irregular EF shape of peas, another well-watered crop, might be attributed to the superimposed effects of rainfall peaks, e.g., DOY 49 and 81, the later emergence period and lower evapotranspiration due to its architecture and a lower canopy height. Maximum LE values in the GS generally remained below 250 W m^{-2} , (upper quartiles 180 and 168 W m^{-2} in April and May), and were of a similar order of magnitude to H (upper quartile 158 and 192 W m^{-2} the same months).

From late February to late June, T_s values ranged from 0.7 to 1, most data being close to 1, leading to a great similarity between EF and f_{LUE} patterns. Similar results were obtained in summer and autumn. The lowest T_s values were reached in winter, dropping by up to 0.2-0.3. These results suggest that the T_s stress index has no significant impact on GPP most of the time, except in winter, a period in which GPP reaches the minimum values (see below).

5.3.3 FPAR MODIS retrievals

The $\text{FPAR}_{\text{MODIS}}$ patterns depicted in Fig.5.2b followed the expected seasonal evolution consistent with growing. $\text{FPAR}_{\text{MODIS}}$ progressively increased from late February, peaked in May and then began to decline, reaching minimum values in central summer and winter. Despite the similarities in the year-to-year patterns, some differences in magnitude and shape can be distinguished. Rapeseed exhibited the greatest $\text{FPAR}_{\text{MODIS}}$

value, 0.68, as well as amplitude, with a plateau spreading over April-May and early June. As mentioned above, the plateau corresponded to flowering and the initial stage of pod formation. Despite the weak $FPAR_{MODIS}$ seasonal amplitude, peas behaved in a similar manner, with a plateau lasting approximately three months, from mid April to late June (DOY 97-176). Peas exhibited the lowest $FPAR_{MODIS}$ peak, 0.40, and values remained relatively high, close to 0.23, in most of July. The shape of these seasonal courses contrasts with those corresponding to wheat and rye. In both cases, $FPAR_{MODIS}$ also showed a progressive increase followed by a decline although no significant plateau was observed. As in the two preceding crops, maximum values, 0.45 and 0.55, were reached in mid May. The comparison between year-to-year patterns reveals that MODIS satisfactorily reflected the main features of the crops as well as the expected $FPAR_{MODIS}$ decline in 2009 that affected wheat due to the drought as compared with rapeseed and rye. The contrast between $FPAR_{MODIS}$ of rapeseed and peas is an evident example consistent with the different architecture of both crops.

5.3.4 GPP-LUE model results

The crop-to-crop GPP seasonal pattern is depicted in Fig.5.2c. GPP rose from March to May and then declined sharply, reaching minimum values in central summer and winter. Rapeseed, pea and rye GPP peaks, 110, 56 and 110 $g\ C\ m^{-2}\ 8-d$ respectively, occurred in mid May (DOY 129), late May (DOY 145) and early May (DOY 121) whereas in the case of wheat, the peak, 53 $g\ C\ m^{-2}\ 8-d$, was earlier, in mid to late April (DOY 113). The different crops again showed certain differences in seasonal cycle amplitude. Rapeseed and rye presented the broadest seasonal cycle, spanning from March to mid-early July, 143 days (DOY 57-200) and 135 days (DOY 57-192), respectively, whereas in the case of wheat and peas said cycles were 123 and 104 days, from late February to late June (DOY 41-184) and from early April to early July, (DOY 89-193), respectively. Annual accumulated GPP was 1684, 714, 733 and 1409 $g\ C\ m^{-2}$ for rapeseed, wheat, peas and rye.

As pointed out earlier, ϵ_{OLUE} was derived through the slope of a linear regression fit between the GPP and G_{APAR} results as defined in Eq. 5.2. Fig. 5.3 shows the results of the linear fit. Coloured symbols, red, green, pink and blue, correspond to rapeseed, wheat, peas and rye, with the bold black line corresponding to the overall fit. Table 5.2 summarizes the parameter estimates overall and for each individual crop, the intercept, a , the slope, ϵ_0 , R^2 , MAE, and RMSE. From this Figure, the goodness of the fit can be inferred. Overall, R^2 yielded 86.1%, the intercept was close to zero, $2.747 \text{ g C m}^{-2} \text{ 8-d}$, and the slope, ϵ_{OLUE} , $3.331 \pm 0.104 \text{ g C MJ}^{-1}$. Crop-to-crop results also proved satisfactory, with R^2 ranging from 90.8 to 77.8% for rapeseed and wheat, respectively. The ϵ_{OLUE} extreme values obtained were $3.954 \pm 0.195 \text{ g C MJ}^{-1}$ for rye, and $2.738 \pm 0.171 \text{ g C MJ}^{-1}$ for peas, respectively. ϵ_{OLUE} for rapeseed and wheat yielded intermediate values of 2.916 ± 0.182 and $2.859 \pm 0.230 \text{ g C MJ}^{-1}$, respectively.

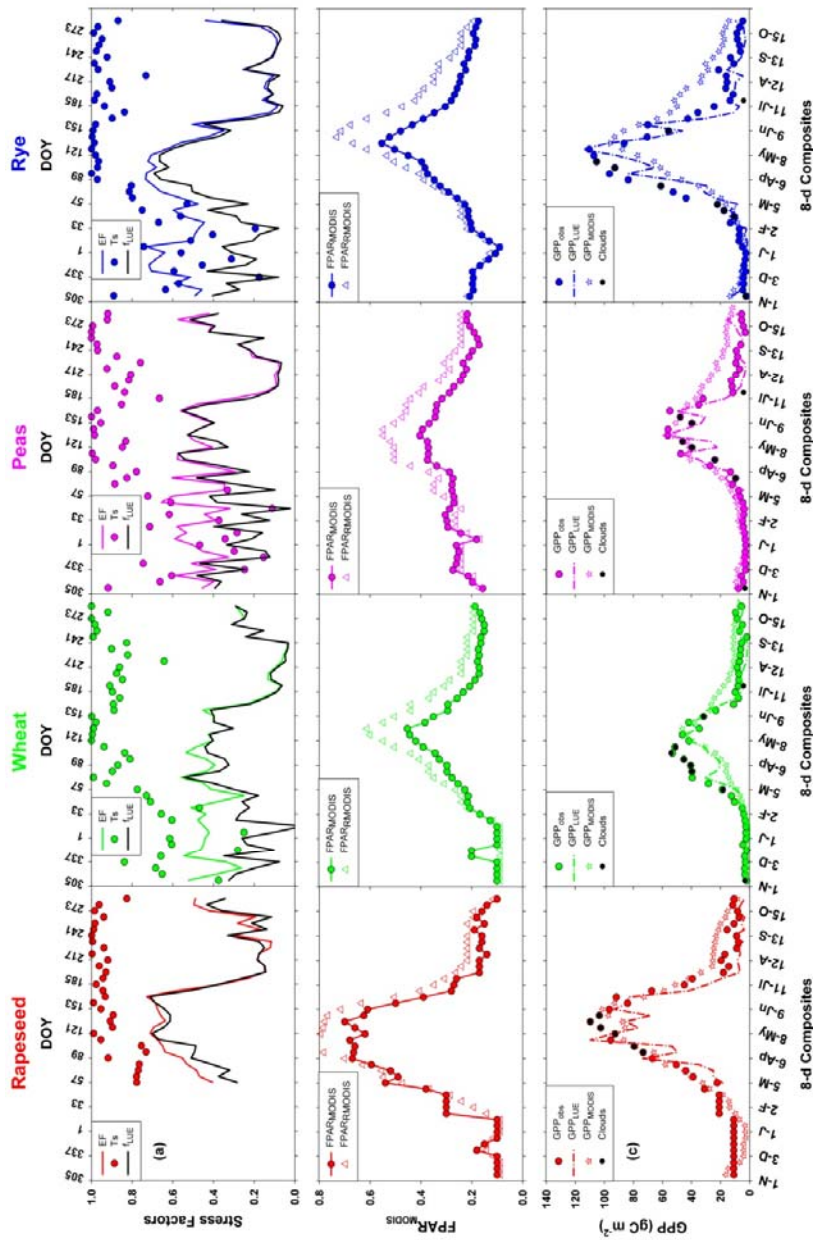


Figure 5.2. a) Seasonal patterns of stress indexes, evaporative fraction, f_{LUE} and their product, f_{LUE} , for each crop type. b) Seasonal patterns of $FPAR_{MODIS}$ and $FPAR_{MODIS}$ retrievals for each crop type. c) Seasonal patterns of GPP observed, GPP_{LUE} and GPP_{MODIS} calibrated retrievals for each crop type. Black dots indicate partly cloudy days during growing season, GS. Rapeseed, wheat, peas and rye were seeded in 2008, 2009, 2010 and 2011, respectively. Data in all Figures refer to 8-d composites. X bottom and top axes show the date and DOY, respectively.

The comparison between the GPP and GPP_{LUE} results plotted in Fig.5.2c illustrates the general good agreement of the modelled results. However, from this Figure certain discrepancies between both temporal series in GS are evident, especially in April. Most of these and, in particular, underestimation of the modelled results, occurred under partly cloudy 8-d days, shown as black dots in this Figure. During these days, PAR declined leading to a decrease in GPP_{LUE} as a result of its direct influence on LUE model formulation in contrast to GPP which remained significantly higher. The GPP_{LUE} underestimation obtained suggests that the light use efficiency, ϵ , on partly cloudy days tends to increase compared to that on clear days, a result which concurs with others reported.

5.3.5 Inter-comparison between GPP and GPP MODIS retrievals

Fig.5.4 depicts the results of the linear fit of GPP versus GPP_{MODIS} retrievals. Coloured symbols, red, green, pink and blue, correspond to rapeseed, wheat, peas and rye, and the bold black line corresponds to the overall fit. All linear fits were performed by dividing GPP_{MODIS} retrievals by the one originally prescribed for crops in the MODIS look up table, $0.604 \text{ g C MJ}^{-1}$ (Running et al., 2000). Therefore, the slope of the linear fit accounts for the ϵ_{0MODIS} values based on validation results at our measuring site without any prior assumption of prescribed values. The results of the overall and individual crop-to-crop linear fits are shown in Table 5.2. Overall, the fit proved moderately satisfactory, $R^2=71.7\%$, with the intercept being close to zero, -3.214 g C 8-d , and the slope, namely ϵ_{0MODIS} , $2.128 \pm 0.098 \text{ g C MJ}^{-1}$. Crop-to-crop results showed a strong correlation for rapeseed, $R^2=89.8\%$, $\epsilon_0=2.412 \pm 0.117 \text{ g C MJ}^{-1}$, and peas, $R^2=85.9\%$, $\epsilon_0=1.747 \pm 0.107 \text{ g C MJ}^{-1}$ in contrast to rye, $R^2=66.5\%$, $\epsilon_0=2.301 \pm 0.246 \text{ g C MJ}^{-1}$ and wheat, $R^2=55.5\%$, $\epsilon_0=1.278 \pm 0.173 \text{ g C MJ}^{-1}$, for which the worst results were obtained. The calibrated GPP_{MODIS} temporal series (original retrievals multiplied by ϵ_{0MODIS} of each individual crop) are depicted in Fig.5.2c.

The comparison between Fig.5.3 and 5.4 and the statistics shown in Table 5.2 reveals the better accuracy of the LUE model against the MODIS estimates overall. The first point worthy of note is the higher scatter of GPP_{MODIS} against GPP as compared with those obtained for GPP_{LUE} modelled results. This conclusion is also derived through the values of all the statistics, a lower R^2 , and a higher MAE and RMSE. The second point worth noting is the GPP_{MODIS} overestimation during summer, from July to September, a period of time during which GPP_{MODIS} are significantly higher than GPP (see Fig.5.2c). As the LUE model and MODIS results have the same APAR, the differences found depend on the stress factors considered in each formulation, $f_{LUE}(EF, T_s)$ in this study and $f_{MODIS}(D, T)$. The main conclusion to be drawn from the preceding results is that the f_{LUE} considered here describes the GPP seasonal variation more realistically than f_{MODIS} does. This is particularly true in summer when EF and SM drop dramatically to values as low as 0.1 and less than 5%, respectively. It should also be noted that the best linear fits between GPP and GPP_{MODIS} corresponded to rapeseed and peas, the two well-watered crops, the worst fits being for wheat affected by drought.

Table 5.2. Optimal light use efficiency, ϵ_0 , intercept, a , determination coefficient, R^2 , mean absolute error, MAE, and root mean square error, RMSE, for each crop type, rapeseed, wheat, peas and rye, seeded in 2008, 2009, 2010 and 2011. LUE and MODIS subscriptions refer to the results of the LUE model and GPP_{MODIS} 8-d retrievals, respectively.

Crop	ϵ_{LUE} g C MJ ⁻¹	a_{LUE} g C m ⁻²	R^2_{LUE} (%)	MAE _{LUE} g C m ⁻²	RMSE _{LUE} g C m ⁻²	ϵ_{MODIS} g C MJ ⁻¹	a_{MODIS} g C m ⁻²	R^2_{MODIS} (%)	MAE _{MODIS} g C m ⁻²	RMSE _{MODIS} g C m ⁻²
Overall	3.331	2.747	86.1	7.7	10.8	2.128	-3.214	71.7	10.7	14.8
Rapeseed	2.916	10.069	90.8	8.8	11.2	2.412	0.056	89.8	8.7	10.6
Wheat	2.859	2.299	77.8	5.0	7.7	1.278	1.704	55.5	7.5	10.9
Peas	2.738	0.585	85.4	4.5	6.6	1.747	-5.661	85.9	6.5	5.1
Rye	3.954	5.052	90.3	7.5	10.7	2.301	-2.242	66.5	19.9	7.5

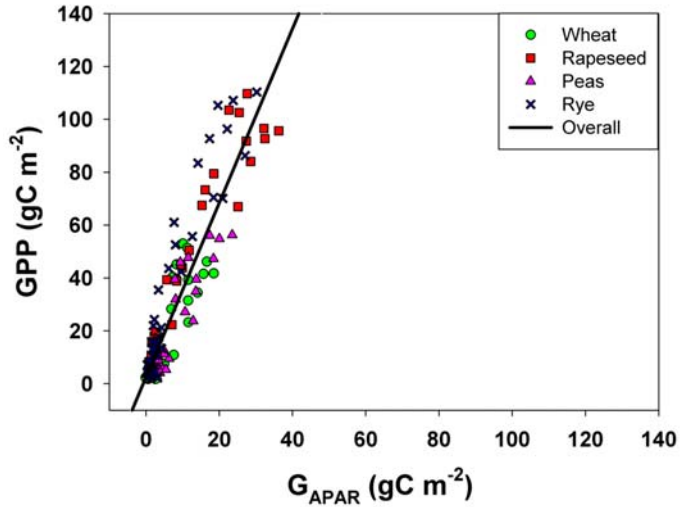


Figure 5.3. Linear fit of observed GPP versus modelled G_{APAR} for each crop type. Red, green, pink and blue symbols correspond to rapeseed, wheat, peas and rye, respectively, seeded in 2008, 2009, 2010 and 2011. The black line shows the overall linear fit for rapeseed, wheat, and rye.




Figure 5.4. Linear fit of observed GPP versus GPP_{MODIS} 8-d composites for each crop type. Red, green, pink and blue symbols correspond to rapeseed, wheat, peas and rye, respectively, seeded in 2008, 2009, 2010 and 2011. The black line shows the overall linear fit for rapeseed, wheat, and rye.

5.4 Discussion of the results

5.4.1 GPP

The comparative analysis of the GPP patterns of each crop stresses the influence of the architecture, phenology and climatic conditions. The highest GPP values were obtained for crops with a denser and greater canopy height, rapeseed, 1.30 m and rye, 1.60 m, which also exhibited the longest seasonal cycle, lasting around 143 and 135 days. The wider seasonal cycle of rapeseed could be attributed to the more temperate climatic conditions from mid May to mid June, 2008, T being 3.6 °C lower than in 2011, and to the higher accumulated rainfall, 80 mm against 50 mm.

Rapeseed, peas and, in part, rye grew under well-watered conditions at the measuring site, accumulated rainfall during GS being 252, 220 and 161 mm, respectively. Conversely, wheat growing was affected by water stress, with rainfall in the GS dropping to 106 mm. The influence of drought contributed greatly to an early GPP peak, which occurred in late April, and to reducing the maximum height of the canopy, which under well-watered conditions is usually 0.7-0.8 m. Differences in the emergence and growing phenological stages in the case of peas, the crop seeded latest, in January, also explain the delay in the seasonal cycle, from April to late June.

Annual rapeseed and rye GPPs, 1684 and 1409 g C m⁻², respectively were rather high compared to other results reported for winter crops including rapeseed (Béziat et al., 2009). In particular, the annual rapeseed GPP obtained in this study, a C3 plant, was comparable to C4 species, like corn, featured by higher light use efficiency and biomass production (Zhu et al., 2010). Reported annual GPP values for corn are¹ 789-1171 g C m⁻² (Yan et al., 2009), and 1567 g C m⁻² (Wang et al., 2012). The annual GPP of rye, although also high, is in the range of other results published, 744-2097 g C m⁻² (Koizumi, et al., 1990)¹. The same occurred in the case

¹ NPP data reported by authors have been transformed to GPP using a ratio of 0.55 (see Eqs. 5.10-5.11 in section 5.4.2)

of wheat and peas, 714 and 733 g C m⁻², both values being in the range similar to those reported for crops (Zhao et al., 2005). In the case of peas, the annual GPP obtained in this study, 733 g C m⁻² was lower than reported results of irrigated peas ~1014-1180 g C m⁻² (Giunta et al., 2009)¹ and in the range of some similar legumes, e.g, chickpea, under and without water stress (Tesfaye et al., 2006)¹ ~ 528-930 g C m⁻². For wheat, annual GPP, 714 g C m⁻² was similar to that reported by Yan et al. (2009), 602-729 g C m⁻², and intermediate to extreme values, 907 and 499 g C m⁻², recorded at another agricultural site located close to the measurement station (unpublished results) in 2003, a rainy year (602 mm), and 2005 affected by severe drought (276 mm). The dramatic decline in 2005 proves the significant impact of droughts on GPP and therefore on crop inability to sequester CO₂. This result emphasises the adverse consequences of climate change not only on crop production but also on a possible increase in atmospheric CO₂ which might take place in the Southern Mediterranean, one of the most vulnerable regions foreseen by the IPCC (2007) in future years. Rapeseed, wheat, pea and rye accumulated GPP in GS was 1219, 551, 521 and 1134 g C m⁻². Despite the large differences found between the different crops, the contribution of the GS to the annuals was rather conservative, and accounted for 72.4, 77.2, 71.2 and 80.4% for the same crops.

The LUE model applied has properly fitted overall GPP (R²=86.1%) as well as crop-to-crop (R² ranged from 90.8 to 77.8 %), showing a significant improvement compared to concurrent GPP_{MODIS} retrievals (R²= 71.7%). The main GPP_{MODIS} inaccuracies have primarily been attributed to differences in the defined stress factor, f_{MODIS} on D and T with respect to f_{LUE} on EF and T_s used in this study. GPP exhibited a satisfactory correlation with f_{LUE} in GS, R²=59.7% proving its suitability to describe water availability in contrast with the weak correlation found when f_{MODIS} is considered, R²=12.4%. This result, together with the better linear fits of GPP versus GPP_{MODIS} obtained for crops less affected by environmental stress, rapeseed and peas, supports the interpretation given.

Another interesting result concerns the different order in magnitude of ε_{0LUE} and ε_{0MODIS}, overall, 3.331 and 2.128 g C MJ⁻¹, respectively.

$\epsilon_{0LUE}:\epsilon_{0MODIS}$ ratio was 1.56 overall and varied, depending on crop type, the values being 1.21, 2.24, 1.57 and 1.72 for rapeseed, wheat, peas and rye, respectively, the lower the ratios the better the watered conditions prevailing in GS (rapeseed and peas) and conversely, the greater the ratios the worse the watered conditions (wheat). Indeed, $\epsilon_{0LUE}:\epsilon_{0MODIS}$ was inversely proportional to the $f_{LUE}:f_{MODIS}$, 0.69 on average (the ratio was computed using the overall individual 8-d composites data). This result highlights the important role in the f formulation included in the LUE model on ϵ_0 results.

5.4.2 Maximum Light Use Efficiency, ϵ_0

Despite the abundant literature existing on ϵ values for different crop type, comparisons of our results with others reported are difficult given the different experimental methods used for NPP or GPP estimates and units used by authors. Thus, in some of the many field experiments based on NPP measurements, either total or above ground biomass production, results are expressed in g DM MJ⁻¹ of dry matter, DM, whereas in others, e.g. eddy correlation measurements, results are expressed in g C MJ⁻¹ absorbed by photosynthesis uptake. For unit conversion here, we use a similar approach to that reported by Lobell et al. (2002):

$$\epsilon_{\text{NPP}} (\text{g C MJ}^{-1}) = \epsilon_{\text{biomass}} (\text{g DM MJ}^{-1}) F S^{-1} \quad (5.10)$$

where F is the conversion unit of g DM to g C and S the carbon production. In this study, we considered F to be equal to 0.467. S was considered 1 or 0.8 depending on the reported values, namely, total or above ground carbon, respectively. Whenever no information was found, we assumed S=1. Finally, conversion to ϵ_{GPP} was performed:

$$\epsilon_{\text{GPP}} (\text{g C MJ}^{-1}) = R \epsilon_{\text{NPP}} (\text{g C MJ}^{-1}) \quad (5.11)$$

where R is the NPP:GPP ratio, considered here to be 0.55, the average value of those reported for crops (Aubinet et al., 2009; Beer et al., 2010; King et al., 2011; Moureaux et al., 2008).

An additional remark concerns solar radiation. Here, we normalize all results to PAR MJ⁻¹. Results expressed as a function of solar radiation, SR, were converted to PAR by dividing SR by 2. Finally, it should also be highlighted that a number of ϵ results reported based on biomass measurements were obtained under the climate conditions driving field experiments, meaning they may have been affected by water stress. In fact, the influence of an increase in D on subsequent ϵ decline is discussed by Kemanian et al. (2004). As a result, such comparisons with our results should be treated with caution. In contrast, results may be better compared when LUE models are applied to GPP or NPP results from eddy covariance

fluxes, since they usually include stress factors in their formulation and, hence, report ϵ_0 .

The ϵ_0 value obtained in this study, $3.331 \text{ g C MJ}^{-1}$, is in the range of those reported for the crops studied, ranging from 1.613 to $3.600 \text{ g C MJ}^{-1}$ (Akmal and Janssens, 2004; Lobell et al., 2002). Although various studies have shown that different crops have differing ϵ_0 values (Chen et al., 2011; Turner et al., 2006), the results published for a specific crop also present significant variability. For wheat, they range from 1.921 to $3.417 \text{ g C MJ}^{-1}$ (García et al., 1988; Lobell et al., 2002; Muurinen and Peltonen-Sainio, 2006; O'Connell et al., 2004). Reported values for peas range from 1.525 to $2.112 \text{ g C MJ}^{-1}$ (Giunta et al., 2009; Lecoecur and Ney, 2003; Worku and Demisie, 2012). For canola and rapeseed, the values are 2.165 and $2.049 \text{ g C MJ}^{-1}$, respectively (Justes et al., 2000; Soetedjo et al., 1998), and for rye they range from 2.038 to $3.600 \text{ g C MJ}^{-1}$ (Akmal and Janssens 2004). The significant differences reported might be attributed to many factors, such as irrigation, climate conditions, rotation schemes and agricultural management practices. Our results are in agreement with the variability observed for a specific crop and crop-to-crop, ϵ_{0LUE} ranging from 2.738 to $3.954 \text{ g C MJ}^{-1}$ for peas and rye, respectively, the larger values tending to be associated to crops with denser and taller canopies, rapeseed and rye. In dense canopies, more leaves are shaded and operate in the linear portion of the light response curve increasing the ϵ of the canopy as a whole. Conversely, in sparse canopies most leaves experience a similar light regimen, resulting in a decline in ϵ . It is also usually assumed that erect canopies of tall species, rye being one clear example, absorb incident radiation very efficiently without starving the shaded component optimal levels of transmitted radiation (Yahuza, 2011).

5.4.3 Calibration of $\text{FPAR}_{\text{MODIS}}$ using LAI ground measurements

GPP seasonal evolution at our measuring site was regulated by EF, the major stress factor, and FPAR. Both variables correlated well with GPP/PAR during the GS, ($R^2=71.2\%$), EF and $\text{FPAR}_{\text{MODIS}}$ accounting for 49.9 and 61.1% of the variance of the linear fit, thus indicating their joint contribution to GPP seasonal evolution. Hence, bias in EF or FPAR might be considered as an important error source of GPP estimates. Based on the satisfactory closure of energy balance, 93% (Chapter 3), bias in EF is not expected to lead to any significant error in GPP. Regarding FPAR, MODIS captured seasonal and inter-annual variations of each crop type reasonably well, retrievals proving consistent with their architecture and water stress. However, underestimation or overestimation of FPAR, the major driver of GPP at our measuring site, causes the opposite effects on ϵ_0 . In an attempt to analyse possible $\text{FPAR}_{\text{MODIS}}$ inaccuracies and their influence on ϵ_0 , as pointed out earlier (see section 5.2.4), we used the ground measurements performed at the plot as a support. The procedure followed is described below.

FPAR direct measurements are usually sparse. An alternative is to estimate FPAR on NDVI (Sims et al., 2005). Another commonly used approach is to derive FPAR from direct measurements of LAI using the Lambert-Beer equation:

$$\text{FPAR} = 1 - \exp(-K \cdot \text{LAI}) \quad (5.12)$$

where K is the light extinction coefficient.

As stated earlier, LAI measurements were regularly performed during the GS covering the main phenological stages of rapeseed and rye. In the case of peas, no measurements were conducted, and for wheat the number of measurements was primarily limited to May. These data enable us to perform an inter-comparison exercise between concurrent LAI and $\text{LAI}_{\text{MODIS}}$ products. The results of the linear regression of LAI versus the $\text{LAI}_{\text{MODIS}}$ composites are depicted in Fig.5.5. The black line shows the linear

fit for the three crops, and red, green, and blue symbols identify the individual results for each crop type. A quick look at this Figure allows us to conclude the systematic underestimation of LAI_{MODIS} versus LAI on overall as well as for each individual crop type. Since the intercept of the fit was close to zero, the slope, 1.334, directly accounts for MODIS underestimation. R^2 of the linear fit was moderately satisfactory, 67.6%, the greater deviations being for rye. Based on this finding, the $FPAR_{MODIS}$ composites were re-computed using Eq. 5.12 as follows: 1) The K parameter of $FPAR_{MODIS}$ was fitted using the LAI_{MODIS} composites retrieved in the central pixel. The K parameter estimates yielded 0.686 ± 0.016 ($R^2=86.9\%$), a value in the range of other reported results (Atwell et al., 1999; O'Connell et al., 2004). This approach allows the original $FPAR_{MODIS}$ computed with a robust algorithm to be preserved, deriving the K values by using the Lambert-Beer equation. 2) A new $FPAR$ 8-d temporal series, $FPAR_{RMODIS}$, was re-computed using the product of K parameter estimates by the re-computed LAI_{MODIS} retrievals (LAI_{MODIS} retrievals multiplied by 1.334). Due to limited ground data, no distinction between crops was made. Hence, the new $FPAR_{RMODIS}$ temporal series (see Fig.5.2b) should be considered as a calibration of the MODIS results at the central pixel based on ground LAI observations over the whole period studied. As expected, the re-computed $FPAR_{RMODIS}$ series exhibited a strong correlation with the original temporal series, $R^2=88.2\%$, although it obviously yielded higher values, which were higher by an average factor of 1.23, leading to the subsequent decline in ϵ_{0N} , (values obtained with the LUE model using recomputed $FPAR_{RMODIS}$ derived from LAI ground measurements) $2.597 \pm 0.088 \text{ g C MJ}^{-1}$ ($R^2=83.4\%$). Crop-to-crop re-computed $FPAR_{RMODIS}$ series yielded ϵ_{0N} values of 2.593 ± 0.091 ($R^2=83.0\%$), $2.415 \pm 0.145 \text{ g C MJ}^{-1}$ ($R^2=90.5\%$), $1.993 \pm 0.184 \text{ g C MJ}^{-1}$, ($R^2=72.7\%$), $1.989 \pm 0.112 \text{ g C MJ}^{-1}$ ($R^2=87.7\%$) and $3.050 \pm 0.187 \text{ g C MJ}^{-1}$ ($R^2=85.9\%$) overall, for rapeseed, wheat, peas and rye, respectively. The linear fit of these values versus the canopy height, depicted in Fig.5.6, was statistically significant at 95% significance level, thus indicating the dependence of canopy height and architecture on ϵ_{0N} , the greater the values, the denser and taller the canopies and conversely.




Figure 5.5. Linear fit of ground based LAI versus LAI_{MODIS} 8-d composites. The black line shows the overall linear fit for rapeseed, wheat, and rye. Red, green, and blue symbols show the individual data for each crop type.




Figure 5.6. Linear fit of optimal light use efficiency, ϵ_{0N} , versus canopy height, h . ϵ_{0N} values correspond to those obtained with the LUE model using recomputed FPAR_{RMODIS} input data derived from LAI ground data. Dotted lines are the confidence intervals at 95% significance level.

5.5 Conclusions

We present the most salient results of GPP seasonal evolution observed and modelled for a biofuel crop in the Spanish Plateau, consisting of annual rotation of non-irrigated rapeseed, wheat, peas and rye. The influence of crop architecture, phenology and climatic conditions dominated crop-to-crop seasonal evolution of EF, $\text{FPAR}_{\text{MODIS}}$ and GPP seasonal evolution. Higher GPP were obtained for denser and higher canopy height crops, rapeseed and rye. Both exhibited a marked EF seasonal variation driven by evapotranspiration, higher FPAR peaks and the longer seasonal cycle, lasting around 143 and 135 days, respectively. Rapeseed and rye also yielded high GPP annuals, 1684 and 1409 g C m⁻² almost comparable to C4 plants. Wheat exhibited the lowest annual, 714 g C m⁻² followed by peas 733 g C m⁻². Lower values might partially be attributed to their shorter seasonal cycle, 123 and 104 days, respectively. The influence of drought during 2009 on the Spanish plateau was another expected factor contributing to a drop in the normal annual GPP of wheat.

The LUE model applied to derive GPP provided satisfactory overall ($R^2=86.1\%$) and crop-to-crop, (R^2 ranging from 77.8 to 90.8%) results and a significant improvement in G_{APAR} estimates compared with concurrent MODIS 8-d. ($R^2 =71.7\%$) retrievals. The slope of the linear fit of GPP versus G_{APAR} , namely ϵ_{OLUE} , also varied depending on crop type, with higher values tending to be linked to higher density and canopy height, 2.916 ± 0.182 and 3.954 ± 0.195 g C MJ⁻¹ for rapeseed and rye. ϵ_{OLUE} for peas and wheat yielded intermediate values 2.738 ± 0.171 and 2.859 ± 0.230 g C MJ⁻¹. Underestimating the LUE model in most of April under partially cloudy sky, particularly affecting wheat, was a major reason for the worst results obtained for this crop. This result confirmed the increase in ϵ in the presence of clouds reported in other studies (King et al., 2011; Sims et al., 2005), and hence, the potential importance of considering variability in ϵ_0 in LUE models to improve results compared to those obtained by considering a constant value throughout the year.

Although MODIS captured crop-to-crop $\text{FPAR}_{\text{MODIS}}$ seasonal evolution quite well, it tended to underestimate derived ground based FPAR

by a factor close to 1.2. Indeed, observed underestimation led to the opposite effects on ϵ_0 , in a similar ratio. Using the reprocessed $\text{FPAR}_{\text{MODIS}}$ temporal series, the $\epsilon_{0\text{N}}$ obtained were 2.593 ± 0.091 , 2.415 ± 0.145 , 1.993 ± 0.184 , 1.989 ± 0.112 , 3.050 ± 0.187 g C MJ⁻¹ overall, for rapeseed, wheat, peas and rye, respectively. These new values were linearly related with canopy height. However, even though the linear fit was statistically significant at 95% significance level, the influence of canopy height on $\epsilon_{0\text{N}}$ obtained in this study should be treated with caution given the limited data available, four years. Additional measurements with variable canopies heights would be necessary in order to confirm whether this conclusion is maintained or not.

The less accurate results of $\text{GPP}_{\text{MODIS}}$ have been attributed to differences in the formulation of f_{MODIS} versus f_{LUE} considered in this study. In particular, EF provided a better description of the environmental stress conditions. This conclusion is supported by: a) $\text{GPP}_{\text{MODIS}}$ overestimation in summer, during which EF and SM drop to values as low as 0.1 and <5%, respectively. b) The best linear fits for well-watered crops, rapeseed and peas $R^2=89.8\%$ and $R^2=85.9\%$, and, conversely, the poorer results for wheat, $R^2=55.5\%$ affected by water stress. Despite the less accurate $\text{GPP}_{\text{MODIS}}$ compared to the results obtained with the LUE model, inter-comparison results with GPP evidence the satisfactory potential of MODIS to routinely quantify GPP of crops at our measuring site. Improving current $\text{GPP}_{\text{MODIS}}$ retrievals could likely be achieved by updating the original look-up-table and including crop type discrimination. However, despite this, validation and calibration experiments will continue to be necessary at specific sites due to the significant impact of agricultural management practices, including rotation cycles, on CO₂ photosynthetic uptake.

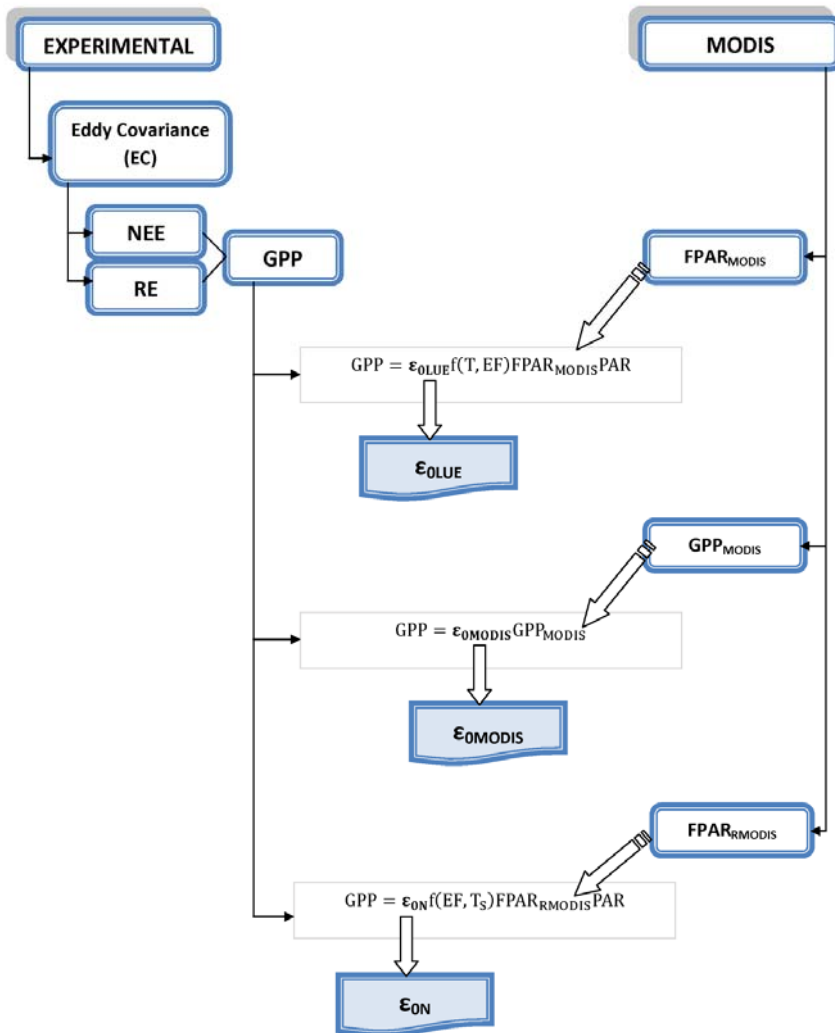


Figure 5.7. Flow chart of the methodology followed when estimating maximum light use efficiency.

CAPÍTULO 6.

CONCLUSIONES

6.1 Conclusiones (español)

A continuación enumeramos los principales resultados y conclusiones obtenidos de este amplio estudio:

1. La fiabilidad de las medidas EC fue evaluada mediante el estudio del cierre en el balance de energía. Hemos obtenido satisfactorios resultados para dicho cierre, alcanzando un valor del 86% ($R^2=0.95$). Este valor aumentó hasta un 92% ($R^2=0.96$) cuando se tuvo en cuenta el término de almacenamiento para el flujo del calor del suelo. Estos resultados indican la buena calidad de los flujos medidos con la instrumentación EC. Al estudiar la evolución estacional en el cierre del balance de energía, los resultados mostraron mejores valores para el cierre, por encima del 90%, desde abril hasta septiembre, incluyendo el MIP. La evolución estacional obtenida para el cierre del balance de energía revela, por tanto, la influencia de las condiciones meteorológicas en las medidas realizadas.
2. Hemos estudiado el reparto de energía por parte del ecosistema en los diferentes procesos biofísicos. Para el periodo global de 4 años, H fue el principal contribuyente, participando con aproximadamente un 52% de la energía disponible, seguido de LE, con un porcentaje del 40%. Sin embargo, cuando el periodo se limitó al MIP, estos papeles se invirtieron, pasando a ser LE el principal término utilizando cerca del 50% de la energía, en detrimento de H, que participó con un 38%. Frente a este comportamiento general, hay que destacar el papel de la colza en comparación al resto de

cultivos estudiados. En este caso, LE desempeñó el papel principal en el reparto de energía independientemente del periodo evaluado, alcanzando valores de hasta un 70% para el MIP.

3. Se ha utilizado el algoritmo SEBS para modelar las largas series temporales de los flujos de energía y EF empleando datos satelitales y la base de datos meteorológica del ECMWF. El análisis comparativo entre los valores de dichas bases de datos y los concurrentes medidos in situ para dos de las principales variables, la temperatura del aire y la temperatura del suelo, han revelado resultados satisfactorios, con pendientes de 0.96 ($R^2=0.98$) y 0.74 ($R^2=0.93$), respectivamente. Para la humedad del suelo la comparación con los datos suministrados por el sensor AMSR-E mostró un coeficiente de determinación menor, 0.52. No obstante, los datos de dicho sensor, a pesar de su amplia resolución espacial, suministraron una evolución estacional similar a la de las medidas in situ. El buen acuerdo obtenido entre las series de datos experimentales y las bases de datos externas utilizadas nos permite concluir que los valores perdidos debidos a fallos en la instrumentación podrían ser rellenados mediante el uso de teledetección o las mencionadas bases de datos meteorológicas.
4. La formulación original del modelo de una fuente SEBS condujo a resultados poco satisfactorios para H, LE y EF, especialmente en verano durante el periodo de barbecho. Para este periodo los valores de LE y EF fueron altamente sobreestimados a la vez que los valores de H fueron subestimados, lo que implica que el

algoritmo original del modelo no se adapta a las condiciones presentes en la zona de estudio.

5. Para solventar la sobreestimación de LE y EF obtenida con la versión original del modelo hemos propuesto y calibrado una nueva versión, SEBS_NDVI, utilizando un factor de escala dependiente del NDVI y de la temperatura del suelo, LST. Esta nueva versión ha mejorado sustancialmente la evolución estacional modelada, en particular para LE y EF, alcanzando coeficientes de determinación de 0.70 y 0.65, respectivamente.
6. Como medio para obtener los valores anuales, tanto del NEE como de la GPP, para cada uno de los años de medida, hemos rellenado satisfactoriamente los huecos inevitables en las largas series temporales de datos medidos con la instrumentación EC. En el primer caso hemos utilizado los resultados del modelo de Michaelis-Menten, ajustado cada 15 días ó 1 mes, durante todo el periodo de estudio. Para la respiración hemos empleado una ecuación de Van't Hoff modificada utilizando los datos nocturnos obtenidos para cada tipo de cultivo, en función de la humedad del suelo y la temperatura del aire.
7. El comportamiento global/neto como sumidero de carbono de cada uno de los cultivos estudiados destaca como una de las principales conclusiones. Los valores acumulados de NEE fueron: -373, -157, -98, -511 g C m⁻², para la colza, el trigo, los guisantes y el centeno, respectivamente. Del mismo modo, los valores acumulados para la GPP fueron: 1684, 714, 733 y 1409 g C m⁻². Las diferencias en los órdenes de magnitud demuestran la influencia del tipo de cultivo y

de las condiciones climáticas dominantes sobre el ciclo global del carbono. En particular, los bajos valores obtenidos para el NEE y la GPP del trigo probablemente se justifican por las condiciones de sequía; la precipitación acumulada durante el MIP fueron sólo 106 mm.

8. Para el periodo global de estudio y para cada uno de los cultivos hemos aplicado un modelo LUE a la GPP que utiliza como parámetros de entrada los datos experimentales de EF, temperatura del aire y PAR, y datos satelitales de FPAR del sensor MODIS. El valor máximo de la eficiencia en el uso de la luz, ϵ_{0LUE} , parámetro clave, ha sido determinado a partir de la pendiente de la regresión lineal entre los valores experimentales de GPP y el producto de los restantes términos, incluyendo el factor de estrés. Todos los ajustes han mostrado resultados satisfactorios, revelando por tanto la bondad del modelo. Este modelo presenta una mejora notable al aplicado en los datos de GPP MODIS, obteniéndose una buena correlación sólo para el caso de buena disponibilidad de agua. La intercomparación entre ambos valores de GPP ($R^2=0.71$) reveló una clara subestimación de los datos de la GPP del MODIS, resultado que hemos atribuido a la formulación de los factores de estrés empleados, diferente a la utilizada en el modelo aplicado en este estudio.
9. Hemos obtenido un valor global de ϵ_{0LUE} para el periodo de estudio de 4 años de $3.331 \text{ g C MJ}^{-1}$. Así mismo, hemos determinado valores característicos de ϵ_{0LUE} para cada uno de los cuatro cultivos estudiados: 2.916, 2.859, 2.738, y $3.954 \text{ g C MJ}^{-1}$, para colza,

trigo, guisantes y centeno, respectivamente, con coeficientes de determinación entre 78 y 91%. Estos resultados revelan la gran variabilidad en la eficiencia dependiendo del tipo de cultivo, de sus respectivas características y de su estructura.

10. Los valores de FPAR procedentes del sensor MODIS subestimaron los datos medidos en superficie, calculados a partir de medidas in situ del LAI. Para solventar este problema, hemos recalibrado las series temporales del MODIS utilizando datos de LAI experimentales. La inclusión de las series temporales de FPAR recalibradas en el modelo LUE condujeron a valores inferiores de ϵ_{0LUE} : 2.593, 2.415, 1.993, 1.989, y 3.050 g C MJ⁻¹, para el conjunto global, la colza, el trigo, los guisantes y el centeno, respectivamente. Los coeficientes de determinación oscilaron entre 73 y 91%.
11. De todo ello se desprende como conclusión final que los resultados del estudio de los flujos de energía y de CO₂ realizados en un cultivo rotante en una parcela agrícola de la meseta castellana han contribuido a conocer mejor los cultivos más representativos de la zona de estudio como son la colza, el trigo, los guisantes, y el centeno. En particular, su comportamiento dentro del ciclo de carbono y su eficiencia en el uso de la luz.

6.2 Conclusions (english)

The following results and conclusions can be drawn from the study presented in this thesis:

1. Reliability in EC measurements was evaluated by means of the energy balance closure. Satisfactory results were found for the closure, and reached a value of 86% ($R^2 = 0.95$). This value increased up to 92% ($R^2=0.96$) when the storage term for the soil heat flux was taken into consideration. These results indicate the good quality of the fluxes measured with the EC instrumentation. When analyzing the seasonal trend for the energy balance closure, the results showed better values for closure, close to 100%, from April to September, including the MIP. The determined seasonal pattern for the energy balance closure therefore revealed the influence of meteorological conditions on measurements.
2. We studied energy partitioning in the various processes involved in the ecosystem. For the period as a whole, H was the main driver, participating with approximately 52% of available energy, followed by LE, with 40%. However, when the period was constrained to the MIP, said roles were inverted, with LE being the main term using over 50% of the energy to the detriment of H, which contributed 38%. Regarding this general behavior, the role played by rapeseed in comparison with the remaining crops studied should be highlighted. In this case, LE played the main role in energy partitioning, regardless of the study period, and reached values up to 71% for the MIP.

3. The SEBS algorithm was used to model the long term series of energy fluxes and EF using remote sensing data and the meteorological database from the ECMWF. The comparative analysis between those databases and their concurrent in situ measurements for two of the main variables, air temperature and soil temperature, revealed satisfactory results with slopes of 0.96 ($R^2=0.98$) and 0.74 ($R^2=0.93$), respectively. For soil moisture, comparison with the data retrieved from the AMSR-E sensor showed a lower determination coefficient, 0.52. However, despite its coarse spatial resolution, data from said sensor provided a similar seasonal pattern to in situ measurements. The good agreement obtained between experimental and external databases allows us to conclude that missing values due to instrumentation failures could be gap filled using remote sensing or the mentioned external meteorological databases.
4. The original formulation for the SEBS one-source model led to unsatisfactory results for H, LE, and EF, particularly in summer during the fallow period. For this period, LE and EF values were highly overestimated while H values were underestimated, implying that the original algorithm does not adapt to the conditions present in the study area.
5. To solve the overestimation obtained for LE and EF with the original version of the model, we proposed and calibrated a new version, SEBS_NDVI, using a scale factor depending on NDVI and land surface temperature, LST. This new version

substantially improved the modeled seasonal pattern, particularly for LE and EF, reaching determination coefficients of 0.70 and 0.65, respectively.

6. As a means of obtaining the annual values for both NEE and GPP for each measured year using EC instrumentation, we satisfactorily gap-filled the inevitable gaps in the long temporal data series. In the NEE case, we used the results of the Michaelis-Menten model, fitted for 15 days or 1 month, throughout the whole of the period studied. For respiration, we employed a modified Van't Hoff equation using the nocturnal data obtained for each crop type, depending on the soil moisture and air temperature.
7. The global/net behavior as carbon sink for each studied crop emerged as one of the main conclusions. Accumulated NEE values were: -373, -157, -98, -511 g C m⁻², for rapeseed, wheat, peas, and rye, respectively. Similarly, accumulated GPP values were: 1684, 714, 733 and 1409 g C m⁻². The differences in their magnitude evidenced the influence of crop type and the prevailing meteorological conditions on the global carbon cycle. In particular, low values for NEE and GPP obtained for wheat could be likely justified by drought conditions, the cumulative rainfall during the MIP being only 106 mm.
8. For the overall study period and for each crop, we applied a LUE model to the GPP, using experimental data of EF, air temperature and PAR, and remote sensing data of FPAR from the sensor MODIS as input parameters. The maximum value for

the light use efficiency, ϵ_{0LUE} , a key parameter, was determined from the slope of the linear regression between the experimental values of GPP and the product of the remaining terms, including the stress factor. All the fits showed satisfactory results, thus revealing the goodness of the model. The model presents a marked improvement on that applied for GPP MODIS data, obtaining a good correlation only for the case of good water availability. Intercomparison between both GPP values ($R^2=0.71$) revealed a clear underestimation for GPP MODIS data, a result we attribute to the formulation of the stress factors employed, which are different to those used in this study.

9. We obtained an overall value of ϵ_{0LUE} for the 4-year study period of $3.331 \text{ g C MJ}^{-1}$. Likewise, we determined characteristic values of ϵ_{0LUE} for each of the four studied crops: 2.916, 2.859, 2.738, and $3.954 \text{ g C MJ}^{-1}$, for rapeseed, wheat, peas, and rye, respectively, with determination coefficients between 78 and 91%. These results revealed the great variability in light efficiency depending on crop type, their respective characteristics, and their structure.
10. FPAR values retrieved from MODIS underestimated in situ measurements, calculated from experimental LAI measurements. To solve this problem, we recalibrated the MODIS time series using experimental LAI values. Including the recalibrated FPAR time series in the LUE model led to lower values of ϵ_{0LUE} : 2.593, 2.415, 1.993, 1.989, and $3.050 \text{ g C MJ}^{-1}$,

for the overall period, rapeseed, wheat, peas, and rye, respectively. The determination coefficients ranged between 73 and 91%.

11. It follows as a final conclusion that the results for the study of the energy and CO₂ fluxes performed in a rotating crop over an agricultural plot of the Castilian plateau have contributed towards a better understanding of the most representative crops in the study area such as rapeseed, wheat, peas, and rye, and in particular, their behavior in the carbon cycle and their light use efficiency.

BIBLIOGRAFÍA

1. Abtew, W. and Melesse, A., 2013. Evaporation and Evapotranspiration. Measurements and Estimations. Springer Science + Business Media. Dordrecht.
2. Adiku, S.G.K., Reichstein, M., Lohila, A., Dinh, N.Q., Aurela, M., Laurila, T., Lueers, J., Tenhunen, J.D., 2006. PIXGRO: A model for simulating the ecosystem CO₂ exchange and growth of spring barley. *Ecol. Model.*, 190 (3-4), pp. 260-276.
3. AEMET → http://www.aemet.es/es/servicio_sclimaticos/datosclimatologicos/valoresclimatologicos?l=2539&k=cle; ftp://ftpdatos.aemet.es
4. Albergel, C., Calvet, J.C., Gibelin, A.L., Lafont, S., Roujean, J.L., Berne, C., Traullé, O., Fritz, N., 2010. Observed and modelled ecosystem respiration and gross primary production of a grassland in Southwestern France. *Biogeosciences*. 7, 1657-1668.
5. Albrizio R. and Steduto P., 2003. Photosynthesis, respiration and conservative carbon use efficiency of four field grown crops. *Agric. For. Meteorol.* 116, 19-36.
6. Akmal, M., Janssens, M.J.J., 2004. Productivity and light use efficiency of perennial ryegrass with contrasting water and nitrogen supplies. *Field Crops Res.* 88, 143-155.
7. Atwell, B.A., Kriedemann, P.E., Turnbull, C., 1999. Plants in action: adaptation in nature and performance in cultivation. Macmillan Education Australia, Melbourne, Australia, 664p.
8. Aubinet, M., Moureaux, C., Bodson, B., Dufranne, D., Heinesch, B., Suleau, M., Vancutsem, F., Vilret, A., 2009. Carbon sequestration by a crop over a 4-year sugar beet/ winter wheat/seed potato/winter wheat rotation cycle. *Agric. For. Meteorol.* 149, 407-418.
9. Aubinet, M., Vesala, T., Papale, D. Eddy Covariance. A Practical Guide to Measurement and Data Analysis. Springer Atmospheric Sciences. Springer Science + Business Media B. V. 2012. ISBN: 978 - 94 - 007 - 2350 - 4. e-ISBN: 978 - 94 - 007 - 2351 - 1.
10. Awal, M.A., Ishak, W., Endan, J., Haniff, M., 2006. Measurements of leaf area index using optical method (LAI-2000) in oil palm plantation. *Agricultural Science*, 29 (1 & 2). pp. 15-24. ISSN 1511-3701.
11. Baldocchi, D., Falge, E., Gu, L., Olson, R., Hollinger, D., Running, S., Anthoni, P., Bernhofer, C., Davis, K., Evans, R., Fuentes, J., Goldenstein, A., Katul, G., Law, B., Lee, X., Malhi, Y., Meyers, T., Munger, W., Oechel, W., Paw U, K.T., Pilegaard, K., Schmid, H.P., Valentini, R., Verma, S., Vesala, T., Wilson, K., Wosfy, S., 2001. FLUXNET: a new tool to study the temporal and spatial variability of ecosystem-scale carbon dioxide, water vapor and energy flux densities. *Bull. Amer. Meteor. Soc.* 82, 2415-2434.
12. Baldocchi, D.D., and Valentini, R., 2004. Geographic and temporal variation of the mechanisms controlling carbon exchange by ecosystems and their sensitivity to environmental perturbations. Chapter 15. In: Field, C. and Raupach, M. (eds.)

- The global carbon cycle: integrating humans, climate, and the natural world/ Towards CO₂ stabilization: Issues, Strategies and consequences. A SCOPE/GCP Rapid Assessment Project. Island Press. Pp 295-315.
13. Baldocchi, D.D., Xu, L., Kiang, N., 2004. How plant functional-type, weather, seasonal drought, and soil physical properties alter water and energy fluxes of an oak-grass savanna and an annual grassland. *Agric. For. Meteorol.* 123, 13-39.
 14. Baldocchi, D., 2008. Turner review no. 15. 'Breathing' of the Terrestrial Biosphere: Lessons Learned from a Global Network of Carbon Dioxide Flux Measurement Systems, *Aust. J. Bot.* 56, 1-26.
 15. Baozhang, C., 2012. Coupled Terrestrial Carbon and Water Dynamics in Terrestrial Ecosystems: Contributions of Remote Sensing. 516pp. Ch 9, In: *Remote Sensing - Applications*, Dr. Boris Escalante (Ed.), ISBN: 978-953-51-0651-7, InTech, DOI: 10.5772/36522. G.
 16. Bastiaanssen, W.G.M, Menenti, M., Feddes, R.A., Holtslag, A.A. M., 1998. A remote sensing surface energy balance algorithm for land (SEBAL) 1. Formulation. *J. Hydrol.* 212-213, 198-212.
 17. Bastiaanssen, W.G.M., 2000. SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. *J. Hydrol.* 229, 87-100.
 18. Barr, A.G., Morgenstern, K., Black, T.A., McCaughey, J.H., Nestic, Z., 2006. Surface energy balance closure by the eddy-covariance method above three boreal forest stands and implications for the measurement of the CO₂ flux. *Agric. For. Meteorol.* 140, 322-337.
 19. Beer C., Reichstein M., Ciais P., Farquhar G.D., Papale D., 2007. Mean annual GPP of Europe derived from its water balance. *Geophys. Res. Lett.* 34.
 20. Beer, C., Reichstein, M., Tomelleri, E., Ciais, P., Jung, M., Carvalhais, N., Rödenbeck, C., Arain, M.A., Baldocchi, D., Bonan, G.B., Bondeau, A., Cescatti, A., Lasslop, G., Lindroth, A., Lomas, M., Luysaert, S., Margolis, H., Oleson, K.W., Rouspard, O., Veenendaal, E., Viovy, N., Williams, C., Woodward, F. I., Papale, D., 2010. Terrestrial gross carbon dioxide uptake: global distribution and covariation with climate. *Science.* 329, 834-838, doi:10.1126/science.1184984.
 21. Berberoglu, S., Evrendilek, F., Ozkan, C., Donmez, C., 2007. Modeling forest productivity using envisat MERIS data. *Sensors*, vol. 7, no. 10, pp. 2115-2127.
 22. Berbigier, P., Bonnefond, J.M., Mellmann, P., 2001. CO₂ and water vapour fluxes for 2 years above Euroflux forest site. *Agric. For. Meteorol.* 108, 183-197.
 23. Béziat, P., Ceschia, E., Dedieu, G., 2009. Carbon balance of a three crop succession over two cropland sites in South West France. *Agric. For. Meteorol.* 149, 1628-1645.

24. Bhattacharyya, P., Neogi, S., Roy, K.S., Dash, P.K., Nayak, A.K., Mohapatra, T., 2014. Tropical low land rice ecosystem is a net carbon sink. *Agric. Ecosyst. Environ.* 189, 127-135.
25. Bi, X., Gao, Z., Deng, X., Wu, D., Liang, J., Zhang, H., Sparrow, M., Du, J., Li, F., Tan, H., 2007. Seasonal and diurnal variations in moisture, heat, and CO₂ fluxes over grassland in the tropical monsoon region of southern China. *J. Geophys. Res. D: Atmos.* 112, D10106.
26. Bradford J.B., Hicke J.A., Lauenroth W.K., 2005. The relative importance of light-use efficiency modifications from environmental conditions and cultivation for estimation of large-scale net primary productivity. *Remote Sens. Environ.* 96, 246-255.
27. Burba, G. and Anderson, D. A Brief Practical Guide to Eddy Covariance Flux Measurements. Principles and Workflow Examples for Scientific and Industrial Applications. Version 1.0.1. 2005–2010 Li-Cor Inc.
28. Cava, D., Contini, D., Donato, A., Martano, P., 2008. Analysis of short-term closure of the surface energy balance above short vegetation. *Agric. For. Meteorol.* 148, 82–93.
29. Chakraborty, A., Sai, M.S., Murthya, C.S., Roy, P.S., Behera, G., 2012. Assessment of area favourable for crop sowing using AMSR-E derived Soil Moisture Index (AMSR-E SMI). *Int. J. Appl. Earth Obs. Geoinf.* 18, 537–547.
30. Chapin, F.S., III, Matson, P.A., Mooney, H.A., 2002. *Principles of terrestrial ecosystem ecology.* Springer-Verlag, New York., 436 p., ISBN: 0-387-95439-2.
31. Chen, S., Chen, J., Lin, G., Zhang, W., Miao, H., Wei, L., Huang, J., Han, X., 2009. Energy balance and partition in Inner Mongolia steppe ecosystems with different land use types. *Agric. For. Meteorol.* 149, 1800-1809.
32. Chen, T., van der Werf, G.R., Dolman, A.J., Groenendijk, M., 2011. Evaluation of cropland maximum light use efficiency using eddy flux measurements in North America and Europe. *Geophys. Res. Lett.* 38, L14707, doi:10.1029/2011GL047533.
33. Chen, G., Tian, H., Huang, C., Prior, S.A., Pan, S., 2013. Integrating a process-based ecosystem model with Landsat imagery to assess impacts of forest disturbance on terrestrial carbon dynamics: Case studies in Alabama and Mississippi. *J. Geophys. Res.: Biogeosci.* 118, 3, 1208-1224.
34. Chen T., Van Der Werf G.R., Gobron N., Moors E.J., Dolman A.J., 2014. Global cropland monthly gross primary production in the year 2000. *Biogeosciences.* 11, 3871-3880.
35. Clothier, B.E., Clawson, K.L., Pinter Jr., P.J., Moran, M.S., Reginato, R.J., Jackson, R.D., 1986. Estimation of soil heat flux from net radiation during the growth of alfalfa. *Agric. For. Meteorol.* 37, 319-329.

36. Cook, B.D., Davis, K.J., Wang, W., Desai, A., Berger, B.W., Teclaw, R.M., Martin, J.G., Bolstad, P.V., Bakwin, P.S., Yi, C., Heilman, W., 2004. Carbon exchange and venting anomalies in an upland deciduous forest in northern Wisconsin, USA. *Agric. For. Meteorol.* 126, 271-295.
37. Coops N.C., Black T.A., Jassal R.(.)S., Trofymow J.A.(.), Morgenstern K., 2007. Comparison of MODIS, eddy covariance determined and physiologically modelled gross primary production (GPP) in a Douglas-fir forest stand. *Remote Sens. Environ.* 107, 385-401.
38. Crawford E., 1997. Arrhenius' 1896 model of the greenhouse effect in context. *Ambio.* 26, 6-11.
39. Dufranne, D., Moureaux, C., Vancutsem, F., Bodson, B., Aubinet, M., 2011. Comparison of carbon fluxes, growth and productivity of a winter wheat crop in three contrasting growing seasons. *Agric. Ecosyst. Environ.* 141, 133-142.
40. Duursma, R.A., Medlyn, B.E., 2012. MAESPA: A model to study interactions between water limitation, environmental drivers and vegetation function at tree and stand levels, with an example application to [CO₂] × drought interactions. *Geoscientific Model Development*, 5 (4), pp. 919-940.
41. Elhag, M., Psilovikos, A., Manakos, I., Perakis, K., 2011. Application of the Sebs water balance model in estimating daily evapotranspiration and evaporative fraction from remote sensing data over the Nile Delta. *Water Resour. Manage.* 25, 2731-2742.
42. Ershadi, A., McCabe, M.F., Evans, J.P., Walker, J.P., 2013. Effects of spatial aggregation on the multi-scale estimation of evapotranspiration. *Remote Sens. Environ.* 131, 51-62.
43. Evett, S.R., Prueger, J.H., Tolck, J.A., 2012. Water and Energy Balances in the Soil-Plant-Atmosphere Continuum, in: Huang, P. M., Li, Y., Summer, M. E. (Eds.). *Handbook of Soil Sciences. Properties and processes.* 2nd edition. Taylor and Francis Group, LLC. CRC Press, Boca Ratón, Chapter 6.
44. Falge E., Baldocchi D., Tenhunen J., Aubinet M., Bakwin P., Berbigier P., Bernhofer C., Burba G., Clement R., Davis K.J., Elbers, J.A., Goldstein, A.H., Grelle, A., Granier, A., Gumundsson, J., Hollinger, D., Kowalski, A.S., Katul, G., Law, B.E., Malhi, Y., Meyers, T., Monson, R.K., Munger, J.W., Oechel, W., Paw U, K.T., Pilegaard, K., Rannik, U., Rebmann, C., Suyker, A., Valentini, R., Wilson, K., Wofsy, S., 2002. Seasonality of ecosystem respiration and gross primary production as derived from FLUXNET measurements. *Agric. For. Meteorol.* 113, 53-74.
45. Falkowski P., Scholes R.J., Boyle E., Canadell J., Canfield D., Elser J., Gruber N., Hibbard K., Hogberg P., Linder S., Mackenzie, F.T., Moore III, B., Pedersen, T., Rosental, Y., Seitzinger, S., Smetacek, V., Steffen, W., 2000. The global carbon cycle: A test of our knowledge of earth as a system. *Science.* 290, 291-296.

46. Falloon P. and Betts R., 2010. Climate impacts on European agriculture and water management in the context of adaptation and mitigation-The importance of an integrated approach. *Sci. Total Environ.* 408, 5667-5687.
47. Farquhar, G.D., von Caemmerer, S., Berry, J.A., 1980. A biochemical model of photosynthetic CO₂ assimilation in leaves of C3 species. *Planta.* 149, 1, 78-90.
48. Fensholt, R., Sandholt, I., Rasmussen, M.S., Stisen, S., Diouf, A., 2006. Evaluation of satellite based primary production modelling in the semi-arid Sahel. *Remote Sens. Environ.* 105, 173-188.
49. Figueroa Clemente, Manuel Enrique (Coordinador), Redondo Gomez, Susana (Coordinador), Miquel Suárez Inclán, Luis (Colaborador), Miquel Mena, D. (Colaborador), Teresa, Arenillas (Colaborador): *Los Sumideros Naturales de CO₂*. Universidad de Sevilla. 2007. ISBN 978-84-472-0956-9. 218 p.
50. Foken, T., 2008. The energy balance closure problem: An overview. *Ecol. Appl.* 18, 1351-1367.
51. Font Tullot, I., 1983. *Climatología de España y Portugal*. Sección de publicaciones del Instituto Nacional de Meteorología. Madrid. ISBN: 84-500-9467-4.
52. Frolking S.E., Bubier J.L., Moore T.R., Ball T., Bellisario L.M., Bhardwaj A., Carroll P., Crill P.M., Lafleur P.M., McCaughey J.H., Roulet, N.T., Suyker, A.E., Verma, S.B., Waddington, J.M., Whiting, G.J., 1998. Relationship between ecosystem productivity and photosynthetically active radiation for northern peatlands. *Glob. Biogeochem. Cycle.* 12, 115-126.
53. García, R., Kanemasu, E.T., Blad, B.L., Hatfield, J.L., Major, D.J., Reginato, R.J., Hubbard, K.G., 1988. Interception and use efficiency of light in winter wheat under different nitrogen regimes. *Agric. For. Meteorol.* 44, 175-186.
54. Gebremichael, M. and Barros, A.P., 2006. Evaluation of MODIS. Gross primary productivity (GPP) in tropical monsoon regions. *Remote Sens. Environ.* 100, 150-166.
55. Gentine, P., Entekhabi, D., Chehbouni, A., Boulet, G., Duchemin, B., 2007. Analysis of evaporative fraction diurnal behaviour. *Agric. For. Meteorol.* 143, 13-29.
56. Gibson, L.A., Münch, Z., Engelbrecht, J., 2011. Particular uncertainties encountered in using a pre-packaged SEBS model to derive evapotranspiration in a heterogeneous study area in South Africa. *Hydrol. Earth Syst. Sci.* 15, 295-310.
57. Gilmanov, T.G., Soussana, J.F., Aires, L., Allard, V., Ammann, C., Balzarolo, M., Barcza, Z., Bernhofer, C., Campbell, C.L., Cernusca, A., Cescatti, A., Clifton-Brown, J., Dirks, B.O.M., Dore, S., Eugster, W., Fuhrer, J., Gimeno, C., Gruenwald, T., Haszpra, L., Hensen, A., Ibrom, A., Jacobs, A.F.G., Jones, M.B., Lanigan, G., Laurila, T., Lohila, A., G.Manca, Marcolla, B., Nagy, Z., Pilegaard, K., Pinter, K., Pio, C., Raschi, A., Rogiers, N., Sanz,

- M.J., Stefani, P., Sutton, M., Tuba, Z., Valentini, R., Williams, M.L., Wohlfahrt, G., 2007. Partitioning European grassland net ecosystem CO₂ exchange into gross primary productivity and ecosystem respiration using light response function analysis. *Agric. Ecosyst. Environ.* 121, 93-120.
58. Gilmanov, T.G., Wylie, B.K., Tieszen, L.L., Meyers, T.P., Baron, V.S., Bernacchi, C.J., Billesbach, D.P., Burba, G.G., Fischer, M.L., Glenn, A.J., Hanan, N.P., Hatfield, J.L., Heuer, M.W., Hollinger, S.E., Howard, D.M., Matamala, R., Prueger, J.H., Tenuta, M., Young, D.G., 2013. CO₂ uptake and ecophysiological parameters of the grain crops of midcontinent North America: Estimates from flux tower measurements. *Agric. Ecosyst. Environ.* 164, 162-175.
59. Gitelson, A.A., Viña, A., Verma, S.B., Rundquist, D.C., Arkebauer, T.J., Keydan, G., Leavitt, B., Ciganda, V., Burba, G.G., Suyker, A.E., 2006. Relationship between gross primary production and chlorophyll content in crops: Implications for the synoptic monitoring of vegetation productivity. *J. Geophys. Res.: Atmos.* 111, 8.
60. Giunta, F., Pruneddu, G., Motzo, R., 2009. Radiation interception and biomass and nitrogen accumulation in different cereal and grain legume species. *Field Crops Res.* 110, 76-84.
61. Goerner A., Reichstein M., Tomelleri E., Hanan N., Rambal S., Papale D., Dragoni D., Schmulius C., 2011. Remote sensing of ecosystem light use efficiency with MODIS-based PRI. *Biogeosciences.* 8, 189-202.
62. Gökmen, M., Vekerdy, Z., Verhoef, A., Verhoef, W., Batelaan, O., Van der Tol, C., 2012. Integration of soil moisture in SEBS for improving evapotranspiration estimation under water stress conditions. *Remote Sens. Environ.* 121, 261-274.
63. Gonzalez-Dugo, M.P., Neale, C.M.U., Mateos, L., Kustas, W.P., Prueger, J.H., Anderson, M.C., Li, F., 2009. A comparison of operational remote sensing-based models for estimating crop evapotranspiration. *Agric. For. Meteorol.* 149, 1843-1853.
64. Govind A., Cowling S., Kumari J., Rajan N., Al-Yaari A., 2015. Distributed modeling of ecohydrological processes at high spatial resolution over a landscape having patches of managed forest stands and crop fields in SW Europe. *Ecol. Model.* 297, 126-140.
65. Grierson, W., 2001. Role of temperature in the physiology of crop plants: Pre- and Postharvest. Chapter 2. In: *Handbook of plant and crop physiology*, edited by Mohammad Pessarakli. Marcel Dekker Inc. New York. 973p
66. Gruhier, C., de Rosnay, P., Kerr, Y., Mougin, E., Ceschia, E., Calvet, J.-C., Richaume, P., 2008. Evaluation of AMSR-E soil moisture product based on ground measurements over temperate and semi-arid regions. *Geophys. Res. Lett.* 35, 10, L10405, doi: 10.1029/2008GL033330.

67. Guy, S.O., Wysocki, D.J., Schillinger, W.F., Chastain, T.G., Karow, R.S., Garland-Campbell, K., Burke, I.C., 2014. Camelina: Adaptation and performance of genotypes. *Field Crop Res.* 155, 224-232.
68. Hammerle, A., Haslwanter, A., Schmitt, M., Bahn, M., Tappeiner, U., Cernusca, A., Wohlfahrt, G., 2007. Eddy covariance measurements of carbon dioxide, latent and sensible energy fluxes above a meadow on a mountain slope. *Boundary-Layer Meteorol.* 122, 397-416.
69. Hashimoto, H., Wang, W., Milesi, C., White, M.A., Ganguly, S., Gamo, M., Hirata, R., Myneni, R.B., Nemani, R.R., 2012. Exploring Simple Algorithms for Estimating Gross Primary Production in Forested Areas from Satellite Data. *Remote Sens.* 4, 303-326.
70. Haslwanter, A., Hammerle, A., Wohlfahrt, G., 2009. Open-path vs. closed-path eddy covariance measurements of the net ecosystem carbon dioxide and water vapour exchange: A long-term perspective. *Agric. For. Meteorol.* 149, 291-302.
71. Hauggaard-Nielsen, H., Johansen, A., Carter, M.S., Ambus, P., Jensen, E.S., 2012. Strip cropping of alternating perennial grass-clover and annual rye-vetch intercrops when grown within an organic farming system. *Field Crop Res.* 136, 1-11.
72. Heinsch F.A., Zhao M., Running S.W., Kimball J.S., Nemani R.R., Davis K.J., Bolstad P.V., Cook B.D., Desai A.R., Ricciuto D.M., Law, B.E., Oechel, W.C., Kwon, H., Luo, H.Y., Wofsy, S.C., Dunn, A.L., Munger, J.W., Baldocchi, D.D., Xu, L.K., Hollinger, D.Y., Richardson, A.D., Stoy, P.C., Siqueira, M.B.S., Monson, R.K., Burns, S.P., Flanagan, L.B., 2006. Evaluation of remote sensing based terrestrial productivity from MODIS using regional tower eddy flux network observations. *IEEE Trans. Geosci. Remote Sens.* 44, 1908-1923.
73. Hernandez-Ramirez, G., Hatfield, J.L., Prueger, J.H., Sauer, T.J., 2010. Energy balance and turbulent flux partitioning in a corn-soybean rotation in the Midwestern US. *Theor. Appl. Climatol.* 100, 79-92.
74. Heusinkveld, B.G., Jacobs, A.F.G., Holtslag, A.A.M., Berkowicz, S.M., 2004. Surface energy balance closure in an arid region: Role of soil heat flux. *Agric. For. Meteorol.* 122, 21-37.
75. Hollinger, S.E., Bernacchi, C.J., Meyers, T.P., 2005. Carbon budget of mature no-till ecosystem in North Central Region of the United States. *Agric. For. Meteorol.* 130, 59-69.
76. Houghton, R.A., 1999. The annual net flux of carbon to the atmosphere from change land in land use 1850-1990. *Tellus.* 51B, 298-313.
77. Houghton, R.A., 2007. Balancing the global carbon budget. *Ann. Rev. Earth Planet. Sci.* 35, 313-347.
78. Hua, W., Fan, G., Zhou, D., Ni, C., Li, X., Wang, Y., Liu, Y., Huang, X., 2008. Preliminary analysis on the relationships between Tibetan Plateau NDVI change and its surface heat

- source and precipitation of China. *Sci. China Ser. D-Earth Sci.* 51, 5, 677–685.
79. Huang, K., Wang, S., Zhou, L., Wang, H., Zhang, J., Yan, J., Zhao, L., Wang, Y., Shi, P., 2014. Impacts of diffuse radiation on light use efficiency across terrestrial ecosystems based on eddy covariance observation in China. *PLoS ONE*. 9.
80. Hydrology Handbook. 2nd edition. 1996. *Manuals and Reports on Engineering Practice*, American Society of Civil Engineers, pp. 1–784. Nº 28. Chapter 4.
81. IDECYL.
<http://www.idecyl.jcyl.es/hac/6/VCIG/Login.ini>
82. INE, 2015:
<http://www.ine.es/jaxi/tabla.do?type=pcaxis&path=%2Ft43%2Fa011%2Fa1998%2Fdensidad%2Fa2008%2Ff0%2F&file=t10031.px>
83. IPCC, 2007. *Climate Change, 2007: The Sciences Basis*. Intergovernmental Panel of Climate Change, 18 pp, Cambridge University Press, UK.
84. IPCC, 2013. *Climate Change 2013: The Physical Sciences Basis*. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1535 pp.
85. Jaksic, V., Kiely, G., Albertson, J., Oren, R., Katul, G., Leahy, P., Byrne, K.A., 2006. Net ecosystem exchange of grassland in contrasting wet and dry years. *Agric. For. Meteorol.* 139, 323–334.
86. JCYL
http://www.estadistica.jcyl.es/web/jcyl/Estadistica/es/Plantilla100/1284180021365/_/_/_
87. Jia, L., Su, Z., Van den Hurk, B., Menenti, M., Moene, A., De Bruin, H., Baselga, J., Ibañez, M., Cuesta, A., 2003. Estimation of sensible heat flux using the surface energy balance system (SEBS) and ATSR measurements. *Phys. Chem. Earth.* 28, 75–88.
88. Jianlin, W., Guirui, Y., Quanxiao, F., Defeng, J., Hua, Q., Qiufeng, W., 2008. Responses of water use efficiency of 9 plant species to light and CO₂ and their modeling. *Acta Ecologica Sinica.* 28, 525–533.
89. Jimenez Ballesta, R. and Ibañez Marti, J.J., 1993. Iron Oxides in Soils on Plio-quaternary Surfaces. In: *Symposium sobre la Raña en España y Portugal*. Edited by A. Pinilla. Consejo Superior de Investigaciones Científicas (CSIC).
90. Jin, X., Wan, L., Su, Z., 2005. Research on evaporation of Taiyuan basin area by using remote sensing. *Hydrol. Earth Syst. Sci. Discuss.* 2, 209–227.
91. Ju, W., Wang, S., Yu, G., Zhou, Y., Wang, H., 2010. Modeling the impact of drought on canopy carbon and water fluxes for a subtropical evergreen coniferous plantation in southern China through parameter optimization using an ensemble Kalman filter. *Biogeosciences*, 7 (3), pp. 845–857.

92. Jung, M., Reichstein, M., Margolis, H.A., Cescatti, A., Richardson, A.D., Arain, M.A., Arneth, A., Bernhofer, C., Bonal, D., Chen, J., Gianelle, D., Gobron, N., Kiely, G., Kutsch, W., Lasslop, G., Law, B.E., Lindroth, A., Merbold, L., Montagnani, L., Moors, E.J., Papale, D., Sottocornola, M., Vaccari, F. & Williams, C., 2011 Global patterns of land-atmosphere fluxes of carbon dioxide, latent heat, and sensible heat derived from eddy covariance, satellite, and meteorological observations. *J. Geophys. Res.: Biogeosci.* 116, 3.
93. Justes, E., Denoroy, P., Gabrielle, B., Gosse, G., 2000. Effect of crop nitrogen status and temperature on the radiation use efficiency of winter oilseed rape. *Eur. J. Agron.* 13, 165–177.
94. Kalma, J.D., McVicar, T.R., McCabe, M.F., 2008. Estimating land surface evaporation: A review of methods using remotely sensed surface temperature data. *Surv. Geophys.* 29, 421–469.
95. Kemanian, A.R., Stöckle, C.O., Huggins, D.R., 2004. Variability of Barley Radiation-Use Efficiency. *Crop Sci.* 44, 1662–1672.
96. Kidston, J., Brümmer, C., Black, T.A., Morgenstern, K., Nasic, Z., McCaughey, J.H., Barr, A.G., 2010. Energy balance closure using eddy covariance above two different land surfaces and implications for CO₂ flux measurements. *Boundary-Layer Meteorol.* 136, 193–218.
97. King, D.A., Turner, D.P., Ritts, W.D., 2011. Parameterization of a diagnostic carbon cycle model for continental scale application. *Remote Sens. Environ.* 115, 1653–1664.
98. Kirschbaum, M.U.F., 2004. Direct and indirect climate change effects on photosynthesis and transpiration. *Plant Biology.* 6, 242–253.
99. Kirschbaum, M., Eamus, D., Gifford, R., Roxburgh, S.H., Sands, P., 2001. Definitions of some ecological terms used in carbon accounting. *Proceedings of the Net Ecosystem Exchange CRC Workshop* (eds M.U.F.Kirschbaum and R. Mueller), April 18–21, 2–5. CRC for Greenhouse Accounting, Canberra, Australia.
100. Koizumi, H., Usami, Y., Satoh, M., 1990. Annual net primary production and efficiency of solar-energy utilization in 3 double-cropping agroecosystems in Japan, *Agr. Ecosyst. Environ.* 32, 241–255.
101. Kremer, C., Stöckle, C.O., Kemanian, A.R., Howell, T., 2008. A Canopy Transpiration and Photosynthesis Model for Evaluating Simple Crop Productivity Models. Chapter 6 In *Response of Crops to Limited Water: Understanding and Modeling Water Stress Effects on Plant Growth Processes 2008*. p. 165–189. Editors: Ahuja, L.R., Reddy, V.R., Saseendran, S.A., Yu, Qiang.
102. Kustas, W.P., Daughtry, C.S.T., Van Oevelen, P. J., 1993. Analytical treatment of the relationships between soil heat flux/net radiation ratio and vegetation indices. *Remote Sens. Environ.* 46, 319–330.

103. Kustas, W.P., Humes, K.S., Norman, J.M., Moran, M.S., 1996. Single- and Dual-Source Modelling of Surface Energy Fluxes with Radiometric Surface Temperature. *J. Appl. Meteorol.* 35, 110-121.
104. Kustas, W.P., Prueger, J.H., Hatfield, J.L., Ramalingam, K., Hipps, L. E., 2000. Variability in soil heat flux from a mesquite dune site. *Agric. For. Meteorol.* 103, 249-264.
105. Lafont, S., Kergoat, L., Dedieu, G., Chevillard, A., Karstens, U., Kolle, O., 2002. Spatial and temporal variability of land CO₂ fluxes estimated with remote sensing and analysis data over western Eurasia. *Tellus.* 54B. 820-833.
106. Le Quéré, C., Peters, G.P., Andres, R.J., Andrew, R.M., Boden, T.A., Ciais, P., Friedlingstein, P., Houghton, R.A., Marland, G., Moriarty, R., Sitch, S., Tans, P., Arneeth, A., Arvanitis, A., Bakker, D.C.E., Bopp, L., Canadell, J.G., Chini, L.P., Doney, S.C., Harper, A., Harris, I., House, J.I., Jain, A.K., Jones, S.D., Kato, E., Keeling, R.F., Klein Goldewijk, K., Körtzinger, A., Koven, C., Lefèvre, N., Maignan, F., Omar, A., Ono, T., Park, G.-H., Pfeil, B., Poulter, B., Raupach, M.R., Regnier, P., Rödenbeck, C., Saito, S., Schwinger, J., Segschneider, J., Stocker, B.D., Takahashi, T., Tilbrook, B., van Heuven, S., Viovy, N., Wanninkhof, R., Wiltshire, A., Zaehle, S., 2014. Global carbon budget 2013. *Earth System Science Data.* 6, 235-263.
107. Lecoœur, J. and Ney, B., 2003. Change with time in potential radiation-use efficiency in field pea. *Eur. J. Agron.* 19, 91-105.
108. Lee, D., Kim, J., Lee, K.-., Kim, S., 2010. Partitioning of catchment water budget and its implications for ecosystem carbon exchange. *Biogeosciences.* 7, 1903-1914.
109. Lei, H.M. and Yang, D.W., 2010a. Seasonal and interannual variations in carbon dioxide exchange over a cropland in the North China Plain. *Global Change Biol.* 16, 2944-2957.
110. Lei, H. and Yang, D., 2010b. Interannual and seasonal variability in evapotranspiration and energy partitioning over an irrigated cropland in the North China plain. *Agric. For. Meteorol.* 150, 581-589.
111. Leuning, R., Cleugh, H.A., Zegelin, S.J., Hughes, D., 2005. Carbon and water fluxes over a temperate eucalyptus forest and a tropical wet/dry savannah in Australia: measurements and comparison with MODIS remote sensing estimates. *Agric. For. Meteorol.* 129, 151-173.
112. Lenz, K.E., Host, G.E., Roskoski, K., Noormets, A., Söber, A., Karnosky, D.F., 2010. Analysis of a Farquhar-von Caemmerer-Berry leaf-level photosynthetic rate model for *Populus tremuloides* in the context of modeling and measurement limitations. *Environ. Pollut.* 158 (4), 1015-1022.
113. Li, Z., Yu, G., Xiao, X., Li, Y., Zhao, X., Ren, C., Zhang, L., Fu, Y., 2007. Modeling gross primary production of alpine ecosystems in the Tibetan Plateau using MODIS images and climate data. *Remote Sens. Environ.* 107, 510-519.

114. Li, Z.-L., Tang, R., Wan, Z., Bi, Y., Zhou, C., Tang, B., Yan, G., Zhang, X., 2009. A review of current methodologies for regional evapotranspiration estimation from remotely sensed data. *Sensors*. 9, 3801–3853.
115. Lindroth, A., Mölder, M., Lagergren, F., 2010. Heat storage in forest biomass improves energy balance closure. *Biogeosciences*. 7, 301–313.
116. Liu, H., Tu, G., Fu, C., Shi, L., 2008. Three-year variations of water, energy and CO₂ fluxes of cropland and degraded grassland surfaces in a semi-arid area of Northeastern China. *Adv. Atmos. Sci.* 25, 1009–1020.
117. Lobell, D.B., Hicke, J.A., Asner, G.P., Field, C.B., Tucker, C.J., Los, S.O., 2002. Satellite estimates of productivity and light use efficiency in United States agriculture, 1982–98. *Global Change Biol.* 8, 722–735.
118. Lu, J., Li, Z., Tang, R., Tang, B., Wu, H., Yang, F., Labed, J., Zhou, G., 2013. Evaluating the SEBS-estimated evaporative fraction from MODIS data for a complex underlying surface. *Hydrol. Processes*. 27, 3139–3149.
119. Lucht, W., Schaaf, C.B., Strahler, A.H., 2000. An algorithm for the retrieval of albedo from space using semiempirical BRDF models. *IEEE Trans. Geosci. Remote Sens.* 38, 977–998.
120. Ma, W., Hafeez, M., Rabbani, U., Ishikawa, H., Ma, Y., 2012. Retrieved actual ET using SEBS model from Landsat-5 TM data for irrigation area of Australia. *Atmos. Environ.* 59, 408–414.
121. MAGRAMA, 2009. Anuario de Estadística. 2009. Ministerio de Agricultura, Alimentación y Medio Ambiente. <http://www.magrama.gob.es/es/estadistica/temas/publicaciones/anuario-de-estadistica/2009/default.aspx>
122. MAGRAMA, 2012. Anuario de Estadística. 2012. Ministerio de Agricultura, Alimentación y Medio Ambiente. <http://www.magrama.gob.es/es/estadistica/temas/publicaciones/anuario-de-estadistica/2012/default.aspx>
123. MAGRAMA, 2013. Anuario de Estadística 2012. Gobierno de España. Ministerio de Agricultura, Alimentación y Medio Ambiente - Spanish Ministry of Agriculture, Food, and Environment - . Madrid, Spain.
124. Mauder, M. and Foken, T., 2004. Documentation and instruction manual of the eddy covariance software package TK2. Universität Bayreuth, Abt. Mikrometeorologie, Print, ISSN 1614-8916. *Arbeitsergebnisse*, 26, 45 pp.
125. McCallum, I., Wagner, W., Schmullius, C., Shvidenko, A., Obersteiner, M., Fritz, S., Nilsson, S., 2009. Satellite-based terrestrial production efficiency modeling. *Carbon Balance Manag.* 4, 8.
126. McCaughey, J.H., 1985. Energy balance storage terms in a mature mixed forest at Petawawa, Ontario - A case study. *Boundary-Layer Meteorol.* 31, 89–101.

127. Medrano, H., Escalona, J.M., Bota, J., Gulías, J., Flexas, J., 2002. Regulation of photosynthesis of C3 plants in response to progressive drought: Stomatal conductance as a reference parameter. *Ann. Bot.* 89, 895-905.
128. Meyers, T.P. and Hollinger, S.E., 2004. An assessment of storage terms in the surface energy balance of maize and soybean. *Agric. For. Meteorol.* 125, 105-115.
129. Migliavacca, M., Meroni, M., Busetto, L., Colombo, R., Zenone, T., Matteucci, G., Manca, G., Seufert, G., 2009. Modeling gross primary production of agro-forestry ecosystems by assimilation of satellite-derived information in a process-based model. *Sensors*, 9 (2), 922-942.
130. Mo, X., Liu, S., Lin, Z., 2012. Evaluation of an ecosystem model for a wheat-maize double cropping system over the North China Plain. *Environ. Modell. Softw.* 32, 61-73.
131. Moncrieff, J., Valentini, R., Greco, S., Seufert, G., Ciccioli, P., 1997. Trace gas exchange over terrestrial ecosystems: Methods and perspectives in micrometeorology. *J. Exp. Bot.* 48, 1133-1142.
132. Monteith, J. L., 1972. Solar radiation and productivity in tropical ecosystems. *J. Appl. Ecol.* 9, 747-766.
133. Morales, P., Sykes, M.T., Prentice, I.C., Smith, P., Smith, B., Bugmann, H., Zierl, B., Friedlingstein, P., Viovy, N., Sabaté, S., Sánchez, A., Pla, E., Gracia, C.A., Sitch, S., Arneth, A., Ogee, J., 2005. Comparing and evaluating process-based ecosystem model predictions of carbon and water fluxes in major European forest biomes. *Global Change Biol.* 11, 2211-2233.
134. Moureaux, C., Debacq, A., Hoyaux, J., Suleau, M., Tourneur, D., Vancutsem, F., Bodson, B., Aubinet, M., 2008. Carbon balance assessment of a Belgian winter wheat crop (*Triticum aestivum* L.). *Glob. Chang. Biol.* 14, 1353-1366.
135. Mudge, P.L., Wallace, D.F., Rutledge, S., Campbell, D.I., Schipper, L.A., Hosking, C.L., 2011. Carbon balance of an intensively grazed temperate pasture in two climatically: Contrasting years. *Agric. Ecosyst. Environ.* 144, 271-280.
136. Muurinen, S. and Peltonen-Sainio, P., 2006. Radiation-use efficiency of modern and old spring cereal cultivars and its response to nitrogen in northern growing conditions. *Field Crops Res.* 96, 363-373
137. Niu, S., Yuan, Z., Zhang, Y., Liu, W., Zhang, L., Huang, J., Wan, S., 2005. Photosynthetic responses of C3 and C4 species to seasonal water variability and competition. *J. Exp. Bot.* 56, 2867-2876.
138. Norman, J.M., Kustas, W.P., Humes, K.S., 1995. Source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature. *Agric. For. Meteorol.* 77, 263-293.

139. O'Connell, M.G., O'Leary, G.J., Whitfield, D.M., Connor, D.J., 2004. Interception of photosynthetically active radiation and radiation-use efficiency of wheat, field pea and mustard in a semi-arid environment. *Field Crops Res.* 85, 111–124.
140. Ochsner, T.E., Sauer, T.J., Horton, R., 2006. Field tests of the soil heat flux plate method and some alternatives. *Agron. J.* 98, 1005-1014.
141. Ogawa, K. and Schmugge, T., 2004. Mapping surface broadband emissivity of the Sahara Desert using ASTER and MODIS data. *Earth Interact.* 8 (7), 1–14.
142. Olesen J.E. and Bindi M., 2002. Consequences of climate change for European agricultural productivity, land use and policy. *Eur. J. Agron.* 16, 239-262.
143. Oliphant, A.J., Grimmond, C.S.B., Zutter, H.N., Schmid, H.P., Su, H.-B., Scott, S.L., Offerle, B., Randolph, J.C., Ehman, J., 2004. Heat storage and energy balance fluxes for a temperate deciduous forest. *Agric. For. Meteorol.* 126, 185-201.
144. Pallardy, S.G. 2008. Chapter 12: Transpiration and plant water balance. In: *Physiology of woody plants*. Academic Press, Elsevier Inc. San Diego.
145. Papale, D., Reichstein, M., Aubinet, M., Canfora, E., Bernhofer, C., Kutsch, W., Longdoz, B., Rambal, S., Valentini, R., Vesala, T., Yakir, D., 2006. Towards a standardized processing of Net Ecosystem Exchange measured with eddy covariance technique: algorithms and uncertainty estimation. *Biogeosciences.* 3, 571–583.
146. Paredes, V., 2013. Medida y parametrización de los flujos de CO₂ en un uso de suelo agrícola de la meseta utilizando datos en superficie y teledetección. PhD Thesis, University of Valladolid (Spain), 259 pp.
147. Pardo, N., Sánchez, M.L., Timmermans, J., Su, Z., Pérez, I.A., García, M.A., 2014. SEBS validation in a Spanish rotating crop. *Agric. For. Meteorol.* 195–196, 132–142.
148. Patel, N.R., Dadhwal, V.K., Saha, S.K, Garg, A., Sharma, N., 2010. Evaluation of MODIS data potential to infer water stress for wheat NPP estimation. *Trop. Ecol.* 51, 93–105.
149. Pei, F., Li, X., Liu, X., Lao, C., 2013. Assessing the impacts of droughts on net primary productivity in China. *J. Environ. Manage.* 114, 362–371.
150. Peng, Y., Gitelson, A.A., Sakamoto, T., 2013. Remote estimation of gross primary productivity in crops using MODIS 250m data. *Remote Sens. Environ.* 128, 186-196.
151. Pérez, I.A., García, M.A., Sánchez, M.L., De Torre, B., 2006. Analysis of wind data in the low atmosphere from a RASS sodar. *Ann. Geophys.* 24, 415-426.
152. Peterson, C.L. and Hustrulid, T., 1998. Carbon cycle for rapeseed oil biodiesel fuels. *Biomass Bioenerg.* 14, 91-101.

153. Pilegaard, K., Hummelshøj, P., Jensen, N.O., Chen, Z., 2001. Two years of continuous CO₂ eddy-flux measurements over a Danish beech forest. *Agric. For. Meteorol.* 107, 29-41.
154. Prince, S.D. and Goward, S.N., 1995. Global primary production: a remote sensing approach. *J. Biogeogr.* 22, 815-835.
155. Qaderi, M. M. and Reid, D. M. 2009. Crop responses to elevated carbon dioxide and temperature. 1-18, in Singh, S. N. (ed.). *Climate Change and Crops*. Springer-Verlag, Berlin Heidelberg.
156. Qian, W., Princevac, M., Venkatram, A., 2010. Using temperature fluctuation measurements to estimate meteorological inputs for modeling dispersion during convective conditions in urban areas. *Bound.-Layer Meteorol.* 135 (2), 269-289.
157. Reay, D.S. and Grace, J., 2007. Carbon dioxide: Importance, sources and sinks. *Greenhouse Gas Sinks*, 1-10.
158. Reichstein, M., Falge, E., Baldocchi, D., Papale, D., Aubinet, M., Berbigier, P., Bernhofer, C., Buchmann, N., Gilmanov, T., Granier, A., Grünwald, T., Havránková, K., Ilvesniemi, H., Janous, D., Knohl, A., Laurila, T., Lohila, A., Loustau, D., Matteucci, G., Meyers, T., Miglietta, F., Ourcival, J.M., Pumpanen, J., Rambal, S., Rotenberg, E., Sanz, M., Tenhunen, J., Seufert, G., Vaccari, F., Vesala, T., Yakir, D., Valentini, R., 2005. On the separation of net ecosystem exchange into assimilation and ecosystem respiration: review and improved algorithm. *Global Change Biol.* 11, 1424-1439.
159. Reichstein, M., Papale, D., Valentini, R., Aubinet, M., Bernhofer, C., Knohl, A., Laurila, T., Lindroth, A., Moors, E., Pilegaard, K., Seufert, G., 2007. Determinants of terrestrial ecosystem carbon balance inferred from European eddy covariance flux sites. *Geophys. Res. Lett.* 34, L01402, doi:10.1029/2006GL027880.
160. Reichstein, M., Bahn, M., Mahecha, M.D., Kattge, J., Baldocchi, D.D., 2014. Linking plant and ecosystem functional biogeography. *Proc. Natl. Acad. Sci. U. S. A.* 111, 13697-13702.
161. Reijnders, L. and Huijbregts, M.A.J., 2008. Biogenic greenhouse gas emissions linked to the life cycles of biodiesel derived from European rapeseed and Brazilian soybeans. *J. Clean. Prod.* 16, 1943-1948
162. Revill, A., Sus, O., Barrett, B., Williams, M., 2013. Carbon cycling of European croplands: A framework for the assimilation of optical and microwave Earth observation data. *Remote Sens. Environ.* 137, 84-93.
163. Riederer, M., Serafimovich, A., Foken, T., 2014. Net ecosystem CO₂ exchange measurements by the closed chamber method and the eddy covariance technique and their dependence on atmospheric conditions. *Atmos. Meas. Tech.* 7, 1057-1064.

164. Roerink, G. J., Su, Z., Menenti, M., 2000. S-SEBI: A Simple Remote Sensing Algorithm to Estimate the Surface Energy Balance. *Phys. Chem. Earth*. 25, 2, 147-157.
165. Runkle, B.R.K., Wille, C., Gažovič, M., Wilmking, M., Kutzbach, L., 2014. The surface energy balance and its drivers in a boreal peatland fen of northwestern Russia. *J. Hydrol.* 511, 359-373.
166. Running, S.W., Baldocchi, D.D., Turner, D.P., Gower, S.T., Bakwin, P.S., Hibbard, K.A., 1999. A global terrestrial monitoring network integrating tower fluxes, flask sampling, ecosystem modelling and EOS satellite data. *Remote Sens. Environ.* 70, 108-127.
167. Running, S.R., Thornton, P.E., Nemani, R., Glassy, J.M., 2000. Global terrestrial gross and net primary productivity from the Earth Observing System, in: Sala, O.E., Jackson, R.B., Mooney, H.A., Howarth, R.W. (Eds.), *Methods in Ecosystem Science*, Springer, New York, pp. 44-57.
168. Sánchez, M.L., Ozores, M.I., Colle, R., López, M.J., De Torre, B., García, M.A., Pérez, I., 2002. Soil CO₂ fluxes in cereal land use of the Spanish plateau: Influence of conventional and reduced tillage practices. *Chemosphere*. 47, 837-844.
169. Sánchez, M.L., Pérez, I.A., García, M.A., 2010a. Study of CO₂ variability at different temporal scales recorded in a rural Spanish site. *Agric. For. Meteorol.* 150, 1168-1173.
170. Sánchez, J.M., Caselles, V., Rubio, E.M., 2010b. Analysis of the energy balance closure over a FLUXNET boreal forest in Finland. *Hydrol. Earth Syst. Sci.* 14, 1487-1497.
171. Sánchez-Cañete, E.P., Kowalski, A.S., Serrano-Ortiz, P., Pérez-Priego, O., Domingo, F., 2013. Deep CO₂ soil inhalation/exhalation induced by synoptic pressure changes and atmospheric tides in a carbonated semiarid steppe. *Biogeosciences*. 10, 6591-6600.
172. Sandaña, P., Ramírez, M., Pinochet, D., 2012. Radiation interception and radiation use efficiency of wheat and pea under different P availabilities. *Field Crops Res.* 127, 44-50.
173. Santanello Jr., J. A. and Friedl, M. A., 2003. Diurnal covariation in soil heat flux and net radiation. *J. Appl. Meteorol.* 42, 851-862.
174. Schulze, E.D., Luysaert, S., Ciais, P., Freibauer, A., Janssens, I.A., Soussana, J.F., Smith, P., Grace, J., Levin, I., Thiruchittampalam, B., Heimann, M., Dolman, A.J., Valentini, R., Bousquet, P., Peylin, P., Peters, W., Rödenbeck, C., Etiope, G., Vuichard, N., Wattenbach, M., Nabuurs, G.J., Poussi, Z., Nieschulze, J., Gash, J.H., and the CarboEurope Team, 2009. Importance of methane and nitrous oxide for Europe's terrestrial greenhouse-gas balance. *Nat. Geosci.* 2, 842-850, doi:10.1038/ngeo686.

175. Sellers, P.J., Randall, D.A., Collatz, G.J., Berry, J.A., Field, C.B., Dazlich, D.A., Zhang, C., Collelo, G.D., Bounoua, L., 1996. A revised land surface parameterization (SiB2) for atmospheric GCMs. Part I: Model formulation. *J. Clim.* 9 (4), 676-705.
176. Seoáñez Calvo, M., 2002. Tratado de la contaminación atmosférica: Problemas, tratamiento y gestión. Colección Ingeniería del Medio Ambiente. Madrid: Mundi-Prensa. 1111 p. ISBN: 8484760359.
177. Shao, C., Chen, J., Li, L., Xu, W., Chen, S., Gwen, T., Xu, J., Zhang, W., 2008. Spatial variability in soil heat flux at three Inner Mongolia steppe ecosystems. *Agric. For. Meteorol.* 148, 1433-1443.
178. Shen, S. and Leptoukh, G.G., 2011. Estimation of surface air temperature over central and eastern Eurasia from MODIS land surface temperature. *Environ. Res. Lett.* 6, 045206, doi: 10.1088/1748-9326/6/4/045206.
179. Shi, T.-., Guan, D.-., Wu, J.-., Wang, A.-., Jin, C.-., Han, S.-., 2008. Comparison of methods for estimating evapotranspiration rate of dry forest canopy: Eddy covariance, Bowen ratio energy balance, and Penman-Monteith equation. *J. Geophys. Res.: Atmospheres.* 113.
180. Shim, C., Hong, J., Hong, J., Kim, Y., Kang, M., Malla Thakuri, B., Kim, Y., Chun, J., 2014. Evaluation of MODIS GPP over a complex ecosystem in East Asia: A case study at Gwangneung flux tower in Korea. *Adv. Space Res.* 54, 11, 2296-2308.
181. Shuttleworth, W.J. and Wallace, J.S., 1985. Evaporation from sparse crops - an energy combination theory. *Quarterly Journal - Royal Meteorological Society*, 111 (469), pp. 839-855.
182. Shuttleworth, W.J., 2012. Surface energy fluxes (chapter 4), in *Terrestrial Hydrometeorology*, John Wiley & Sons, Ltd, Chichester, UK. doi: 10.1002/9781119951933.ch4.
183. SIGPAC.
<http://sigpac.mapa.es/fega/visor/>
184. Sims, D.A., Rahman, A.F., Cordova, V.D., Baldocchi, D.D., Flanagan, L.B., Goldstein, A.H., Hollinger, D.Y., Misson, L., Monson, R.K., Schmid, H.P., Wofsy, S.C., Xu, L., 2005. Midday values of gross CO₂ flux and light use efficiency during satellite overpasses can be used to directly estimate eight-day mean flux. *Agric. For. Meteorol.* 131, 1-12.
185. Smith, P., 2004. Carbon sequestration in croplands: the potential in Europe and the global context. *Europ. J. Agron.* 20, 229-236.
186. Smith, P., Martino, D., Cai, Z., Gwary, D., Janzen, H., Kumar, P., McCarl, B., Ogle, S., O'Mara, F., Rice, C., Scholes, B., Sirotenko, O., Howden, M., McAllister, T., Pan, G., Romanenko, V., Schneider, U., Towprayoon, S., Wattenbach, M., Smith, J., 2008. Greenhouse gas mitigation in agriculture. *Philos. Trans. R. Soc. London, Ser. B.* 363, 789-813. doi: 10.1098/rstb.2007.2184.

187. Soetedjo, P., Martin, L. D., Janes, J.V., 1998. Canopy architecture, light utilization and productivity of intercrops of field pea and canola. In: *Agronomy, growing a greener future?*. Proceedings of the 9th Australian Agronomy Conference, 20-23 July 1998, Edited by DL Michalk and JE Pratley. Charles Sturt University, Wagga wagga, NSW.
188. Steffen, W., Noble, I., Canadell, J., Apps, M., Schulze, E.D., Jarvis, P.G., Baldocchi, D., Ciais, P., Cramer, W., Ehleringer, J., Farquhar, G., Field, C.B., Ghazi, A., Gifford, R., Heimann, M., Houghton, R., Kabat, P., Korner, C., Lambin, E., Linder, S., Mooney, H.A., Murdiyarso, D., Post, W.M., Prentice, I.C., Raupach, M.R., Schimel, D.S., Shvidenko, A., Valentini, R., 1998. The terrestrial carbon cycle: Implications for the Kyoto Protocol. *Science*. 280, 1393-1394.
189. Su, Z., 2002. The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. *Hydrol. Earth Syst. Sci.* 6, 85-99.
An introduction to surface Energy Balance System (SEBS). SU, Z. Lecture Notes - www.itc.nl
190. Sun, G., Noormets, A., Gavazzi, M.J., McNulty, S.G., Chen, J., Domec, J.-C., King, J.S., Amatya, D.M., Skaggs, R. W., 2010. Energy and water balance of two contrasting loblolly pine plantations on the lower coastal plain of North Carolina, USA. *Forest Ecol. Manag.* 259, 1299-1310.
191. Szczypta, C., Calvet, J.-C., Albergel, C., Balsamo, G., Boussetta, S., Carrer, D., Lafont, S., Meurey, C., 2011. Verification of the new ECMWF ERA-Interim reanalysis over France. *Hydrol. Earth Syst. Sci.* 15, 647-666.
192. Szilagyi, J., Rundquist, D. C., Gosselin, D. C., Parlange, M. B., 1998. NDVI relationship to monthly evaporation. *Geophys. Res. Lett.* 25, 10, 1753-1756.
193. Tanaka, H., Hiyama, T., Kobayashi, N., Yabuki, H., Ishii, Y., Desyatkin, R.V., Maximov, T.C., Ohta, T., 2008. Energy balance and its closure over a young larch forest in eastern Siberia. *Agric. For. Meteorol.* 148, 1954-1967.
194. Tang, R., Li, Z.-L., Chen, K.-S, Jia, Y., Li, C., Sun, X., 2013. Spatial-scale effect on the SEBAL model for evapotranspiration estimation using remote sensing data. *Agric. For. Meteorol.* 174-175, 28-42.
195. Tao, B., Tian, H., Chen, G., Ren, W., Lu, C., Alley, K. D., Xu, X., Liu, M., Pan, S., Virji, H., 2011. Changes in carbon fluxes and pools induced by cropland expansion in South and Southeast Asia in the 20th century. *Biogeosciences Discuss.* 8, 11979-12012.
196. Tesfaye, K., Walker, S., Tsubo, M., 2006. Radiation interception and radiation use efficiency of three grain legumes under water deficit conditions in a semi-arid environment. *Europ. J. Agron.* 25, 60-70.

197. Träger-Chatterjee, C., Müller, R. W., Trentmann, J., Bendix, J., 2010. Evaluation of ERA-40 and ERA-interim re-analysis incoming surface shortwave radiation datasets with mesoscale remote sensing data. *Meteorol. Z.* 19, 6, 631-640.
198. Timmermans, W. J., Kustas, W. P., Anderson, M. C., French, A. N., 2007. An intercomparison of the Surface Energy Balance Algorithm for Land (SEBAL) and the Two-Source Energy Balance (TSEB) modelling Schemes. *Remote Sens. Environ.* 108, 369-384.
199. Tolk, L.F., Dolman, A.J., Meesters, A.G.C.A., Peters, W., 2011. A comparison of different inverse carbon flux estimation approaches for application on a regional domain. *Atmos. Chem. Phys.* 11 (20), 10349-10365.
200. Turner, D.P., Ritts, W.D., Cohen, W.B., Gower, S.T., Zhao, M., Running, S.W., Wofsy, S.C., Urbanski, S., Dunn, A.L., Munger, J.W., 2003. Scaling Gross Primary Production (GPP) over boreal and deciduous forest landscapes in support of MODIS GPP product validation. *Remote Sens. Environ.* 88, 256-270.
201. Turner, D.P., Ollinger, S.V., Kimball, J.S., 2004. Integrating remote sensing and ecosystem process models for landscape- to regional-scale analysis of the carbon cycle. *Bioscience*, vol. 54, no. 6, pp. 573-584.
202. Turner, D.P., Ritts, W.D., Cohen, W.B., Maeirsperger, T.K., Gower, S.T., Kirschbaum, A.A., Running, S.W., Zhao, M.S., Wofsy, S.C., Dunn, A.L., Law, B.E., Campbell, J.L., Oechel, W.C., Kwon, H.J., Meyers, T.P., Small, E.E., Kurc, S.A., Gamon, J.A., 2005. Site-level evaluation of satellite-based global terrestrial gross primary production and net primary production. *Monitoring. Glob. Chang. Biol.* 11, 666-684.
203. Turner, D.P., Ritts, W.D., Cohen, W.B., Gower, S.T., Running, S.W., Zhao, M., Costa, M.H., Kirschbaum, A.A., Ham, J.M., Saleska, S.R., Ahl, D.E., 2006. Evaluation of MODIS NPP and GPP products across multiple biomes. *Remote Sens. Environ.* 102, 282-292.
204. Valentini R., Matteucci G., Dolman A.J., Schulze E.-., Rebmann C., Moors E.J., Granier A., Gross P., Jensen N.O., Pilegaard K., Lindroth, A., Grelle, A., Bernhofer, C., Grünwald, T., Aubinet, M., Ceulemans, R., Kowalski, A.S., Vesala, T., Rannik, Ü., Berbigier, P., Loustau, D., Guomundsson, J., Thorgeirsson, H., Ibrom, A., Morgenstern, K., Clement, R., Moncrieff, J., Montagnani, L., Minerbi, S., Jarvis, P.G., 2000. Respiration as the main determinant of carbon balance in European forests. *Nature.* 404, 861-865.
205. Venturini, V., Islam, S., Rodríguez L., 2008. Estimation of evaporative fraction and evapotranspiration from MODIS products using a complementary based model. *Remote Sens. Environ.* 112, 132-141.
206. Veroustraete, F., Sabbe, H., Eerens, H., 2002. Estimation of carbon mass fluxes over Europe using the C-Fix model and Euroflux data. *Remote Sens. Environ.* 83, 376-399.

207. Verbeeck, H., Peylin, P., Bacour, C., Bonal, D., Steppe, K., Ciais, P., 2011. Seasonal patterns of CO₂ fluxes in Amazon forests: Fusion of eddy covariance data and the ORCHIDEE model. *J. Geophys. Res.*, 116, G02018, doi:10.1029/2010JG001544.
208. Vinukollu, R. K., Wood, E. F., Ferguson, C. R., Fisher, J. B., 2011. Global estimates of evapotranspiration for climate studies using multi-sensor remote sensing data: Evaluation of three process-based approaches. *Remote Sens. Environ.* 115, 801–823.
209. Wagle, P., Xiao, X., Suyker, A.E., 2015. Estimation and analysis of gross primary production of soybean under various management practices and drought conditions. *ISPRS-J. Photogramm. Remote Sens.* 99, 70–83.
210. Wali, M.K., Evrendilek, F., Fennessy, M.S., 2009. *The Environment: Science, Issues and Solutions*. CRC Press, Florida. 648 pp. ISBN 9780849373879.
211. Wang, Y.-P. and Leuning, R., 1998. A two-leaf model for canopy conductance, photosynthesis and partitioning of available energy I: Model description and comparison with a multi-layered model. *Agric. For. Meteorol.* 91 (1-2), pp. 89–111.
212. Wang, K., Li, Z., Cribb, M., 2006. Estimation of evaporative fraction from a combination of day and night land surface temperatures and NDVI: A new method to determine the Priestley–Taylor parameter. *Remote Sens. Environ.* 102, 293–305.
213. Wang, Z., Xiao, X., Yan, X., 2010. Modeling gross primary production of maize cropland and degraded grassland in northeastern China. *Agric. For. Meteorol.* 150, 1160–1167.
214. Wang, Y. and Li, X., 2011. Sensible heat flux estimation using SEBS, MODIS products and NCEP reanalysis data. *IGARSS. 978-1-4577-1005-6 / 11. IEEE.*
215. Wang, X., Ma, M., Huang, G., Veroustraete, F., Zhang, Z., Song, Yi, Tan, J., 2012. Vegetation primary production estimation at maize and alpine meadow over the Heihe River Basin, China. *Int. J. Appl. Earth Obs. Geoinf.* 17, 94–101.
216. Wang, Y., Li, X., Tang, S., 2013. Validation of the SEBS-derived sensible heat for FY3A/VIRR and TERRA/MODIS over an alpine grass region using LAS measurements. *Int. J. Appl. Earth Observ. Geoinf.* 23, 226–233.
217. Webb, E.K., Pearman, G.I., Leuning, R., 1980. Correction of flux measurements for density effects due to heat and water vapour transfer. *Q. J. R. Meteorol. Soc.*, 106, 85–100.

218. West, T.O., Brandt, C.C., Baskaran, L.M., Hellwinckel, C.M., Mueller, R., Bernacchi, C.J., Bandaru, V., Yang, B., Wilson, B.S., Marland, G., Nelson, R.G., de la Torre Ugarte, D.G., Post, W.M., 2010. Cropland carbon fluxes in the United States: Increasing geospatial resolution of inventory-based carbon accounting. *Ecol. Appl.* 20, 1074-1086.
219. Wilson, K.B., Baldocchi, D.D., Hanson, P.J., 2001. Leaf age affects the seasonal pattern of photosynthetic capacity and net ecosystem exchange of carbon in a deciduous forest. *Plant Cell Environ.* 24 (6), 571-583.
220. Wilson, K., Goldstein, A., Falge, E., Aubinet, M., Baldocchi, D., Berbigier, P., Bernhofer, C., Ceulemans, R., Dolman, H., Field, C., Grelle, A., Ibrom, A., Law, B.E., Kowalski, A., Meyers, T., Moncrieff, J., Monson, R., Oechel, W., Tenhunen, J., Valentini, R., Verma, S., 2002a. Energy balance closure at FLUXNET sites. *Agric. For. Meteorol.* 113, 223-243.
221. Wilson, K.B., Baldocchi, D.D., Aubinet, M., Berbigier, P., Bernhofer, C., Dolman, H., Falge, E., Field, C., Goldstein, A., Granier, A., Grelle, A., Halldor, T., Hollinger, D., Katul, G., Law, B.E., Lindroth, A., Meyers, T., Moncrieff, J., Monson, R., Oechel, W., Tenhunen, J., Valentini, R., Verma, S., Vesala, T., Wofsy, S., 2002b. Energy partitioning between latent and sensible heat flux during the warm season at FLUXNET sites. *Water Resour. Res.* 38, 301-3011.
222. Wolfe, R.E., Nishihama, M., Fleig, A.J., Kuyper, J.A., Roy, D.P., Storey, J.C., Patt, F.S., 2002. Achieving sub-pixel geolocation accuracy in support of MODIS land science. *Remote Sens. Environ.* 83, 31-49.
223. Wolfe R., Nishihama, M., Kuyper, R., 2012. http://mcst.gsfc.nasa.gov/sites/mcst.gsfc/files/meetings_files/STM2012_Cal_Wolfe.pdf
224. Worku, W. and Demisie, W., 2012. Growth, light interception and radiation use efficiency response of Pigeon pea (*Cajanus cajan*) to planting density in Southern Ethiopia. *J. Agron.* 11, 85-93.
225. Xiao, X., Hollinger, D., Aber, J., Goltz, M., Davidson, E.A., Zhang, Q., Moore III, B., 2004. Satellite-based modeling of gross primary production in an evergreen needleleaf forest. *Remote Sens. Environ.* 89, 519-534.
226. Xiao, X., Zhang, Q., Saleska, S., Hutyrá, L., De Camargo, P., Wofsy, S., Froking, S., Boles, S., Keller, M., Moore III, B., 2005. Satellite-based modeling of gross primary production in a seasonally moist tropical evergreen forest. *Remote Sens. Environ.* 94, 105-122.
227. Xiao, J., Sun, G., Chen, J., Chen, H., Chen, S., Dong, G., Gao, S., Guo, H., Guo, J., Han, S., Kato, T., Li, Y., Lin, G., Lu, W., Ma, M., McNulty, S., Shao, C., Wang, X., Xie, X., Zhang, X., Zhang, Z., Zhao, B., Zhou, G., Zhou, J., 2013. Carbon fluxes, evapotranspiration, and water use efficiency of terrestrial ecosystems in China. *Agric. For. Meteorol.* 182-183, 76-90.

228. Xin, Q., Gong, P., Yu, C., Yu, L., Broich, M., Suyker, A.E., Myneni, R.B., 2013. A production efficiency model-based method for satellite estimates of corn and soybean yields in the midwestern US. *Remote Sensing*. 5, 5926-5943.
229. Xin, X. and Liu, Q., 2010. The Two-layer Surface Energy Balance Parameterization Scheme (TSEBPS) for estimation of land surface heat fluxes. *Hydrol. Earth Syst. Sci.* 14, 491-504.
230. Xue, S., Steinberger, Y., Wang, J. S., Li, G.Y., Xu, X.Y., Xie, G.H., 2013. Biodiesel production of nonfood plant resources from Tsinling and Zhongtiao Mountains of China. *Bioenerg Res.* 6, 1104-1117.
231. Yahuza, I., 2011. Review of radiation interception and radiation use efficiency in intercropping in relation to the analysis of wheat/faba bean intercropping system. *J. Bio. & Env. Sci.* 1, 1-15.
232. Yamori, W., Hikosaka, K., Way, D.A., 2014. Temperature response of photosynthesis in C3, C4, and CAM plants: Temperature acclimation and temperature adaptation. *Photosynthesis Res.* 119, 101-117.
233. Yan, H., Fu, Y., Xiao, X., Huang, H.Q., He, H., Ediger, L., 2009. Modeling gross primary productivity for winter wheat-maize double cropping system using MODIS time series and CO₂ eddy flux tower data. *Agric. Ecosys. Environ.* 129, 391-400.
234. Yan, H., Wang, S.-., Billesbach, D., Oechel, W., Bohrer, G., Meyers, T., Martin, T.A., Matamala, R., Phillips, R.P., Rahman, F., Yu, Q., Shugart, H.H., 2015. Improved global simulations of gross primary production based on a new definition of water stress factor and a separate treatment of C3 and C4 plants. *Ecol. Model.* 297, 42-59.
235. Yang, F., Zhou, G., Hunt, J.E., Zhang, F., 2011. Biophysical regulation of net ecosystem carbon dioxide exchange over a temperate desert steppe in Inner Mongolia, China. *Agric. Ecosyst. Environ.* 142, 318-328.
236. Yang, J. and Wang, Y., 2011. Estimating evapotranspiration fraction by modeling two-dimensional space of NDVI/albedo and day-night land surface temperature difference: A comparative study. *Adv. Water Resour.* 34, 512-518.
237. Yuan, W., Liu, S., Zhou, G., Zhou, G., Tieszen, L.L., Baldocchi, D., Bernhofer, C., Gholz, H., Goldstein, A.H., Goulden, M.L., Hollinger, D.Y., Hu, Y., Law, B.E., Stoy P.C., Vesala, T., Wofsy, S.C. and other AmeriFlux collaborators, 2007. Deriving a light use efficiency model from eddy covariance flux data for predicting daily gross primary production across biomes. *Agric. For. Meteorol.* 143, 189-207.

238. Yuan, W., Cai, W., Xia, J., Chen, J., Liu, S., Dong, W., Merbold, L., Law, B., Arain, A., Beringer, J., Bernhofer, C., Black, A., Blanken, P.D., Cescatti, A., Chen, Y., Francois, L., Gianelle, D., Janssens, I.A., Jung, M., Kato, T., Kiely, G., Liu, D., Marcolla, B., Montagnani, L., Raschi, A., Roupsard, O., Varlagin, A., Wohlfahrt, G., 2014. Global comparison of light use efficiency models for simulating terrestrial vegetation gross primary production based on the LaThuile database. *Agric. For. Meteorol.* 192-193, 108-120.
239. Zeri, M., Anderson-Teixeira, K., Hickman, G., Masters, M., DeLucia, E., Bernacchi, C.J., 2011. Carbon exchange by establishing biofuel crops in Central Illinois. *Agric. Ecosyst. Environ.* 144, 319-329.
240. Zhang, Y. and Tang Y., 2005. Inclusion of photoinhibition in simulation of carbon dynamics of an alpine meadow on the Qinghai-Tibetan Plateau, *J. Geophys. Res.* 110, G01007, doi:10.1029/2005JG000021.
241. Zhao, M., Heinsch, F.A., Nemani, R.R., Running, S.W., 2005. Improvements of the MODIS terrestrial gross and net primary production global data set. *Remote Sens. Environ.* 95, 164-176.
242. Zheng, X., Xie, B., Liu, C., Zhou, Z., Yao, Z., Wang, Y., Wang, Y., Yang, L., Zhu, J., Huang, Y., Butterbach-Bahl, K., 2008. Quantifying net ecosystem carbon dioxide exchange of a short-plant cropland with intermittent chamber measurements. *Glob. Biogeochem. Cycle.* 22, 3. doi: 10.1029/2007GB003104
243. Zhu, X-G., Long, S.P., Ort, D.R., 2010. Improving Photosynthetic Efficiency for Greater Yield. *Annu. Rev. Plant Biol.* 61, 235-261.

Curriculum Vitae

PUBLICACIONES

- **CLUSTER ANALYSIS APPLIED TO CO₂ CONCENTRATIONS AT A RURAL SITE.** I. A. PÉREZ, M. L. SÁNCHEZ, M. A. GARCÍA, M. OZORES, N. PARDO. ENVIRONMENTAL SCIENCE AND POLLUTION RESEARCH. 22 (3), 1954-1962. 2015
- **SEBS VALIDATION IN A SPANISH ROTATING CROP.** N. PARDO, M.L. SÁNCHEZ, JORIS TIMMERMANS, ZHONGBO SU, I.A. PÉREZ, M.A. GARCÍA. AGRICULTURAL AND FOREST METEOROLOGY. 195-196, 132-142. 2014
- **CH₄ CONTINUOUS MEASUREMENTS IN THE UPPER SPANISH PLATEAU.** M.L. SÁNCHEZ, M.A. GARCÍA, I.A. PÉREZ, N. PARDO. ENVIRONMENTAL MONITORING AND ASSESSMENT. 186, 2823-2834. 2014
- **ANALYSIS OF CARBON DIOXIDE CONCENTRATION SKEWNESS AT A RURAL SITE.** I.A. PÉREZ, M.L. SÁNCHEZ, M.A. GARCÍA, M. OZORES, N. PARDO. SCIENCE OF TOTAL ENVIRONMENT. 476-477, 158-164. 2014
- **CARBON DIOXIDE AT AN UNPOLLUTED SITE ANALYSED WITH THE SMOOTHING KERNEL METHOD AND SKEWED DISTRIBUTIONS.** I.A. PÉREZ, M.L. SÁNCHEZ, M.A. GARCÍA, N. PARDO. 456-457, 239-245. 2013
- **IMPLEMENTATION OF EF FROM SEBS IN A LUE MODEL IN A RAPESEED CROPLAND.** PROCEEDINGS OF 'ESA LIVING PLANET SYMPOSIUM 2013'. ESA SP-722, DECEMBER

2013. EDINBURGH, UK. N. PARDO, J. TIMMERMANS, I. A. PÉREZ, M. A. GARCÍA, Z. SU, M. L. SÁNCHEZ. 2013

- **MEDIDA Y PARAMETRIZACIÓN DE LOS FLUJOS DE CO₂ EN UN CULTIVO DE COLZA. MEDIDAS IN SITU Y SATELITALES.** M.L. SÁNCHEZ, N. PARDO, I.A. PÉREZ, M.A. GARCÍA. ACADÉMICA ESPAÑOLA. ESPAÑA. 2012
- **ANALYSIS OF CO₂ DAILY CYCLE IN THE LOW ATMOSPHERE AT A RURAL SITE.** I.A. PÉREZ, M.L. SÁNCHEZ, M.A. GARCÍA, N. PARDO. SCIENCE OF TOTAL ENVIRONMENT. 431, 286-292. 2012
- **SPATIAL ANALYSIS OF CO₂ CONCENTRATION IN AN UNPOLLUTED ENVIRONMENT IN NORTHERN SPAIN.** I.A. PÉREZ, M.L. SÁNCHEZ, M.A. GARCÍA, N. PARDO. JOURNAL OF ENVIRONMENT MANAGEMENT. 113, 417-425. 2012
- **ANALYSIS AND FIT OF SURFACE CO₂ CONCENTRATIONS AT A RURAL SITE.** I.A. PÉREZ, M.L. SÁNCHEZ, M.A. GARCÍA, N. PARDO. ENVIRONMENTAL SCIENCE AND POLLUTION RESEARCH. 19, 3015-3027. 2012

CONTRIBUCIONES A CONGRESOS

- **NEE AND GPP DYNAMIC EVOLUTION AT TWO BIOMES IN THE UPPER SPANISH PLATEAU** (Póster). M.L. SÁNCHEZ, N. PARDO, I.A. PÉREZ, M.A. GARCÍA. EUROPEAN GEOSCIENCES UNION (EGU) GENERAL ASSEMBLY 2014. 27 ABRIL - 2 MAYO, 2014. VIENA (AUSTRIA)
- **IMPLEMENTATION OF EF FROM SEBS IN A LUE MODEL IN A RAPESEED CROPLAND** (Póster). PARDO, N., TIMMERMANS, J., PÉREZ, I. A., GARCÍA, M.A., SU, Z.,

SÁNCHEZ, M. L. LIVING PLANET SYMPOSIUM 2013. 9-13 de SEPTIEMBRE de 2013. EDINBURGH (UK)

- **GPP ESTIMATES IN A RAPESEED ROTATING CROP USING IN SITU AND MODIS DATA** (Póster). M.L. SÁNCHEZ, I. A. PÉREZ, N. PARDO, M.A. GARCÍA. 9th INTERNATIONAL CARBON DIOXIDE CONFERENCE. 3-7 de JUNIO de 2013. BEIJING (CHINA)
- **ESTIMATING LIGHT USE EFFICIENCY WITH EVAPORATIVE FRACTION FROM FIELD-MEASUREMENTS AND FROM SEBS FOR RAPESEED** (Póster). PARDO, N., TIMMERMANS, J., SÁNCHEZ, M. L., SU, Z. 5th INTERNATIONAL WORKSHOP ON CATCHMENT HYDROLOGICAL MODELLING AND DATA ASSIMILATION (CAHMDA. 8-13 de JULIO de 2012. ENSCHEDE (HOLANDA)
- **GREENHOUSE GAS MEASUREMENTS IN THE UPPER SPANISH PLATEAU** (Póster). M.L. SÁNCHEZ, I. A. PÉREZ, M.A. GARCÍA, N. PARDO. EUROPEAN GEOSCIENCES UNION (EGU) GENERAL ASSEMBLY 2012. 22-27 de ABRIL de 2012. VIENA (AUSTRIA)
- **GPP ESTIMATES IN A BIODIESEL CROP USING MERIS PRODUCTS** (Póster). M.L. SÁNCHEZ, N. PARDO, I. A. PÉREZ, M.A. GARCÍA, V. PAREDES. EUROPEAN GEOSCIENCES UNION (EGU) GENERAL ASSEMBLY 2012. 22-27 de ABRIL de 2012. VIENA (AUSTRIA)
- **CUANTIFICACIÓN DE LOS SUMIDEROS DE CO₂ EN DOS ECOSISTEMAS DE CASTILLA Y LEÓN.** M.L. SÁNCHEZ, N. PARDO, V. PAREDES, I. A. PÉREZ, M.A. GARCÍA. PRIMER WORKSHOP SOBRE MITIGACIÓN DE EMISIÓN DE GASES DE EFECTO INVERNADERO PROVENIENTES DEL SECTOR AGROFORESTAL. 8-9 de MARZO de 2012. BILBAO (ESPAÑA)

ESTANCIAS DE INVESTIGACIÓN

- Faculty of Geo-Information Science and Earth Observation (ITC), Universidad de Twente. Enschede. Holanda. 2012 (14 semanas). Estancia breve de Personal Investigador – FPI.

DOCENCIA

- Curso 2013/2014. Universidad de Valladolid. Facultad de Ciencias. Grado de Física. Asignatura: Técnicas Experimentales en Física I. 9.5 horas

APÉNDICE I

Las definiciones que se muestran a continuación han sido recopiladas de la bibliografía (Kirschbaum et al., 2001; Chapin et al., 2002; Steffen et al. 1998). El criterio de signos seguido en esta tesis considera negativos los valores de NEE y RE correspondientes a la absorción de CO₂ por parte del ecosistema. El signo de GPP debería ser siempre positivo durante el día y 0 durante la noche por falta de actividad fotosintética. Sin embargo, existen casos excepcionales como es el caso de sequía para los cuales se podrían obtener valores negativos de GPP (Baldocchi and Valentini, 2004).

- ▣ **GPP**: total amount of carbon fixed in the process of photosynthesis by vegetation in an ecosystem.
- ▣ **NPP**: net production of organic carbon by vegetation in an ecosystem. Net carbon gain defined as the primary production minus the plant respiration (R_{plant} or R_a).
- ▣ **R_h**: carbon lost through microbial and animal (heterotrophic) respiration, which converts organic matter into CO₂.
- ▣ **R_a**: (autotrophic) respiration from plant roots.
- ▣ **RE** ó **R_{eco}**: combined respiration from plants (R_a) and animals and microbes (R_h).
- ▣ **NEE**: net ecosystem exchange between ecosystem and atmosphere.
- ▣ **NEP**: net primary production minus carbon losses in R_h .
- ▣ **NBP** or **NBE**: NEP integrated at large spatial scales. Change in carbon stocks after episodic carbon losses due to natural or anthropogenic disturbances have been taken into account. This variable is usually employed as a measure of the carbon flux at larger temporal and spatial scales.

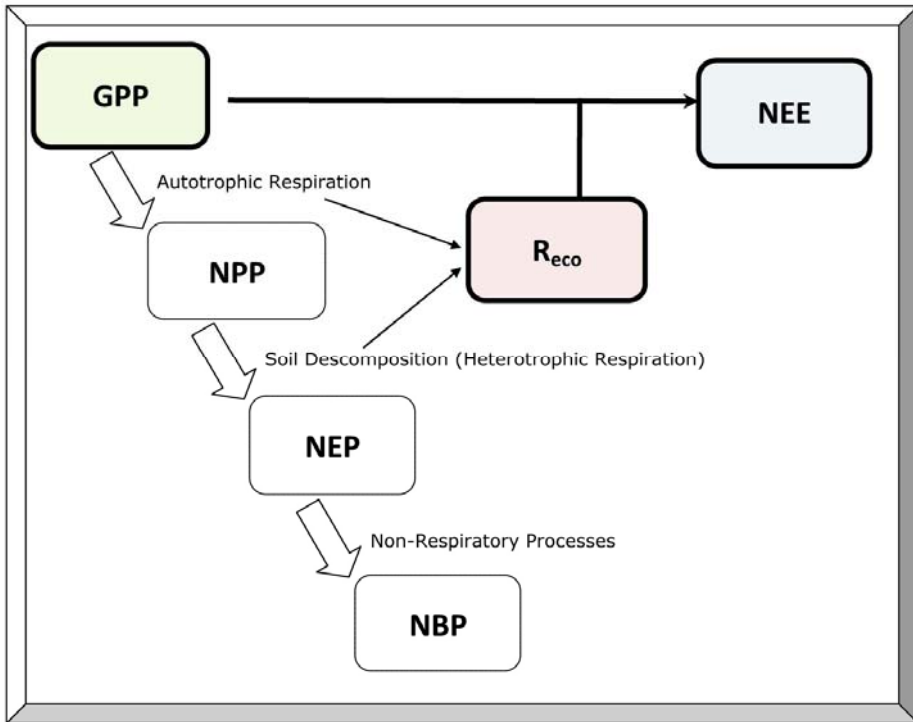


Figura A1. Diagrama de flujo que muestra la interrelación entre los diferentes flujos de CO₂ descritos en este apéndice.

APÉNDICE II

Medida y parametrización de los flujos de CO2 en un cultivo de colza

El objetivo central de este trabajo es presentar los resultados experimentales de los flujos netos de CO₂, NEE, y la producción primaria bruta, GPP, en un campo de cultivo de colza en Castilla y León y parametrizar los resultados mediante un modelo de uso eficiente de luz, LUE, usando datos medidos en superficie y teledetección. Los principales objetivos abordados son: 1. Adquisición de datos sistemáticos de los flujos netos de CO₂, NEE, vapor de agua o calor latente, LE, y energía en una parcela de cultivo rotante de colza. 2. Descripción cuantitativa de la capacidad de la colza como sumidero de CO₂. 3. Descripción y parametrización de la dinámica evolutiva de NEE y de la respiración, RE, usando datos de radiación fotosintética activa, PAR, la temperatura, la humedad del suelo medidas en superficie e índice foliar de la vegetación, LAI. 4. Aplicación y calibración de un modelo LUE para estimar la producción primaria bruta, GPP, utilizando datos de PAR, la fracción de la radiación fotosintética activa absorbida por la vegetación, FAPAR, suministrada por los sensores MODIS de la NOAA y MERIS de la Agencia Europea del Espacio, ESA y la fracción evaporativa, EF, medida en superficie.

M^a Luisa Sánchez

Catedrática de Física Aplicada. Directora del Grupo GIR de Contaminación Atmosférica de la Universidad de Valladolid. Directora de 11 Tesis Doctorales y autora o coautora de numerosas publicaciones nacionales e internacionales.



978-3-659-03319-3

editorial académica española



M^a Luisa Sánchez · Isidro A. Pérez · M^a Angeles García

Medida y parametrización de los flujos de CO2 en un cultivo de colza

Medidas in situ y satelitales

**M^a Luisa Sánchez
Isidro A. Pérez
M^a Angeles García**

**Medida y parametrización de los flujos de CO₂ en un cultivo de
colza**

**M^a Luisa Sánchez
Isidro A. Pérez
M^a Angeles García**

Medida y parametrización de los flujos de CO₂ en un cultivo de colza

Medidas in situ y satelitales

Editorial Académica Española

Impresión

Información bibliográfica publicada por Deutsche Nationalbibliothek: La Deutsche Nationalbibliothek enumera esa publicación en Deutsche Nationalbibliografie; datos bibliográficos detallados están disponibles en internet en <http://dnb.d-nb.de>.

Los demás nombres de marcas y nombres de productos mencionados en este libro están sujetos a la marca registrada o la protección de patentes y son marcas comerciales o marcas comerciales registradas de sus respectivos propietarios. El uso de nombres de marcas, nombre de producto, nombres comunes, nombre comerciales, descripciones de productos, etc. incluso sin una marca particular en estas publicaciones, de ninguna manera debe interpretarse en el sentido de que estos nombres pueden ser considerados ilimitados en materias de marcas y legislación de protección de marcas y, por lo tanto, ser utilizadas por cualquier persona.

Imagen de portada: www.ingimage.com

Editor: Editorial Académica Española es una marca de
LAP LAMBERT Academic Publishing GmbH & Co. KG
Heinrich-Böcking-Str. 6-8, 66121 Saarbrücken, Alemania
Teléfono +49 681 3720-310, Fax +49 681 3720-3109
Correo Electronico: info@eae-publishing.com

Publicado en Alemania

Schaltungsdienst Lange o.H.G., Berlin, Books on Demand GmbH, Norderstedt,
Reha GmbH, Saarbrücken, Amazon Distribution GmbH, Leipzig

ISBN: 978-3-659-03319-3

Imprint (only for USA, GB)

Bibliographic information published by the Deutsche Nationalbibliothek: The Deutsche Nationalbibliothek lists this publication in the Deutsche Nationalbibliografie; detailed bibliographic data are available in the Internet at <http://dnb.d-nb.de>.

Any brand names and product names mentioned in this book are subject to trademark, brand or patent protection and are trademarks or registered trademarks of their respective holders. The use of brand names, product names, common names, trade names, product descriptions etc. even without a particular marking in this works is in no way to be construed to mean that such names may be regarded as unrestricted in respect of trademark and brand protection legislation and could thus be used by anyone.

Cover image: www.ingimage.com

Publisher: Editorial Académica Española is an imprint of the publishing house
LAP LAMBERT Academic Publishing GmbH & Co. KG
Heinrich-Böcking-Str. 6-8, 66121 Saarbrücken, Germany
Phone +49 681 3720-310, Fax +49 681 3720-3109
Email: info@eae-publishing.com

Printed in the U.S.A.

Printed in the U.K. by (see last page)

ISBN: 978-3-659-03319-3

Copyright © 2012 by the author and LAP LAMBERT Academic Publishing GmbH & Co. KG
and licensors

All rights reserved. Saarbrücken 2012

MEDIDA Y PARAMETRIZACIÓN DE LOS FLUJOS DE CO₂ EN UN CULTIVO DE COLZA UTILIZANDO MEDIDAS IN SITU Y SATELITALES

M.L Sánchez, N. Pardo, I.A. Pérez y M.A. García
Departamento de Física Aplicada. Facultad de Ciencias.
Universidad de Valladolid.
Campus Miguel Delibes. Paseo Belén, 7, 47011 Valladolid.
Correo electrónico: marisa@fal.uva.es

RESUMEN

El objetivo central de este trabajo es presentar los resultados experimentales de los flujos netos de CO₂, NEE, y la producción primaria bruta, GPP, en un campo de cultivo de colza en Castilla y León y parametrizar los resultados mediante un modelo de uso eficiente de luz, LUE, usando datos medidos en superficie y teledetección. Los objetivos específicos abordados son:

- Adquisición de datos sistemáticos de los flujos netos de CO₂, NEE, vapor de agua o calor latente, LE, y energía en una parcela de cultivo rotante de colza.
- Descripción cuantitativa de la capacidad de la colza como sumidero de CO₂.
- Descripción y parametrización de la dinámica evolutiva de NEE y de la respiración, RE, usando datos de radiación fotosintética activa, PAR, la temperatura, la humedad del suelo medidas en superficie e índice foliar de la vegetación, LAI.
- Aplicación y calibración de un modelo LUE para estimar la producción primaria bruta, GPP, utilizando datos de PAR, la fracción de la radiación fotosintética activa absorbida por la vegetación, FAPAR, suministrada por los sensores MODIS de la NOAA y MERIS de la Agencia Europea del Espacio, ESA y la fracción evaporativa, EF, medida en superficie.

Este trabajo también aborda el análisis comparativo de los parámetros biofísicos FAPAR y LAI suministrado por los dos sensores satelitales e inter-compara los resultados del LAI medidos en superficie con los suministrados por

dichos sensores. Asimismo calibra los datos de GPP calculados por MODIS, los cuales infravaloran substancialmente los valores experimentales obtenidos.

Palabras Clave: Cambio climático, sumideros de CO₂, producción primaria neta y producción primaria bruta, teledetección.

1. ANTECEDENTES

Existe un amplio consenso de que se está produciendo una aceleración en el cambio climático más rápido de lo esperado. El caldeoamiento del sistema climático parece ser inequívoco como lo demuestran diversos indicadores entre los cuales destacan el aumento de temperatura en 0.75°C registrado durante los 100 últimos años a escala planetaria, el del nivel del mar en 2.3 mm/año, la significativa reducción de las áreas cubiertas de nieve en el hemisferio norte en aproximadamente 36 millones de km² así como la recesión de los glaciares (IPCC, 2007). También se ha reportado el adelanto de la primavera y el retraso del otoño (Feld et al., 1998, Valladares et al., 2005, Angert et al., 2005), el aumento significativo de eventos meteorológicos severos y la presencia de una alteración geográfica en la distribución pluviométrica en el hemisferio norte, con un aumento del 2 al 4% de precipitaciones copiosas y de la cobertura nubosa en las latitudes medias y altas durante la segunda mitad del milenio (IPCC, 2001). Un aumento de temperatura y/o una disminución de las precipitaciones puede tener una incidencia clave en la humedad del suelo causando sequías cada vez más severas las cuales se prevé tengan particular incidencia en el sur de Europa. Paralelamente el aumento de la cobertura nubosa incide en la energía disponible por parte de la vegetación y en su distribución en forma de calor sensible y de calor latente. El aumento de la temperatura y la disminución de la humedad relativa provocan un gran impacto sobre la vegetación ya que intervienen directamente en el control de la apertura estomática (Meyers, 2001), uno de los principales mecanismos a través de los cuales la vegetación actúa como sumidero de CO₂, el principal gas invernadero, con una aportación del 82.7% en Europa. En este contexto aún se desconoce la respuesta de los ecosistemas al cambio

global (Adams y Piovesan, 2002) y por tanto su papel de realimentación sobre el ciclo de carbono y el futuro del clima. Ya casi nadie duda de que dichas alteraciones tienen como origen el aumento de las concentraciones de gases invernadero en la atmósfera debido a actividades antrópicas, resultado del aumento de las emisiones y a los cambios de usos de suelo provocados por el hombre (Houghton, 1999). Las concentraciones de CO₂ en la atmósfera han aumentado desde la era preindustrial, 278 ppm, hasta 393 ppm en 2011 mostrando las observaciones históricas más largas recogidas en Mauna Loa una tendencia anual progresivamente creciente (<http://www.cmdl.noaa.gov>). Estos mismos resultados han sido confirmados en otros emplazamientos rurales habiéndose reportado tasas crecientes anuales superiores a 2.3 ppm/año (Ferrarese et al., 2002, Apadula et al., 2003, Tsutsumi et al., 2006). En Castilla y León, las medidas que viene realizando nuestro grupo desde el año 2000 han reflejado un aumento aún superior, alrededor de 3 ppm/año (Sánchez et al., 2010), tal como visualmente se deduce de la Figura 1 donde se muestra la evolución de los promedios mensuales. Dicha tasa parece haber comenzado a disminuir durante los dos últimos años, lo que estaría en conformidad con la reducción de emisiones llevada a cabo en el territorio nacional.




Figura 1. Evolución de las concentraciones de CO₂ en un área rural de la meseta desde 2000 a 2011.

La valoración más reciente de la Agencia de Medio Ambiente Europea, EEA, 2011 (<http://www.eea.europa.eu/themes/climate/ghg-country-profiles/>) de la que disponemos sobre la situación actual de las emisiones de gases invernadero de los 15 países que subscribieron el Protocolo de Kioto, EU-15, muestra que durante los tres primeros años del primer período de compromiso, 2008-2012, las emisiones de los gases con efecto invernadero, GEI, expresadas como CO₂ equivalente se han reducido en promedio en un 4.7%, porcentaje aún lejano del comprometido 8%. De dicho porcentaje, 1.2% corresponde a la reducción de emisiones domésticas, 0.9% a las derivadas de los usos del suelo y 2.5% a las propuestas por cada país mediante el uso de los mecanismos flexibles contemplados en el Protocolo de Kioto (http://unfccc.int/kyoto_protocol/mechanisms/). Estas últimas contemplan contabilizar los sumideros y la financiación de proyectos de reducción de emisiones en otros países.

La reducción obtenida hasta ahora se ha debido principalmente a los sectores de la agricultura (11%), los residuos (39%), los procesos industriales (11%) y en alguna medida la producción y uso de la energía (4%). Estos resultados contrastan con el transporte el cual ha experimentado un aumento en la EU-15 desde el año base de aproximadamente un 31%. La preocupación sobre la evolución de este importante sector es evidente ya que las previsiones apuntan a que el tráfico continuara aumentando durante esta década.

Sin embargo la situación de cada uno de los países de la UE es muy desigual. Así, mientras en 2006 12 países de la EU-15 ya cumplían sus compromisos adoptados en el Protocolo de Kioto o proyectaban cumplirlos, Dinamarca, Italia y España, presentaban una situación mucho más comprometida. De estos tres países España estaba en la peor situación arrojando un aumento de las emisiones del 51%, de las cuales los sectores energía y transporte han experimentado incrementos del 38 y 89% respectivamente. Entre 2008 y 2009 las emisiones en España disminuyeron un 9.2% hecho parcialmente atribuido a la recesión económica, al aumento de energías renovables y a la reducción del uso del carbón. A pesar de ello, España deberá hacer

un importante esfuerzo hasta 2012 para cumplir la comprometida estabilización del 15% aplicando los mecanismos flexibles previstos en el Protocolo de Kioto para lo que también contempla acogerse a la contabilización de los sumideros.

Respecto a los dos principales sectores contribuyentes a las emisiones de CO₂, suministro y uso de la energía (53%) y transporte (25.1%), la reducción de emisiones prevé diversas alternativas. Para el sector energía las líneas estratégicas consideran el aumento de las energías renovables, la mejora de los procesos de combustión y de la eficiencia energética en general, así como el uso creciente de centrales térmicas de ciclo combinado. Para el sector transporte ocurre otro tanto: innovaciones tecnológicas en los motores convencionales promovidas mediante la Directiva 2003/73/CE, la cual fomenta el mayor conocimiento del usuario sobre el consumo y las emisiones de CO₂ de los vehículos, la reducción voluntaria de las emisiones por parte de los fabricantes de automóviles, el recurso de fiscalidad para el desarrollo de vehículos que consuman poco combustible, la fabricación de nuevos motores de automoción –híbridos, eléctricos- y el fomento de nuevos tipos de carburante basados en el uso de energías limpias. En este último contexto la Directiva 2003/30/CE del Parlamento Europeo promueve el uso de biocarburantes y entre otros establece:

- Que los Estados miembros deberán velar para que la proporción mínima de biocarburantes y otros combustibles renovables sea el 2% de todo el carburante comercializado en 2005 y del 5.75% en diciembre de 2010.
- Todo Estado que fije unos objetivos más bajos deberá justificarlo con criterios objetivos.

Dentro de los biocarburantes destaca el biodiesel el cual se fabrica a partir de aceites vegetales de cultivos tales como la soja, el girasol, la colza o la jatrofa. Considerando las condiciones agroclimáticas de nuestro país, el girasol y la colza, bien adaptados a los climas fríos, se consideran los cultivos más viables. La producción de girasol se ha mantenido durante los últimos años básicamente constante y la de la colza ha experimentado un notable incremento en la superficie

cultivada ascendiendo en más de 31.5% en la EU. Los países que más superficie destinan a los cultivos de biodiesel y en concreto de colza son Alemania y Francia. En España sólo ocupa aproximadamente el 1% de la superficie cultivable.

El cultivo de la colza presenta tanto beneficios medioambientales como ventajas para el agricultor. Por ejemplo, el uso del biodiesel no requiere ninguna modificación de los motores diesel, es biodegradable y se argumenta que reduce las emisiones de CO₂. Para el agricultor supone una buena alternativa rotacional del cultivo de cereal y una solución para el uso de sus tierras tras la reducción comunitaria impuesta para otros tipos de cultivos. El previsto aumento de superficie de colza cultivada en España en detrimento de otro tipo de cultivos supone un cambio de usos de suelos cuyas consecuencias sobre el ciclo de carbono están por determinar. Ello sugiere el interés de cuantificar la capacidad de este tipo de cultivo para absorber CO₂ de la atmósfera o lo que es equivalente, su capacidad de actuación como sumidero.

Las variables clave en el ciclo de carbono de los ecosistemas terrestres son la producción primaria neta, NEE, la producción primaria bruta, GPP, y la evapotranspiración. GPP es la cantidad de CO₂ absorbida por la vegetación a través de la fotosíntesis. Parte del CO₂ absorbido es devuelto a la atmósfera mediante los procesos de respiración, RE. NEE es el balance entre ambos términos y tiene un gran valor socio- económico ya que está relacionado con la productividad de las cosechas.

NEE se obtiene directamente sumando durante un intervalo de tiempo -por ejemplo, 1 día, 1 semana- (Running et al., 1999) los valores de los flujos netos, NEE, medidos con una alta resolución temporal, típicamente 30 o 60 minutos, mediante instrumentación de respuesta rápida y la aplicación del método de la covarianza, EC. La respiración, RE, también puede medirse con similar resolución temporal, bien directamente utilizando cámaras específicas (Sánchez et al., 2003, Pumpanen et al., 2004), o parametrizando los valores nocturnos de NEE (período en el que no hay fotosíntesis) en función de variables exógenas tales como la temperatura del aire, la

del suelo o la humedad del suelo (Sims et al., 2006). A partir de las medidas directas de NEE y las de RE se obtiene GPP. El aumento del número de observatorios que realizan este tipo de medias en diferentes ecosistemas distribuidos en el planeta, tales como los integrados en las redes CARBONEUROFLUX y FLUXNET, han puesto de manifiesto la gran variabilidad geográfica de NEE y consecuentemente de GPP (Baldocchi et al., 2001, Running et al., 1999). Otra alternativa para estimar GPP se basa en la aplicación de modelos biofísicos de uso eficiente de la luz, LUE, (Turner et al., 2003, Sims et al., 2005). Este tipo de modelos se funda en la teoría original de Monteith el cual formuló que la NEE de los cultivos bien irrigados es linealmente proporcional a la cantidad de radiación fotosintética activa absorbida por la vegetación, APAR, la cual se determina mediante el producto de PAR y la fracción absorbida, FAPAR. La formulación incorpora un factor de eficiencia de conversión de PAR, ϵ . Por tanto los modelos LUE tienen 3 parámetros básicos de entrada: PAR, FAPAR y ϵ .

PAR se mide en superficie y FAPAR también puede medirse directamente (Sims et al., 2005) o estimarse mediante teledetección (Bacour et al., 2006, Gobron et al., 2008). El creciente número de satélites que orbitan el planeta capaz de suministrar productos de cubierta vegetal constituye por tanto una potente herramienta para estimar NEE y GPP a escala global. Entre éstos destacan la utilización de imágenes AVHRR para derivar FAPAR. Este es el caso del modelo biosférico CASA, uno de los módulos del modelo de asimilación Carbontracker implementado a escala europea y global, el cual suministra entre otros parámetros de salida, los valores de NEE en una rejilla de $1^{\circ} \times 1^{\circ}$ (Peters et al., 2007, Peters et al., 2009). Los sensores MODIS (Moderate Resolution Imaging Spectroradiometer) de la NOAA y MERIS (Medium Resolution Imaging Spectrometer) de la ESA, suministran FAPAR con una resolución espacial variable entre 250 m y 1 km así como el valor de LAI, otro parámetro biofísico crucial para la descripción de la cubierta vegetal. El sensor MODIS, además, proporciona información directa de GPP o la fotosíntesis neta con una resolución temporal de 8-días. Sin embargo, los cálculos basados en la

teledetección requieren un riguroso proceso de calibración a partir de los resultados medidos en superficie (Gebremichael y Barros, 2006), aspecto particularmente crucial para obtener una estimación correcta del parámetro ε de un cultivo o ecosistema dado, para el cual los resultados publicados son muy contrastados.

De lo expuesto se concluye que el uso combinado de datos satelitales de FAPAR y medidas en superficie constituye un excelente procedimiento para determinar NEE y GPP en un ecosistema dado y calibrar el modelo LUE a partir de los datos medidos en superficie, objetivo principal del presente trabajo en el cultivo de colza, muy poco estudiado en la bibliografía.

2. FUNDAMENTOS

Entre los métodos micrometeorológicos utilizados para medir flujos de CO_2 destaca el método directo de correlaciones turbulentas o eddy covariance, EC. Este se basa en la suposición de que el valor de una magnitud medida, a , se puede expresar:

$$a = \bar{a} + a' \quad (1)$$

siendo \bar{a} el valor promedio y a' las fluctuaciones aleatorias que experimenta en el intervalo de tiempo de medidas. Estadísticamente dichas fluctuaciones en promedio son nulas ya que los valores negativos se compensan con los positivos.

Los flujos verticales de cualquier magnitud entre la vegetación y la atmósfera son proporcionales a las covarianzas, o valores medios de los productos de las fluctuaciones de dicho escalar a' y las fluctuaciones de la componente vertical de la velocidad de viento w' :

$$F = \overline{a'w'} \quad (2)$$

Según la magnitud considerada se tienen los flujos de energía, los flujos de materia y los flujos de cantidad de movimiento. En la temática que nos ocupa, los flujos de materia corresponden a la transferencia de las concentraciones de CO_2 y de

vapor de agua. Flujos positivos de CO₂ representan transferencia de energía y masa desde la vegetación a la atmósfera y flujos negativos desde la atmósfera a la vegetación.

Los flujos de energía o calor sensible, H, tienen como origen las fluctuaciones de la temperatura del aire, T'. Por tanto la covarianza viene dada por:

$$H = \rho_a c_p \overline{T'w'} \quad (3)$$

Los flujos de CO₂ y de vapor de agua, LE, corresponden a las covarianzas de las concentraciones de CO₂ y de vapor de agua:

$$NEE = \rho_a \overline{CO_2'w'} \quad (4)$$

$$LE = L_v \overline{\rho'w'} \quad (5)$$

y los flujos de cantidad de movimiento a las covarianzas de la velocidad de viento u':

$$\tau = \rho_a \overline{u'w'} \quad (6)$$

donde ρ_a , ρ_v y c_p representan la densidad del aire, del vapor de agua y el calor específico del aire respectivamente.

Por tanto todas las covarianzas o flujos se determinan a partir de las fluctuaciones de la magnitud implicada, la cual se obtiene restando el valor medio de las medidas realizadas durante un tiempo dado al valor instantáneo. La correcta caracterización de los remolinos o fluctuaciones aleatorias tiene 3 requerimientos: a) Utilizar instrumentación de respuesta rápida que sea capaz de realizar medidas en intervalos muy cortos de tiempo, típicamente 0.1 s para capturar todas las escalas de remolinos que se producen. b) Utilizar una escala de tiempo adecuada para establecer un valor promedio estadísticamente representativo, típicamente 30 minutos o 1 h. c) Que la turbulencia sea estacionaria.

Cuando la estratificación térmica de la atmósfera es muy estable o la turbulencia es muy débil, la materia que fluye desde la vegetación y el suelo a la

atmósfera puede hacerlo muy lentamente y no alcanzar el instrumento de medida en un tiempo suficientemente pequeño con respecto al tiempo en que se realiza el promedio. Estas condiciones violan las condiciones de estacionariedad y de flujos constantes en la capa superficial originando un almacenamiento en las capas de aire más bajas que debe añadirse a los flujos turbulentos para representar adecuadamente el balance de masa. Para el CO₂ el término de almacenamiento es pequeño en el caso de cultivos o cubiertas vegetales de escasa altura y sin embargo desempeña un papel mucho más importante en zonas arboladas especialmente si los árboles son altos. A pesar de ello este término es significativo a la salida y a la puesta del sol, momentos de transición entre la estratificación nocturna estable y el inicio de la turbulencia convectiva diurna y de la transición de la respiración a la fotosíntesis. Idealmente, las medidas de los flujos turbulentos requieren homogeneidad horizontal del terreno y homogeneidad de la cubierta vegetal en una cobertura horizontal de unas 100 veces la altura a la que se instala la instrumentación. Los terrenos llanos y con monocultivo cumplen muy bien estos requerimientos aportando resultados totalmente representativos.

3. DESCRIPCIÓN DEL LUGAR DE MEDIDAS

La parcela del cultivo de colza seleccionada se encuentra ubicada en el centro de la meseta castellana, tal y como se muestra en la Figura 2. Se trata de una explotación agraria privada de 1800 ha, Monte de Rocío, con diversos tipos de cultivos rotantes de secano e irrigados y en las que se aplican frecuentemente técnicas de mínimo laboreo, las cuales contribuyen en gran medida a reducir las emisiones de CO₂ por la respiración del suelo (Sánchez et al., 2002). Las parcelas son amplias y en concreto, la elegida de colza, tiene un excelente tamaño, 16 ha. Posee facilidades eléctricas en el centro de dicha parcela, lo que para el método de trabajo seguido resulta de gran utilidad. Este hecho unido a la horizontalidad del terreno propicia unas condiciones ideales para el uso de medidas micrometeorológicas que cuantifiquen los sumideros de CO₂ con elevada representatividad.



Figura 2. Localización de la parcela rotante de colza.

El ciclo de rotación comprende los cultivos siguientes, colza, trigo/cebada, guisantes, centeno y girasol. En lo que respecta al cultivo de colza, la siembra tiene lugar en la segunda quincena de septiembre y la cosecha a mediados de julio. Por tanto desde la siembra hasta el mes de febrero casi no hay cubierta vegetal y otro tanto sucede desde mediados de julio hasta mediados de octubre, si bien en este caso y debido a las prácticas de mínimo laboreo utilizadas, el suelo no queda desnudo conteniendo los restos de los tallos de la colza.

El clima de la región castellana es continental mediterráneo, caracterizado por inviernos largos y fríos y veranos cálidos. Las temperaturas máximas y mínimas tienen lugar en julio y enero, respectivamente. Las precipitaciones tienen un marcado carácter estacional con dos máximos, uno en primavera, abril y mayo, y el segundo en el otoño, octubre, noviembre o diciembre, según los años. Durante el verano, especialmente en julio y agosto, las precipitaciones son muy escasas. La precipitación media anual es aproximadamente 450 mm.

4. DATOS E INSTRUMENTACIÓN UTILIZADA

La mayor parte de la adquisición de datos estuvo operacional a primeros de marzo, lo que permitió hacer un seguimiento de la dinámica evolutiva del cultivo desde el principio del período de máximo interés hasta octubre, momento en el que se sembró cebada. La instrumentación utilizada es la que se describe a continuación.

4.1 Micrometeorológica y meteorológica

Los datos de NEE se han medido utilizando un sistema EC constituido por un analizador infrarrojo de respuesta rápida LI-7500 y un anemómetro sónico METEK USA-1. El conjunto operó con una frecuencia de 10 Hz y fue instalado en una pequeña torre de 3.5 m de altura. Los datos instantáneos se almacenaron en un datalogger de respuesta rápida Omni Drive Reader. Dichos valores fueron posteriormente procesados utilizando el software TK2 desarrollado por la Universidad de Baireuth (Alemania) obteniéndose valores promedio cada 30 minutos de los flujos de CO₂, NEE, vapor de agua, LE, calor sensible, H, y cantidad de movimiento. Dicho software incluye en el caso del CO₂ el término de almacenamiento. También incluye, entre otros, la corrección de Webb-Pearman-Leuning, imprescindible a aplicar a las medidas directas que suministran los equipos infrarrojos de lazo abierto, como es el caso del LI-7500.

Asimismo instalamos una segunda pequeña torre de 2.5 m de altura equipada con la instrumentación de respuesta lenta siguiente:

- Un sensor para la medida de radiación fotosintética activa, PAR, LI-190SZ Quantum Sensor.
- Un anemómetro y una veleta, Young.
- Un sonda para la medida de la temperatura del aire, T, y otra para la medida de la humedad relativa, STH/STA/SHA-5031.
- Un radiómetro neto para la medida de la radiación neta, R_N, Ph.Schenk.
- 1 sonda para la medida de la humedad del suelo, Hs, ThetaProbe. Ésta se situó a unos 10 cm de profundidad del suelo.

- 2 platos para la medida de los flujos del suelo, G, Hukseflux. Ambos se situaron a unos 2 cm del suelo, uno en zona de cubierta vegetal y el otro en el surco.

Todos los datos registrados por estos sensores fueron almacenados en otro datalogger, Meteodata 3000. Los datos instantáneos fueron de nuevo procesados para obtener valores promedio de cada variable cada 30 minutos.

La instrumentación anterior se completó con la instalación de una caseta provista de un ordenador con acceso a internet al cual los dos dataloggers transferían los datos de manera continua. Esta opción, que en definitiva significa duplicar el sistema de adquisición de datos, resultó de gran utilidad por dos razones: 1) minimizó el número de datos perdidos y 2) nos permitió acceder diariamente a los datos por control remoto desde la Facultad de Ciencias de la Universidad de Valladolid al ordenador allí instalado, identificar la presencia de fallos temporales casi en tiempo real y corregirlos. Los datos de las precipitaciones fueron adquiridos del Observatorio de Villanubla (AEMET) situado a unos 10 km de la explotación. La Figura 3 muestra la disposición de toda la instrumentación en la parcela.

Merece una atención destacada las unidades en las que se expresan los resultados de NEE, RE y GPP en la bibliografía y las que aquí se utilizarán. El equipo de medida de PAR está configurado para expresar los valores en $\mu\text{mol}/\text{m}^2\cdot\text{s}$. El factor de conversión a las unidades del SI, W/m^2 , utilizado ha sido 4.57 (Aber et al., 1996). Los flujos de CO_2 en la bibliografía se expresan como $\mu\text{mol}/(\text{m}^2\cdot\text{unidad de tiempo})$ o $\text{gC}/(\text{m}^2\cdot\text{unidad de tiempo})$, siendo la unidad de tiempo variable según los datos manejados, desde 30 minutos hasta 1 año. En este trabajo se han utilizado $\mu\text{mol}/(\text{m}^2\cdot\text{unidad de tiempo})$, para la mayor parte de los resultados y solamente se han considerado $\text{gC}/(\text{m}^2\cdot\text{unidad de tiempo})$ en los valores acumulados de NEE, GPP o RE, por considerar que le podrían resultar más familiares a un potencial lector interesado en las repercusiones socio-económicas de los resultados. Alternativamente los valores de gC pueden convertirse en gCO_2 , considerando los pesos moleculares

del C, 12 g/mol y de CO₂, 44 g/mol, sin más que multiplicar los primeros por el factor 3.67.



Figura 3. Instrumentación: Torre Eddy Covarianza, EC, izquierda y Torre meteorológica convencional, derecha.

4.2 Índice Foliar de la Vegetación

Las medidas en superficie de LAI se realizaron con un Analizador LAI-2000 Licor, equipo usualmente utilizado en experiencias de campo. Este equipo relaciona el LAI con la radiación debajo y encima del dosel vegetal a través de la Ley de Beer-Lambert:

$$Q_i = Q_0 \exp^{-K LAI} \quad (7)$$

donde Q_i y Q_0 son la radiación debajo y encima del dosel vegetal y K el coeficiente de extinción.

El sensor tiene 5 lentes concéntricas, cada una de las cuales recibe radiación de un sector anular del cielo centrado en los ángulos con la vertical 7°, 23°, 38°, 53° y 68°. Solo se detecta radiación de longitud de onda inferior a 490 nm, muy poco afectada por la vegetación. El uso de esta técnica tiene diversas limitaciones:

- No debe incidir radiación directa ya que en estas condiciones sobrevalora los resultados.
- El cielo tiene que ser uniforme, sin zonas brillantes, ya que las partes del dosel orientadas a zonas más brillantes podrían dar lugar a mayor transmisividad reduciendo el valor del LAI.
- Los cálculos del LAI admiten que la distribución de las hojas es aleatoria, extremo que generalmente no se cumple ya que las partes externas de la vegetación forman estructuras ordenadas que ocultan a las que están en el interior.

Para subsanar los dos primeros problemas, en el caso bastante habitual de que las medidas se realicen durante el día, el equipo dispone de diversos filtros para reducir la apertura de percepción de la luz según las condiciones atmosféricas. En lo que respecta al último, el software del equipo incluye un factor de “clumping”, FC, (Rambal et al., 2003) con valores variables según la cubierta vegetal que oscilan entre 1.3 y 1.6, de forma que el valor final que suministra es el LAI efectivo o producto del LAI por FC. Los valores que suministra el equipo son válidos para el LAI de la cubierta vegetal verde ya que cuando ésta está seca, la radiación también se atenúa a su paso por el dosel vegetal aportando valores irrealmente altos.

Las medidas se han realizado siguiendo el protocolo usual. Tras elegir un transecto y 10 puntos de medida a lo largo del mismo en cada uno de ellos se realizaron medidas secuenciales, 1 encima, 4 debajo, 1 encima y 4 debajo del dosel vegetal. Las medidas se hicieron de día y cuando el cielo estuvo totalmente despejado utilizamos los filtros adecuados a la situación atmosférica. Asimismo todas ellas se realizaron transversalmente a los surcos para tener en cuenta la realidad del terreno constituido por la vegetación y los surcos del cultivo. Con ello hemos buscado la obtención de los valores de LAI más realistas.

Las medidas comenzaron a mediados en febrero y se prolongaron hasta la senescencia de la vegetación. En general se realizó una medida semanal y durante el período de entallado, que es la etapa fenológica en la que se producen mayores cambios, se realizaron dos medidas semanales. Durante cada una de ellas se midió concurrentemente la altura del cultivo.

4.3 Imágenes satelitales

Los datos satelitales utilizados corresponden a los suministrados por el sensor americano MODIS Terra y el sensor MERIS de la Agencia Europea ESA a bordo de Envisat. Los primeros son de libre disposición y la adquisición de los segundos se ha realizado gratuitamente en el marco de un proyecto CAT-1 presentado y aprobado por la ESA. Los dos sensores suministran, entre otros muchos productos, los parámetros biofísicos de FAPAR y LAI (efectivo) con una resolución espacial de aproximadamente 1 km. El sensor MODIS suministra además los valores del conocido índice de vegetación NDVI y de la GPP. Todos los productos MODIS corresponden a compuestos de 8-días mientras que el sensor MERIS proporciona una imagen diaria cuando sobrevuela el lugar de medida. Para homologar las dos escalas de tiempo diferentes, en este trabajo se han considerado los compuestos de 8 días promediando en el segundo caso los valores de las imágenes MERIS disponibles durante el período concurrente con los del sensor MODIS. El procesado y extracción de datos en cada píxel de 1 km se ha realizado en el caso del MODIS directamente descargando las imágenes y aplicando los criterios de calidad impuestos y en el caso del MERIS con el software BEAM- VISAT de libre disposición utilizando el procesador TOCVEG.

De la amplia información espacial que suministran las imágenes, aquí hemos usado la extraída en el píxel centrado en la parcela y en los 8 circundantes, los 3 superiores, los 2 adyacentes y los 3 inferiores. La construcción de los compuestos de 8 días de los parámetros biofísicos que proporciona el sensor MERIS se ha realizado

analizando con detalle la consistencia de los resultados de cada una de las imágenes diarias disponibles, eliminando anomalías obvias entre datos adyacentes, las cuales se han atribuido a la escasa calidad de los datos en presencia de nubes. La ausencia de datos satelitales en el píxel central se ha suplido mediante interpolación de los datos del compuesto anterior y posterior, y en algún caso, por el promedio de los valores de los 9 píxeles o del adyacente disponible más afín en comportamiento al central. Las imágenes descargadas y procesadas corresponden al ciclo anual completo de la colza, octubre-octubre.

5. CONTROL DE CALIDAD DE LOS DATOS. RELLENO DE HUECOS

La adquisición de una amplia base datos como es la que nos ocupa, hace inevitable la presencia de huecos debido a diversas circunstancias, fallos eléctricos, fallos temporales de la instrumentación o presencia de fenómenos meteorológicos severos (tormentas, precipitaciones intensas, en forma de agua o de nieve, etc). A las anteriores hay que añadir las que surgen imprevistamente en el campo, debido a la presencia de aves o animales, los cuales originan desperfectos en las cúpulas de los radiómetros, cables o simplemente remueven del suelo las sondas de medida instaladas. En lo que respecta a las medidas de flujos, los anemómetros sónicos son muy robustos por lo que la pérdida de datos de los flujos de calor sensible es generalmente baja. No ocurre así con la instrumentación de lazo abierto LI-7500, que a pesar de tener una tecnología avanzada, es muy sensible a las precipitaciones. Cuando éstas ocurren suministra datos anómalos que hay que descartar. Otra fuente de error, inherente al uso de los métodos micrometeorológicos, es la baja o nula turbulencia mecánica, representada a través de la velocidad de fricción, u_f ($\overline{u'w'}^{1/2}$). Valores bajos de este parámetro conducen a datos de baja calidad, especialmente durante la noche, que es cuando dichos valores son inferiores debido a la prevalencia de estratificación estable. Este hecho es muy frecuente en la meseta castellana donde las inversiones nocturnas son muy profundas debido a su aridez, hasta 7.5°C/100 m, y

las condiciones de estancamiento atmosférico conducen con elevada frecuencia a valores de u_f muy bajas.

La ausencia de datos y la eliminación de los de baja calidad conducen a la necesidad de rellenarlos para aportar valores anuales de NEE o GPP que describan la capacidad de un ecosistema como sumidero de CO_2 . En este trabajo se han aplicado los procedimientos siguientes:

- Se han eliminado todos los datos nocturnos con velocidad de fricción u_f inferior a 0.15 m/s.
- Se ha rellenado los datos diurnos ausentes utilizando las ecuaciones de los ajustes de la respuesta a la luz, las ecuaciones de Michaelis-Menten (véase más adelante) obtenidas con los datos de NEE correspondientes a períodos de 15 días exceptuando septiembre y octubre durante los cuales dichas ecuaciones proporcionaron resultados muy pobres.
- Para períodos de tiempo más largos, desde la siembra en octubre hasta febrero, los huecos se han rellenado utilizando los resultados de los ajustes lineales de los compuestos de 8 días de NEE y de GPP en función del producto LAI suministrado por MODIS y MERIS.
- Los datos meteorológicos del período octubre-febrero fueron tomados de otra estación situada en el CIBA, Centro de Investigación de la Baja Atmósfera, situada a unos 10 km de la explotación agraria y donde el grupo investigador tienen otra estación EC. Dichos valores son muy representativos con los registrados en la parcela considerando la escasa distancia entre ambos emplazamientos y la homogeneidad del terreno, como de hecho hemos corroborado inter-comparando los datos de las dos estaciones.

6. ESTIMACIÓN DE LA GPP A PARTIR DE IMÁGENES SATELITALES

Los compuestos de GPP de 8-d han sido calculados utilizando la siguiente ecuación:

$$GPP_{8d} = \varepsilon \cdot APAR \quad (8)$$

donde APAR ha sido determinada a partir de los datos satelitales de FAPAR suministradas por los sensores MERIS de la ESA y MODIS de la NOAA y medidas directas de PAR realizadas en superficie.

$$APAR = PAR \cdot FAPAR \quad (9)$$

El aspecto crucial de esta formulación es el parámetro ε el cual depende del tipo de ecosistema y de las condiciones climáticas. El déficit de presión de vapor, común en zonas semi-áridas durante el período de crecimiento vegetativo, favorece el cierre de los estomas limitando la absorción fotosintética (Running et al., 2000). Durante el período en el que no hay crecimiento vegetativo, y especialmente en el que las temperaturas son bajas, la vitalidad de las plantas también se reduce dando lugar a una drástica disminución de NEE, GPP y de RE. Por ello para estimar el valor de ε de un ecosistema dado la forma habitual de proceder es considerar que este parámetro es función de un valor óptimo, ε_{max} , y de un escalar f , cuyos valores oscilan entre 0 y 1, que tenga en cuenta la influencia de los factores climáticos de la forma siguiente:

$$\varepsilon = \varepsilon_{max} \cdot f \quad (10)$$

Los valores de ε_{max} difieren considerablemente dependiendo de la formulación de los modelos LUE. Por ejemplo, los valores por defecto que utiliza el MODIS para 11 tipos de ecosistemas varían entre 0.604 y 1.259 gC/MJ (Running et al., 1999) mientras que el modelo C-fijo (Veroustraete et al., 2002) utiliza un valor constante para todos los ecosistemas, 1.1 gC/MJ. La formulación de los modelos LUE también difiere en la forma de definir el escalar f . Así, el algoritmo MODIS considera una combinación multiplicativa de dos factores, el déficit de presión de vapor, D , y la temperatura, T , cada uno de los cuales varía de 0 a 1 (Leuning et al., 2005). El

primero, se basa en el hecho de que elevados valores, típicamente superiores a 20 hPa, favorecen el cierre estomático, especialmente en cultivos no irrigados y el segundo se fundamenta en que las altas temperaturas favorecen el estrés hídrico. Sin embargo, algunos autores han argumentado que D no siempre describe adecuadamente la disponibilidad de agua de las plantas (Coops et al., 2007) por lo que otros modelos (Yuan et al., 2007) consideran la fracción evaporativa, EF , definida:

$$EF = \frac{LE}{LE+H} \quad (11)$$

donde H y LE son el calor sensible y el calor latente, respectivamente, medidos por el sistema EC. Valores bajos de EF , habitualmente asociados a valores bajos de calor latente, implican presencia de estrés hídrico y valores altos, suficiente disponibilidad de agua. La inclusión de EF como factor limitante de las condiciones óptimas de la vegetación presenta la ventaja adicional de que puede determinarse no sólo a partir de las observaciones en superficie sino mediante teledetección usando la información suministrada por diversos sensores, como por ejemplo AVHRR, MODIS (Venturini et al., 2008) y AATSR de la ESA. Esta última aplicación se ha implementado recientemente utilizando un elaborado algoritmo, SEBS, basado en la parametrización de la capa superficial/capa planetaria (Rauwerda et al., 2002, Wang et al., 2008). Dicho algoritmo también procesa los flujos de calor sensible, calor latente, radiación neta y flujos de calor del suelo por lo que es particularmente útil para la estimación del balance de energía. Algunos términos del algoritmo SEBS han sido evaluados a partir de medidas en superficie (Sobrino y Soria, 2003). Otros autores han propuesto incluir en el parámetro f un tercer término multiplicativo que incluya la fenología de la vegetación (Xioa et al., 2005, Li et al., 2007),

En este trabajo hemos seleccionado el producto de este factor, EF , y un segundo de la temperatura, T_s :

$$\varepsilon = \varepsilon_{max} \cdot f(T_s, EF) \quad (12)$$

donde T_s viene dado por:

$$T_s = \frac{(T - T_{min})(T - T_{max})}{[(T - T_{min})(T - T_{max})] - (T - T_{opt})^2} \quad (13)$$

siendo T la temperatura del aire y T_{min} , T_{max} y T_{opt} , las temperaturas máxima, mínima y óptima. Los valores de la T_{min} y la T_{max} considerados han sido 0 y 36 °C. Para la T_{opt} hemos seguido el mismo criterio que el utilizado en Albergel et al. (2010), considerando que la temperatura a la que se alcanza la máxima eficiencia corresponde a los valores de GPP máxima, obteniéndose 18 °C. Este valor es ligeramente inferior al descrito por otros autores los cuales han variado desde 22 °C en un cultivo de trigo (Patel et al., 2010) a 20.3° para diversas cubiertas vegetales (Yuan et al., 2007).

Con estas premisas hemos calculado los compuestos de GPP de 8 días mediante la expresión siguiente:

$$GPP_{8d} = \varepsilon \cdot EF \cdot T_s \cdot PAR \cdot FAPAR = \varepsilon_{max} GPP_{PAR} \quad (14)$$

Los datos de GPP de 8 días se han obtenido a partir de la diferencia entre los valores del término de respiración, RE, y NEE directamente medidos en superficie con el sistema EC:

$$GPP_{8d} = RE_{8d} - NEE_{8d} \quad (15)$$

Todos los compuestos de 8 días se han calculado promediando los datos de 30 minutos obtenidos durante esos días, que a su vez, se han seleccionado concurrentemente con los compuestos satelitales. En el caso de la respiración, RE, se

han parametrizado los datos semi-horarios nocturnos, que es cuando la vegetación sólo respira, utilizando la ecuación de Vant'Hoff modificada, incluyendo la humedad del suelo, H_s :

$$RE = a H_s e^{-bT} \quad (16)$$

siendo a y b dos parámetros ajustables cuyos valores se han obtenido utilizando el algoritmo de Marquardt. Los datos seleccionados corresponden a los de NEE registrados cuando la velocidad de fricción fue superior a 0.15 m/s. La ecuación obtenida se ha aplicado al cálculo de la respiración diurna considerando las temperaturas y la humedad del suelo diurnas registradas cada 30 minutos.

Finalmente el parámetro ϵ_{\max} se ha obtenido mediante un ajuste de regresión lineal entre los compuestos de GPP_{8d} observados y GPP_{PAR} (véase la Ec. 14). De dicha ecuación se desprende que ϵ_{\max} corresponde a la pendiente de dicho ajuste.

7. RESULTADOS

7.1 Características meteorológicas generales durante el periodo de medidas

Durante el período de estudio la temperatura media fue 10.2 °C y los valores extremos oscilaron entre -8.7 y 35.4 °C produciéndose durante los meses de Diciembre y Julio, respectivamente. Los promedios mensuales, representados en la Figura 4, siguieron la típica evolución estacional, registrándose los valores inferiores en diciembre, 2.9 °C, y los más altos en agosto, 19.2 °C. La precipitación acumulada fue 457.6 mm, ligeramente más alta que la media histórica, registrándose casi un 50% del total anual durante los meses de abril y mayo. Este último mes fue particularmente lluvioso, se registraron 129.4 mm, hubo nubes frecuentemente, hecho que fue corroborado a través de la observación de las imágenes satelitales y de las medidas de PAR en superficie, mostrados en la Figura 5. Los valores

representados corresponden a los promedios diarios, con valores de PAR>0, y como puede apreciarse, rompieron la tendencia creciente que típicamente se produce en la zona de estudio descendiendo en promedio unos 100 $\mu\text{mol}/\text{m}^2\cdot\text{s}$ con respecto a dicha tendencia.




Figura 4. Distribución anual de precipitaciones y de la temperatura durante el ciclo completo de colza.




Figura 5. Evolución anual de PAR durante el ciclo completo de colza. Los datos mostrados corresponden a los valores promedio diarios, PAR>0.

Durante el período de medidas los vientos fueron moderados, el valor medio de la velocidad de viento fue 3.3 m/s, y los valores extremos oscilaron entre 0 y 19.5 m/s. Las direcciones de viento dominantes fueron de componente NE-ENE y SW-WSW, orientación propiciada por la orografía del terreno en esta zona de la meseta, donde existen dos pequeños valles fluviales que se extienden desde el noreste al suroeste.

7.2 Balance y distribución de la energía disponible

La ecuación de balance de energía de la superficie de un sistema formado por la vegetación, el suelo y la atmósfera que los rodea, viene dada por la expresión:

$$R_N = H + LE + G + S + A + Q \quad (17)$$

donde R_N representa la radiación neta, S el calor almacenado en el suelo y biomasa, A la energía utilizada en la fotosíntesis y Q la energía advectiva. De los términos anteriores no hemos considerado los términos S ni A ya que su aportación representa un 2 o un 3% de la radiación solar neta (Sobrino et al., 2000) y la contribución de Q también se suele considerar despreciable. Por tanto los flujos de energía principalmente implicados son H y LE , medidos con la instrumentación EC y G medido directamente con los platos de flujos térmicos, los cuales corresponden a los valores promedios medidos en el surco y en la vegetación.

El cierre total del balance de energía significa que los valores de R_N deben ser idénticos a la suma aportada por H , LE y G . Sin embargo en la práctica esto raramente ocurre debido, entre otras razones, a errores experimentales en la medida de cada uno de los términos implicados. Por ello, la medida del grado de cumplimiento del principio de conservación de la energía o cierre del balance energético, es indicativa de la calidad de los datos, especialmente los adquiridos mediante la técnica EC, que es precisamente la que suministra los flujos de CO_2 . Por otra parte la participación de cada término a la energía total disponible, R_N , medida directamente mediante un radiómetro neto, es importante desde un punto de vista conceptual ya que permiten caracterizar el comportamiento de un ecosistema.

Porcentajes altos de calor sensible y calor del suelo, típicos de los suelos áridos, implican bajos porcentajes de LE, una buena parte de la cual corresponde a la producida mediante el proceso de evapotranspiración de las plantas y cultivos. Escasa evapotranspiración, especialmente en los cultivos en estado vegetativo, está generalmente vinculada al cierre estomático, lo que a su vez se traduce en una limitación de la absorción fotosintética.

Para valorar el grado de cumplimiento del cierre del balance de energía, y en definitiva, disponer de una medida de la calidad de los datos, hemos realizado un ajuste de regresión lineal de la suma de los tres términos del segundo miembro de la Ec. 17, en función de las medidas directas de R_N . Los resultados obtenidos se muestran en la Figura 6. El coeficiente de determinación del ajuste, R^2 , fue 96.1%, reflejando una buena coincidencia entre los valores semi-horarios del primer y segundo miembro de dicha ecuación. La ordenada en el origen fue prácticamente cero, -0.25 W/m^2 y la pendiente 0.91, lo que implica un cierre en el balance de energía del 91%. Este resultado es bastante satisfactorio, especialmente cuando se compara con los reportados en otros ecosistemas y redes internacionales, como por ejemplo la red internacional FLUXNET en las que el balance de energía en algunos emplazamientos fue tan solo del 50% (Wilson et al., 2002).

En lo que respecta a la distribución de los tres términos considerados, mostrada en la Figura 7, el 52.5% correspondió a LE, un 38.5% al calor sensible, H, y por último un 9.0% a los flujos del suelo G (evaluados sobre 100%). El resultado más notable se refiere a la elevada participación del calor latente en el balance energético, poniendo de manifiesto la alta evapotranspiración del cultivo de colza. Estos resultados contrastan con los obtenidos en una cubierta vegetal arbustiva rala situada en el CIBA, a unos 10 km de esta explotación, donde la participación de los tres términos invierten este patrón, presentándose como términos dominantes H y G, con una contribución aditiva del 66.6% en detrimento del calor latente, cuya aportación es 33.4%.




Figura 6. Ajuste lineal de la suma del calor sensible H, calor latente LE, y calor del suelo G, en función de R_N . La lineal central corresponde al ajuste lineal y las externas al nivel de significación al 95%.

Cada uno de los tres términos siguió una evolución horaria similar. Los valores promedio más altos de H, LE y G tuvieron lugar a las 11-12 h (hora solar), siendo los valores máximos semi-horarios 475.4, 539.2 y 255.0 W/m^2 , respectivamente. Durante el período de máximo interés, las medidas suministradas por la sonda de medida de flujos enterrada en la vegetación fue 0.78 veces inferior a la obtenida en el surco, poniendo de manifiesto la influencia de la cubierta vegetal sobre dichos valores.




Figura 7. Distribución de la energía disponible en forma de calor latente, calor sensible y flujo de calor del suelo.

7.3 Evolución fenológica de la vegetación

La Figura 8 muestra la evolución de la altura de la vegetación y de LAI medido en superficie. Como ya indicamos, y dado que el radiómetro LI-2000 mide el LAI de la vegetación verde, sólo hemos representado los valores obtenidos hasta finales de mayo, cuando se inició la senescencia de la colza y los resultados experimentales de LAI no fueron fidedignos.




Figura 8. Evolución de la altura de la colza medida en superficie.

Las primeras medidas comenzaron a realizarse en la fase inicial de formación de la roseta, presentando una altura media de 5 cm el 12 de febrero. Desde ese momento la colza comenzó a desarrollarse y crecer progresivamente alcanzando una altura de 30 cm a finales de marzo. A principios de abril comenzó la floración y el período de entallado ascendiendo muy rápidamente la altura y alcanzando a finales del mismo 105 cm, lo que representa un 80% de la altura final, 130 cm. Durante la segunda semana de mayo comenzó a aparecer la senescencia basal y la altura se mantuvo ya casi constante. El 20 de mayo prácticamente había concluido la floración dando paso a la aparición de las silicuas. Del 20 al 26 de junio la colza entró en el período total de senescencia, hecho observado visualmente por el amarilleo de las

hojas y corroborado por la evolución de los parámetros biofísicos y de las medidas in situ.

Las observaciones del LAI medido en superficie, y mostradas en la Figura 9, fueron consistentes con la evolución de la altura de la colza. La línea continua muestra la tendencia ajustada a una dependencia polinómica de 2º orden, la cual aportó resultados satisfactorios. Su representación persigue principalmente clarificar los principales rasgos evolutivos. Los valores de LAI oscilaron entre 0.1 el 12 de febrero hasta 2.6, valor alcanzado a finales de abril. A finales de mayo comenzaron a descender de nuevo. El valor máximo obtenido indica que, a pesar de la estructura foliar de la colza, los valores máximos son similares a los reportados en la bibliografía para los cereales no irrigados en zonas áridas y medidas del grupo investigador en trigo en otras áreas agrícolas de la meseta. Este resultado, a priori algo inesperado, podría atribuirse a la reducción de la densidad de masa foliar debido al amplio espaciado del surco que se emplea en la siembra. La evolución temporal fue acorde al crecimiento de la vegetación. La ligera disminución respecto a la tendencia general de los datos observada en la primera quincena de abril, es consistente con el rápido aumento de la altura en el período de entallado, durante el cual la densidad de la masa foliar evidentemente disminuye.

Para analizar la consistencia de los datos de LAI medidos en superficie y los satelitales hemos realizado un ajuste de regresión lineal entre las dos series de datos, cuyos resultados se muestran en la Figura 10. Los valores representados corresponden a compuestos de 8-días del sensor MODIS.

El ajuste de regresión lineal fue muy satisfactorio, $R^2=92.7\%$, mostrando las dos series de datos un buen acuerdo. La ordenada en el origen, fue próxima a cero, -0.22, y la pendiente 1.37. Este último resultado revela que el LAI medido por el sensor MODIS infravalora el valor real substancialmente, un 37%, resultado directamente derivable de la observación de la Figura a través de la desviación de la recta ajustada respecto al ajuste perfecto o pendiente unidad. La comparación con el

LAI aportado por MERIS arrojó resultados similares infravalorando los resultados experimentales un 19%.




Figura 9. Evolución del LAI efectivo medido en superficie.


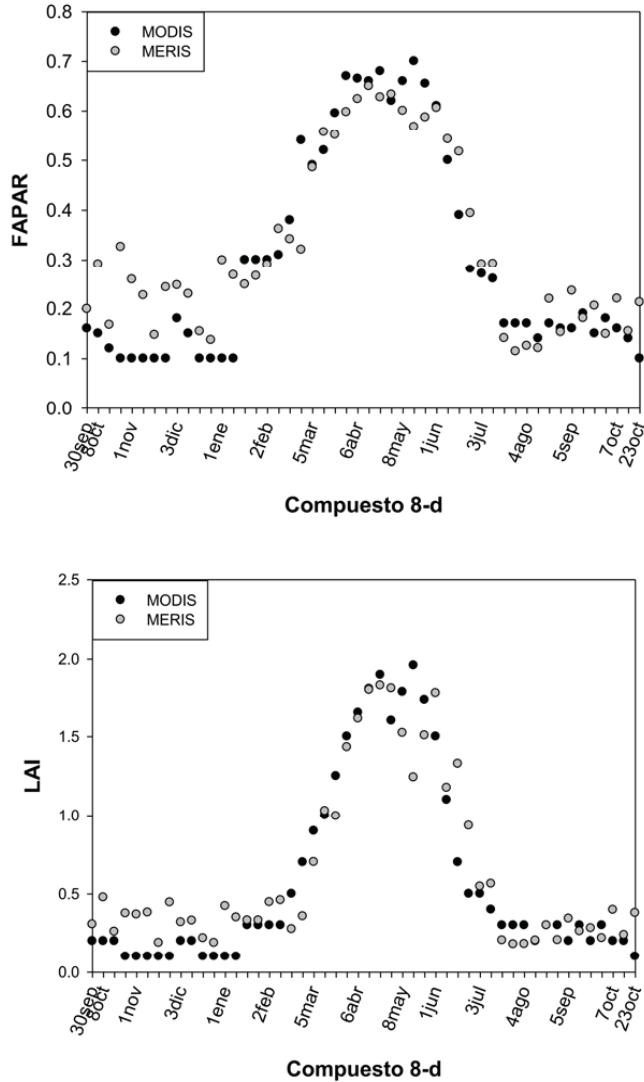


Figura 10. Comparación entre el LAI medido en superficie y el LAI suministrado por el sensor MODIS. Las líneas discontinuas corresponden a los valores de nivel de predicción y de confianza respectivamente, al 95% de nivel de significación.

7.4 LAI y FAPAR satelitales

Las Figuras 11a y 11b muestran la evolución de los compuestos de 8 días de FAPAR y de LAI del sensor MODIS y MERIS en el píxel central durante el ciclo completo.



Figuras 11 a- b. Evolución de los compuestos de 8 días de FAPAR y LAI suministrados por los sensores MODIS y MERIS durante el ciclo completo.

De su observación se desprende la similitud tanto en los valores como en la variación estacional. Los ajustes de regresión lineal para FAPAR y LAI del sensor MODIS frente al sensor MERIS aportaron valores de R^2 satisfactorios, 84.9 y 86.3%, ordenadas en el origen próximas a cero, -0.06 y -0.08 y pendientes próximas a la unidad, 1.12 y 1.05, respectivamente. De este último resultado se desprende que el sensor MODIS sobreestima ligeramente los dos parámetros biofísicos respecto al sensor MERIS. Los valores tan constantes de LAI aportados por MODIS durante el invierno se deben a su escasa variabilidad y a que dicho sensor suministra este dato con una sola cifra decimal. Cabe señalar también que las mayores discrepancias tanto de LAI como para FAPAR se obtuvieron durante los meses de octubre e invierno, siendo sensiblemente superiores para MERIS. Las dos Figuras muestran el aumento progresivo de FAPAR desde marzo hasta el mes de mayo y su posterior disminución durante el verano, el otoño y el invierno. Los valores máximos de FAPAR fueron 0.70 y 0.65 para el sensor MODIS y MERIS y los mínimos 0.10 y 0.11. Los máximos y mínimos del LAI fueron 1.96, 1.82 y 0.10, 0.18, respectivamente. Los valores máximos de los dos parámetros biofísicos estuvieron dentro del orden de magnitud de los descritos en la bibliografía para cultivos (Weiss et al., 2007).

Los valores máximos de dichos parámetros se produjeron a mediados de mayo según MODIS y a finales de abril para MERIS. Estas discrepancias hay que atribuir las a la presencia de nubes en el mes de mayo, condiciones, que como hemos apuntado, conducen a resultados satelitales de peor calidad a pesar de los algoritmos empleados para la máscara de nubes. De hecho durante el mes de mayo se produjeron diversos huecos en el píxel central que hubo que rellenar mediante interpolación de los datos adyacentes o el valor en otro píxel adyacente.

7.5 Evolución de la NEE

La Figura 12 muestra la evolución de la NEE diaria durante el período marzo-octubre. De su observación se desprende la marcada evolución estacional acorde con el ciclo de crecimiento vegetativo de los cultivos. Los valores negativos de NEE aumentan progresivamente desde marzo hasta mediados de junio, revelando la

capacidad del cultivo como sumidero de CO₂. A partir de esa fecha y coincidiendo con el inicio del período de senescencia, comienzan a disminuir, alcanzando los valores mínimos a finales de julio, que aún siguieron siendo negativos. La alternancia de valores positivos y negativos durante los meses de agosto y septiembre revelan que el cultivo comienza a actuar como fuente emisora de CO₂ prevaleciendo los procesos de respiración frente a los de absorción fotosintética. En el mes de octubre los procesos de respiración fueron ya dominantes. El valor medio de los valores diarios de NEE durante este periodo fue -1.89 μmol/m².s y los valores extremos 3.70 y -8.52 μmol/m².s, respectivamente. La observación de la Figura muestra la presencia de una elevada variabilidad diaria, reflejando la influencia de las condiciones meteorológicas sobre los flujos de CO₂.




Figura 12. Evolución de NEE durante el período de medidas. Los datos corresponden a los promedios diarios.

Durante el período de máximo interés, marzo-junio, el valor acumulado de NEE fue -554.2 gC/m², durante el período de medidas -487.6 gC/m² y durante el ciclo completo -356.5 gC/m², habiendo rellenado los datos desde octubre hasta febrero a partir del ajuste lineal de los compuestos de 8 días de NEE con los compuestos de LAI de 8 días suministrados por MODIS, el cual dio un resultado muy satisfactorio, R²=91.7%. Los resultados con el sensor MERIS fueron superiores, -446.4 gC/m²

hecho atribuible a las discrepancias entre los dos sensores durante los meses de otoño e invierno, como ya apuntamos anteriormente. En cualquier caso los valores acumulados obtenidos son más elevados que los reportados para cereales convencionales (Anthoni et al., 2004) e incluso de masas arboladas mediterráneas, *Quercus Ilex* (Allard et al., 2008).

7.6 Respiración del cultivo

La Figura 13 muestra la evolución de la respiración diaria, suma de la diurna y nocturna, durante el período de medidas. La inspección de dicha Figura muestra una evolución estacional similar a la de NEE, caracterizada por una tendencia creciente desde marzo hasta junio seguida de una disminución durante el verano, en julio y en agosto. También muestra su gran variabilidad diaria. Sin embargo contiene algunas peculiaridades. La primera es la presencia de algunos picos en mayo y otro más llamativo a mitad de agosto. Éstos probablemente se produjeron en presencia de precipitaciones, hecho constatado por el aumento de la humedad del suelo medida en la parcela. Sin embargo los aumentos de la humedad del suelo observados no siempre estuvieron acompañados por las precipitaciones registradas en el Observatorio de Villanubla. La falta de sintonía entre los aumentos de la humedad del suelo medidos en la parcela y la ausencia de precipitaciones en dicho observatorio, o viceversa, podrían ser debida al carácter local que tienen los chaparrones, especialmente en verano.

Otro aspecto a destacar es el aumento de los valores de la respiración durante la segunda y tercera semana de junio, alcanzándose valores comparables e incluso superiores al mes de mayo a pesar del inicio de la senescencia. Durante la segunda y tercera semana de junio llovieron 5 días, registrándose valores acumulados de 9.7 y 6.9 mm respectivamente, que de nuevo el sensor de humedad del suelo de la parcela sólo acusó eventos de escasa entidad del 15 al 17 de junio. Por ello, los altos valores de la respiración cabe atribuirlos a los costes de mantenimiento implicados durante la etapa de maduración de las silicuas.




Figura 13. Evolución de la respiración durante el período de medidas. Los datos representados corresponden a los promedios diarios.

En cualquier caso los resultados obtenidos indican la importante contribución de la colza a los procesos de respiración, los cuales se mantienen bastante activos con un retraso respecto a los máximos de NEE de aproximadamente 15 días. Finalmente los valores superiores de RE registrados especialmente en octubre cabe atribuirlos a la presencia estacional de las precipitaciones y a las temperaturas más suaves que se registran durante este mes, factores que favorecen el aumento de la vitalidad de la vegetación. El valor promedio de RE fue $3.91 \mu\text{mol}/\text{m}^2.\text{s}$ y los valores extremos 9.13 y $0.71 \mu\text{mol}/\text{m}^2.\text{s}$. El valor acumulado durante el período de máximo interés fue $644.9 \text{ gC}/\text{m}^2$ y durante el período total de medidas $996.2 \text{ gC}/\text{m}^2$.

7.7 Ciclo diario. Influencia de la radiación fotosintética activa, PAR

La Figura 14 muestra la evolución diaria de los valores semi-horarios de NEE durante el período de medida, marzo y octubre, en un diagrama de cajas y bigotes. Cada caja muestra la distribución estadística de los valores de NEE. La altura de cada caja refleja la dispersión de los datos de NEE en cada una de las horas. La barra horizontal refleja la mediana y la cruz la media, respectivamente. Las barras verticales o bigotes, se refieren a los valores del percentil 25 y 75, respectivamente, y por último, los puntos aislados superiores o inferiores muestran valores

anómalamente altos o bajos que, aún siendo correctos, se desvían de la distribución estadística que sigue la mayor parte de los datos. A efectos comparativos mostramos la evolución concurrente de PAR en la Figura 15.




Figura 14. Evolución de NEE a lo largo del día durante el período de medidas.




Figura 15. Evolución horaria de PAR durante el período de medidas.

Como se deduce de la observación de la Figura 14, durante el período nocturno, desde las 0 hasta la 5 h y desde las 17 hasta las 23, los flujos positivos revelan la presencia de respiración de la vegetación. Inversamente, los valores





negativos durante el período diurno, muestran cómo la vegetación absorbe CO₂. Los valores máximos se obtuvieron en torno a las 12 de la mañana, que es cuando se produce la máxima solar incidente, o lo que es equivalente de PAR (véase la Figura 15). La Figura 14, también revela la gran variabilidad de los valores de NEE obtenidos a lo largo del día. La similitud de las dos Figuras pone de manifiesto, aunque sea de forma cualitativa, la importante influencia que ejercen las variables meteorológicas y en particular la radiación fotosintética activa, parámetro dominante regulador de la fotosíntesis y por tanto de la absorción de CO₂ por la vegetación (Pingintha et al., 2009). Para analizar la respuesta de NEE a los cambios de PAR, hemos utilizado las ecuaciones no lineales propuestas por Michaelis-Menten, ya que son las usuales en este tipo de estudios:

$$NEE = \frac{NEE_{max}PAR}{PAR+K_{50}} + RE \quad (18)$$

donde NEE_{max} es la capacidad máxima fotosintética potencial y K₅₀ es la constante de Michaelis-Menten que representa el valor de PAR para el que la tasa fotosintética alcanza el 50% de su valor máximo, estando definido:

$$K_{50} = -\frac{NEE_{max}}{\alpha} \quad (19)$$

donde α es la eficiencia cuántica, una medida de la eficiencia inicial de la vegetación en el uso de la radiación. Para valores de PAR nulos, es decir durante la noche, los datos de NEE corresponden a la respiración nocturna, RE. Dado que NEE y PAR son directamente medidos en superficie, la Ec. 18 contiene tres parámetros ajustables, NEE_{max}, K₅₀ o α y RE, que pueden obtenerse mediante ajustes no lineales de los valores semi-horarios de NEE en función de PAR utilizando paquetes estadísticos convencionales. Estos valores son muy variables dependiendo del tipo de cultivo y de las condiciones climáticas de los ecosistemas. Las Figuras 16 a-d muestran los resultados de los ajustes para algunos meses del año seleccionados. Los resultados de la eficiencia cuántica, α , y R², NEE_{max} y RE obtenidos para cada período de 15 días se muestran en las Figuras 17 y 18.



Figuras 16 a-d. Ajustes de la NEE semi-horaria en función de PAR.

El valor medio de α durante el período marzo-junio fue, $-0.0477 \mu\text{mol/mol}$, o lo que es equivalente, -2.646 gC/MJ utilizando la aproximación de Prince y Goward (1995), para las plantas C3 a la que pertenece la colza. Dicho valor según los citados autores constituye una manera alternativa de definir el valor de ε_{max} .




Figura 17. Evolución quincenal de la eficiencia cuántica α y R^2 de los ajustes de Michaelis-Menten.

Los valores de R^2 de los ajustes quincenales fueron muy satisfactorios exceptuando septiembre y octubre, que arrojaron valores muy pobres, oscilando entre 86.7% en la primera quincena de junio y 48.0% en la segunda de julio. En lo que respecta a NEE_{max} los valores aumentaron progresivamente desde marzo hasta mayo alcanzando los valores negativos más altos durante la segunda quincena de mayo, que fue el período más activo de la colza como sumidero de CO_2 . El comportamiento de RE fue similar, si bien la Figura 8 revela con claridad el desfase en unos 7-15 días de los máximos valores respecto a NEE_{max} , - los valores máximos se alcanzaron durante la primera quincena de junio y durante la segunda los valores fueron similares a la segunda quincena de abril-. Este resultado está en conformidad con los ya mencionados anteriormente y atribuidos al coste de mantenimiento de los procesos de respiración durante la formación de las silicuas.




Figura 18. Evolución quincenal de NEE_{max} y RE de los ajustes de Michaelis-Menten.

7.8 GPP

La Figura 19 muestra la evolución de los compuestos de 8 días de EF, T_s y f durante el período de medidas. Los valores de EF experimentaron la variación estacional esperada alcanzando los valores más altos durante abril, mayo y junio y los inferiores durante el período central del verano. Los valores extremos fueron 0.76 en la tercera semana de junio y 0.10 en la primera de agosto; durante este mes y la mayor parte del mes de septiembre los valores se mantuvieron inferiores a 0.21. Los bajos valores de EF durante el verano, desde mediados de julio, son consecuencia de la baja evapotranspiración, LE, tras la cosecha y la casi total ausencia de lluvias así como a los altos valores de H debido a la escasa cubierta vegetal y las elevadas temperaturas. En lo que respecta al término T_s los valores fueron mucho menos contrastados y próximos a la unidad, con valores máximos y mínimos de 0.75 y 0.99. De aquí se desprende el importante papel que desempeña EF en el factor f de estrés, el cual osciló entre 0.08 y 0.70 en la primera semana de agosto y de mayo respectivamente.




Figura 19. Evolución de los compuestos de 8 días de cada término implicado en el factor f de estrés, EF y Ts.

La Figura 20 muestra la regresión lineal de la GPP observada y la GPP modelada utilizando los productos satelitales FAPAR suministrados por MODIS. El resultado del ajuste ha sido satisfactorio, como lo refleja el coeficiente de determinación $R^2=91.2\%$. El valor de la pendiente, es decir ϵ_{max} , fue 2.926 ± 0.168 gC/MJ y la ordenada en el origen 10.005 ± 2.908 gC/m².8d. La comparación con los valores de GPP obtenidos con el sensor MERIS, no mostrados aquí, arrojó valores muy similares, $R^2=88.5\%$, 2.821 ± 0.185 gC/MJ y 10.471 ± 3.279 gC/m².8d, respectivamente. A pesar de los resultados de ϵ_{max} tan contrastados descritos en la bibliografía para diversos tipos de cultivos el valor obtenido figura entre los más altos, comparables a los del cultivo de maíz, planta C4, e incluso superiores (Wang et al., 2012). El comportamiento diferente de las plantas C4 se debe a que pueden mantener una tasa fotosintética dada con menos cantidad de agua en comparación con las plantas C3, aportando una GPP superior (Yan et al., 2009). La Figura 21 muestra la evolución de los compuestos de GPP_{8d} observados, modelados y los suministrados por MODIS durante todo el período de estudio.




Figura 20. Ajuste de los compuestos de GPP-8d observada en función de la modelada, GPP_{PAR} . Las líneas discontinuas corresponden a los valores de nivel de predicción y de confianza respectivamente, al 95% de nivel de significación.




Figura 21. Evolución de los compuestos de GPP de 8 días observada, modelada y estimada por el sensor MODIS.

Comparando las tres gráficas de la Figura 21 se extraen las siguientes conclusiones:

- La presencia de picos irregulares bastante acentuados durante abril y parcialmente mayo, donde la GPP modelada desciende sensiblemente. Este

resultado se debe a las variaciones de PAR medida en superficie, la cual reflejó similares variaciones debido a la presencia de nubes.

- La gran infravaloración de la GPP por el sensor MODIS, el cual aportó valores aproximadamente 4 veces inferiores a los observados durante el período de crecimiento vegetativo.

A pesar de la significativa subestimación del MODIS, resulta de interés señalar la buena correlación obtenida con los valores de GPP observados, $R^2=89.6\%$. Basándonos en este resultado, hemos de atribuir los incorrectos resultados aportados por dicho sensor al valor de ϵ_{\max} por defecto definido para los cultivos, 0.604 gC/MJ , que en el caso de las medidas en superficie ha resultado ser aproximadamente 4 veces superior. La subestimación del sensor MODIS para la estimación de la GPP está en conformidad con otros resultados reportados tanto en ecosistemas de climas áridos como en otras condiciones climáticas (Fensholt et al., 2006, Yan et al., 2009, King et al., 2011).

El valor de la GPP observada acumulada durante el período de máximo interés, marzo-junio fue 1219.1 gC/m^2 , durante el período de medidas 1483.6 gC/m^2 y durante el ciclo completo, 1742.5 y 1803.3 gC/m^2 una vez rellenado los huecos mediante un ajuste lineal entre los compuestos de 8 días de GPP y de LAI ($R^2=80.7\%$ y 86.6% para MODIS y MERIS). De aquí se desprende la elevada contribución del período de máximo interés en relación al del ciclo completo, en promedio 0.68 . El valor de la GPP suministrada por el MODIS durante todo el ciclo fue muy inferior, 428.1 gC/m^2 .

Los resultados obtenidos contrastan con los medidos en una cubierta vegetal arbustiva rala situada en el CIBA, los cuales han suministrado un valor de ϵ_{\max} netamente inferior, $1.712 \pm 0.061 \text{ gC/MJ}$ y similar al descrito en la bibliografía para pastizales degradados (Wang et al., 2010) y una GPP acumulada aproximadamente la mitad de la obtenida en el cultivo de colza.

8. DISCUSIÓN DE LOS RESULTADOS. CONCLUSIONES

El cultivo de colza no irrigado estudiado posee una característica diferenciadora respecto a los cereales convencionales: una alta evapotranspiración, constatada a través de las medidas in situ de calor latente, cuyos valores han superado a los del calor sensible y del suelo, siendo responsables de un 52.2% de la energía total disponible, medida directamente mediante un radiómetro neto. Esta singularidad es manifiesta cuando se compara la aportación de este término con la obtenida en una cubierta vegetal arbustiva emplazada a tan sólo 10 km de la explotación agrícola donde la contribución del calor latente a la energía disponible fue bastante inferior, en promedio durante 3 años consecutivos, 33.4%, resultando el calor sensible y los flujos del suelo los factores dominantes 40.3 y 26.3%, respectivamente.

La alta evapotranspiración, consecuencia de su estructura foliar, las buenas condiciones de crecimiento vegetativo y la falta de estrés hídrico debido a las condiciones pluviométricas que han dominado el período de medidas, han propiciado la apertura estomática, favoreciendo la absorción fotosintética de CO₂, y por tanto su capacidad de actuar como un importante sumidero de CO₂.

Cuando se analizan la evolución estacional de las variables medidas in situ y las suministradas por los sensores MODIS y MERIS, la analogía entre los datos de NEE, GPP, FAPAR y LAI, es patente. Todas las medidas in situ y los parámetros biofísicos han probado un buen acuerdo entre la evolución fenológica del cultivo y los diversos eslabones de los flujos de CO₂, NEE, GPP y RE.

Las medidas en superficie han mostrado una variación estacional consistente en un aumento progresivo de NEE, GPP y RE desde marzo hasta junio seguida de una disminución hasta el mes de octubre. El cultivo de colza continuó siendo un sumidero de CO₂ durante el mes de julio, incluso después de la cosecha, y en agosto, para invertirse la situación a partir de septiembre momento a partir del cual se comportó como un emisor de CO₂. La elevada resolución temporal de las medidas, 30 minutos,

ha permitido caracterizar la influencia de las variables dominantes sobre la absorción fotosintética y la respiración, las cuales han venido gobernadas por la PAR para la NEE y por la disponibilidad de agua medida a través de la humedad del suelo y la temperatura del aire, para RE. En concreto la PAR ha explicado un 77.3% de la variabilidad de los datos de NEE semi-horarios medidos directamente mediante el sistema EC probando su gran influencia sobre la absorción fotosintética. La temperatura y sobre todo la disponibilidad del agua, medida a través de la humedad del suelo y la fracción evaporativa, EF, han desempeñado un papel determinante sobre los procesos de respiración del cultivo y GPP.

Los compuestos de 8 días de los sensores MODIS y MERIS, con similar resolución espacial, 1 km, han reflejado similares características y además han sido muy consistentes entre sí obteniéndose mínimas discrepancias en los parámetros biofísicos LAI y FAPAR suministrados por ambos obteniéndose una ligera sobreestimación del sensor MODIS en 1.12 y 1.04 respectivamente. De aquí se extrae como conclusión el grado de precisión y acuerdo de los complicados algoritmos implementados para el procesado de estos productos a partir de las medidas radiométricas satelitales directas. Los compuestos satelitales de 8 días de LAI y FAPAR han mostrado también un progresivo aumento a partir de finales de febrero hasta mediados de mayo acordes al desarrollo del cultivo y la subsiguiente reducción durante el período estival e invernal. Los valores bastante conservativos durante estas dos estaciones del año reflejan adecuadamente la escasa actividad fotosintética de la vegetación en el estado de senescencia o tras la recolección en presencia de las altas temperaturas estivales y bajas temperaturas invernales. Los valores de GPP suministrados por MODIS han evolucionado similarmente.

Sin embargo, y a pesar de estas analogías, el uso de los datos satelitales para las estimaciones de la GPP o NEE ha arrojado discrepancias cualitativas y cuantitativas respecto a las medidas realizadas en superficie. Entre las diferencias cualitativas destacan las fechas en las que se han obtenido los valores máximos a mediados de mayo según MODIS y a finales de abril para MERIS. Estas

discrepancias podrían atribuirse a la presencia de nubes durante el mes de mayo, las cuales conducen a una peor calidad de los datos satelitales. Entre las diferencias cuantitativas merece especial atención la infravaloración de los productos biofísicos satelitales respecto a los observados in situ. En el caso del LAI, la comparación de los datos in situ y los concurrentes satelitales, aspecto poco descrito en la bibliografía, aunque ha arrojado un buen acuerdo dato-a dato con los suministrados por MODIS y MERIS durante el período de crecimiento vegetativo, R^2 , 92.7 y 91.0%, han mostrado una subestimación de los resultados experimentales de un 37 y un 19% respectivamente. Otro tanto ha sucedido con los valores de la GPP estimada por el sensor MODIS y los datos medidos en superficie, los cuales, aún presentando una buena correlación con los de superficie, $R^2= 89.6\%$, han suministrado una subestimación de los resultados muy superior, aproximadamente en un factor 4. Esta discrepancia tan grande se debe a las grandes diferencias entre el valor de ϵ_{\max} para los cultivos considerado en el algoritmo MODIS, 0.604 gC/MJ, con respecto al obtenido en este trabajo 2.926 ± 0.168 gC/MJ. De estos resultados se deriva la necesidad de realizar medidas de superficie al objeto de calibrar los datos aportados por los sensores satelitales.

En lo que concierne a los flujos de CO_2 de la colza, el valor de NEE acumulado a lo largo de todo el ciclo promediando los resultados de MODIS y MERIS, ha sido -422.1 gC/m², revelando claramente su capacidad como sumidero de CO_2 . Durante el período de máximo interés, marzo-junio, el valor acumulado ha sido -554.2 gC/m². El valor de GPP durante el período de máximo interés ha sido 1219.1 gC/m² y durante el ciclo completo 1772.9 gC/m² que normalizando a los 12 meses del año equivale a 1636.5 gC/m². La alta participación porcentual del período de máximo interés, 68.8%, permite concluir el importante papel cuantitativo que desempeña el ciclo de crecimiento vegetativo en la absorción de CO_2 . Por ello, la influencia de sequías, que ejercen un efecto determinante sobre la reducción de NEE y GPP, tiene consecuencias nefastas no sólo por las pérdidas que producen en la

productividad de las cosechas sino también por su impacto negativo en la absorción de CO₂.

El valor acumulado anual de la GPP ha resultado ser comparable a los típicos valores reportados para las plantas C4 y en concreto el maíz, uno de los cultivos más estudiados. Este alto valor tiene un doble origen. En primer lugar, los elevados valores diarios de NEE y en segundo, la contribución de los procesos de respiración diurna, que también aportan valores superiores a la los cereales convencionales, resultado atribuible a la estructura foliar y de las raíces del cultivo de colza. La contribución porcentual de RE a la GPP durante el período de estudio ha sido del 48.5%, aportando un valor comparable al de NEE.

A pesar de que en este trabajo sólo hemos mencionado algunos resultados obtenidos en una zona arbustiva situada a tan sólo 10 km de la parcela de colza, es interesante resaltar que la GPP y la NEE de la colza han resultado ser aproximadamente el doble. De aquí se desprende el importante papel que desempeñan los cultivos agrícolas como sumideros de CO₂ y, apoyándonos en este resultado, la conveniencia de cultivar las tierras frente a la utilización del barbecho, uso de suelo que medioambientalmente carece de dicha capacidad. Por ello, a nuestro juicio, las futuras medidas de la Unión Europea que se están debatiendo para la reestructuración del sector agrario comunitario deberían contemplar el futuro de los cambios de usos del suelo y valorar la gran influencia de los cultivos sobre la absorción de CO₂.

AGRADECIMIENTOS

Este trabajo ha sido financiado por el MICINN, actualmente Ministerio de Economía y Competitividad, y fondos FEDER a través del proyecto CGL2009-11979 a quienes los autores expresan su agradecimiento. Los autores también agradecen a D. Jerónimo Alonso, propietario de la Finca Monte de Rocío, por las facilidades brindadas, su apoyo logístico e informativo, sin cuya colaboración este trabajo no hubiera sido posible. Asimismo expresamos nuestro agradecimiento a la empresa ACOR por su interés y apoyo a la ejecución de este proyecto. Por último, agradecemos a Carlos Blanco su valiosa ayuda en el mantenimiento del correcto

funcionamiento de la instrumentación, soporte informático así como su inestimable contribución a las medidas de campo.

BIBLIOGRAFÍA

- Aber, J.D., Reich, P.B., Goulden, M.L., 1996. Extrapolating leaf CO₂ exchange to the canopy: a generalized model of forest photosynthesis compared with measurements by eddy correlation. *Oecologia*, 106, 257–265.
- Adams, J. M., Piovesan, G., 2002. Uncertainties in the role of land vegetation in the carbon cycle. *Chemosphere*, 49, 805-819.
- Albergel, C., Calvet, J.C., Gibelin, A.L., Lafont, S., Roujean, J.L., Berne, C., Traull'e, O., Fritz, N., 2010. Observed and modelled ecosystem respiration and gross primary production of a grassland in Southwestern France. *Biogeosciences*, 7, 1657-1668.
- Allard, V., Ourcival, J. M., Rambal, S., Joffre, R., Rocheteau, A., 2008. Seasonal and annual variation of carbon exchange in an evergreen Mediterranean forest in Southern France. *Glob. Change Biol.*, 14, 714-725.
- Angert, A., Biraud, S., Bonfils, C., Henning, C.C., Buermann, W., Pinzon, J., Tucher, J., Fung, I., 2005. Drier summers cancel out the CO₂ uptake enhancement induced by warmer springs, *Proc. Nat. Acad. Sci. USA*, 102 (31), 10823-10827.
- Anthoni, P. M., Freibauer, A., Kolle, O., Schulze, E., 2004. Winter wheat carbon exchange in Thuringia, Germany. *Agric. For. Meteorol.*, 121, 55–67.
- Apadula, F., Gotti, A., Pignini, A., Longhetto, A., Rocchetti, F., Cassardo, C., Ferrarese, S., Forza, R., 2003. Localization of source and sink regions of carbon dioxide through the method of the synoptic air trajectory statistics. *Atmos. Environ.*, 37, 3757-3770.
- Bacour, C., Baret, F., Béal, D., Weiss, M., Pavageau, K., 2006. Neural network estimation of LAI, fAPAR, fCover and LAI×C_{ab}, from top of canopy MERIS reflectance data: Principles and validation. *Remote Sens. Environ.*, 105, 313-325.
- Baldocchi, D., Falge, E., Gu, L., Otson, R., Hollinger, D., Running, S, Anthoni, P., Bermhofer, C., Davis, K., Evans, R., Fuentes, J., Goldenstein, A., Katul, G., Law, B., Lee, K., Malhi, Y., Meyers, T., Munger, W., Katul, G., Law, B., Lee, X., Malhi, Y., Meyers, T., Munger, W., Oecheel, W., Li, K.T., Pilegaard, K., Schmidt, H.P., Valentini, R., Verma, S., Vesaia, T., Wilson, K., Wosfy, S., 2001. FLUXNET: a new tool to study the temporal and spatial variability of ecosystem-scale carbon dioxide, water vapour and energy flux densities. *Bull. Amer. Meteor. Soc.*, 82, 2415-2434.
- Coops, N.C., Jassal, R.S., Leuning, R., Black, A.T., Morgenstern, K., 2007. Incorporation of a soil water modifier into MODIS predictions of temperate Douglas-fir gross primary productivity: Initial model development. *Agric. For. Meteorol.*, 147, 99-109.

- Fensholt, R., Sandholt, I., Rasmussen, M.S., Stisen, R., Diouf, A., 2006. Evaluation of satellite based primary production modelling in the semi-arid Sahel. *Remote Sens. Environ.*, 105, 173-188.
- Ferrarese, S., Longhetto, A., Cassardo, C., Apadula, F., Bertoni, D., Giraud, C., Gotti, A., 2002. Study of seasonal and yearly modulation of carbon dioxide sources and sinks, with a particular attention to the Boreal Atlantic Ocean. *Atmos. Environ.*, 36, 5517-5526.
- Feld C.B., Behrenfield, M.J., Randerson, J.T., Falkowski, P., 1998. Primary production of the biosphere: Integrating terrestrial and oceanic compounds. *Science*, 281,237-240.
- Gebremichael, M., Barros, A.P., 2006. Evaluation of MODIS. Gross primary productivity (GPP) in tropical monsoon regions. *Remote Sens. Environ.*, 100, 150-166.
- Gobron, N., Pinty, B., Ausedat, O., Taberner, M., Faber, O., Mélin, F., Lavergne, T., Robustelli, M., Snoeij P., 2008. Uncertainty estimates for the FAPAR operational products derived from MERIS — Impact of top-of-atmosphere radiance uncertainties and validation with field data. *Remote Sens. Environ.*, 112, 1871-1883.
- Houghton, R.A., 1999. The annual net flux of carbon to the atmosphere from change land in land use 1850-1990. *Tellus B*, 51, 298-313.
- IPCC, 2001. *Climate Change 2001: The scientific bases*. Intergovernmental Panel of Climate Change, 881 pp. Cambridge University Press, UK.
- IPCC, 2007. *Climate Change 2007: The scientific bases*. Intergovernmental Panel of Climate Change, 18 pp. Cambridge University Press, UK.
- King, D.A., Turner, D.P., Ritts, W.D., 2011. Parameterization of a diagnostic carbon cycle model for continental scale application. *Remote Sens. Environ.*, 7, 1653-1664.
- Leuning, R., Cleugh, H.A., Zegelin, S.J., Hughes, D., 2005. Carbon and water fluxes over a temperate Eucalyptus forest and a tropical wet/dry savannah in Australia: measurements and comparison with MODIS remote sensing estimates. *Agric. For. Meteorol.*, 129, 151-173.
- Li, Z., Yu, G., Xiao, X., Li, Y., Zhao, X., Ren, CH., Zhang, L., Fu, Y., 2007. Modeling gross primary production of alpine ecosystems in the Tibetan Plateau using MODIS images and climate data. *Remote Sens. Environ.*, 107, 510–519.
- Meyers, T.P., 2001. A comparison of summertime water and CO₂ fluxes over rangeland for well-watered and draught conditions. *Agric. For. Meteorol.*,106, 205-214.
- Patel, N.R., Dadhwal, V.K., Saha, S.K, Garg, A., Sharma, N., 2010. Evaluation of MODIS data potential to infer water stress for wheat NPP estimation. *Tropical Ecology*, 51, 93-105.
- Peters, W., Jacobson, A.R., Sweeney, C., Andrews, A.E., Conway, T.J., Masarie, K., Miller, J.B., Bruhwiler, L.M. P., Petron, G. Adam, I. Hirsch, Worthy, D.A.I., E.J., van der Wer G.R., Randerson J.T., Wennberg P.O., Krol M.C., Tans, P.P.

2007. An atmospheric perspective on North American carbon dioxide exchange: CarbonTracker. PNAS, 104, 18925–18930.
- Peters W. et al. (41 autores), 2009. Seven years of recent European net terrestrial carbon dioxide exchange constrained by atmospheric observations. *Glob. Change Biol.*, 16, 1317-1337.
- Pingintha, N., Leclerc, M.Y., Beasley J. P., Zhang G., Senthong, C., Rowland, D., 2009. Hysteresis response of daytime net ecosystem CO₂ exchange during a drought. *Biogeosciences Discussions*, 6, 10707-10735.
- Prince, S.D., Goward, S.N., 1995. Global primary production: a remote sensing approach. *J. Biogeogr.*, 22, 815–835.
- Pumpanen, J., Kolari, P., Ilvesniemi, H., Minkkinen, K., Vesala, T., Niimistö, S., Lohila, A., Larmola, T., Morero, M., Pihlatie, M., Janssens, I., Curiel, J.Y., Grünzweig, J., Reth, S., Subke, J. A., Savage, K., Kutsch, W., Østreg, G., Ziegler, W., Anthoni, P., Lindroth, A., Hari, P., 2004. Comparison of different chamber techniques for measuring soil CO₂ efflux. *Agric. For. Meteorol.*, 123, 159-176.
- Rambal, S., Ourcival, J.M., Offre, R.J., Moutillotw, F., Nouvellonz, Y., Reichstein, M., Rocheteauz, A., 2003. Drought controls over conductance and assimilation of a Mediterranean evergreen ecosystem: scaling from leaf to canopy. *Glob. Change Biol.*, 9, 1813-1824.
- Rauwerda, J., Roerink, G.J., Su, Z., 2002. Estimation of evaporative fractions by the use of vegetation and soil component temperatures determined by means of dual looking remote sensing. *Alterra Report 580*, Wageningen, The Netherlands.
- Running, S.W., Baldocchi, D.D., Turner, D.P., Gower, S.T., Bakwin, P.S., Hibbard, K.A., 1999. A global terrestrial monitoring network integrating tower fluxes, flask sampling, ecosystem modelling and EOS satellite data. *Remote Sens. Environ.*, 70, 108-127.
- Running, S.R., Thornton, P.E., Nemani, R., Glassy, J.M., 2000. Global terrestrial gross and net primary productivity from the Earth Observing System. *Methods in Ecosystem Science*, Springer, pp45-56.
- Sánchez, M.L., Ozores, M., Colle, R., López, M.J., de Torre, B., García, M.A., Pérez, I., 2002. CO₂ fluxes in cereal land use of the Spanish Plateau: Influence of conventional and reduced tillage practices. *Chemosphere*, 47, 837-844.
- Sánchez, M.L., de Torre, B., García, M.A., Pérez, I., 2003. Soil CO₂ fluxes beneath barley on the Central Spanish Plateau. *Agric. For. Meteorol.*, 118, 85-95.
- Sánchez, M.L., Pérez, I.A., García, M.A., 2010. Study of CO₂ variability at different temporal scales recorded in a rural Spanish site. *Agric. For. Meteorol.*, 150, 1168–1173.
- Sims, D.A., Rahman, A.F., Cordova, V. D., Baldocchi, D.D., Flanagan, L.B., Goldstein, A. H., Hollinger, D.Y., Misson, L., Monson, R.K., Schmid, H.P., Wofsy, S.C., Xu, L., 2005. Midday values of gross CO₂ flux and light use efficiency during satellite overpasses can be used to directly estimate eight-day mean flux. *Agric. For. Meteorol.*, 131, 1-12.

- Sims, D.A., Luo, H., Hastings, S., Oechel, W.C., Rahman, A.F., Gamon J.A., 2006. Parallel adjustments in vegetation greenness and ecosystem CO₂ exchange in response to drought in a Southern California chaparral ecosystem. *Remote Sens. Environ.*, 103, 289-303.
- Sobrino, J.A., Raissouni, N., Kerr, Y., Olioso, A., López-García, M.J., Belaid, A., El Kharraz, M.H., Cuenca, J., Dempere, L., 2000. Teledetección. Servicio de Publicaciones, Universidad de Valencia. ISBN 84-370-4220-8.
- Sobrino, J., Soria G., 2003. AATRS Land-surface temperature and emissivity algorithm Theoretical basis document. EAGLE project (SST3-2003-502057), pp 1-16.
- Tsutsumi, Y., Mori, K., Ikegami, M., Tashiro, T., Tsuboi, K., 2006. Long-term trends of greenhouse gases in regional and background events observed during 1998–2004 at Yonagunijima located to the east of the Asian continent. *Atmos. Environ.*, 40, 5868-5879.
- Turner, D.P., Ritts, W.D., Cohen, W.B., Gower, S.T., Zhao, M.S., Running, S.W., Wofsy, S. C., Urbanski, S., Dunn, A.L., Munger J.W., 2003. Scaling, Gross Primary Production (GPP) over boreal and deciduous forest landscapes in support of MODIS GPP product validation. *Remote Sens. Environ.*, 88, 256-270.
- Valladares, F., Peñulas, J., Calabuig E., 2005. Impactos del Cambio climático en España, ecosistemas terrestres, 112 pp. Ministerio de Medio Ambiente, España.
- Venturini, V., Islam, S., Rodríguez L., 2008. Estimation of evaporative fraction and evapotranspiration from MODIS products using a complementary based model. *Remote Sens. Environ.*, 112, 134-141.
- Veroustraete, F., Sabbe, H., Eerens, H., 2002. Estimation of carbon mass fluxes over Europe using the C-Fix model and Euroflux data. *Remote Sens. Environ.*, 83, 376-399.
- Wang, L., Parodi, G.N., Su, Z., 2008. SEBS Module BEAM tool for surface energy balance estimates from remote sensing data. (Comunicación privada). Remitido para su publicación al 2nd MERIS AATRS Workshop celebrado en Frascati.
- Wang, Z., Xiao, X., Yan, X., 2010. Modeling gross primary production of maize cropland and degraded grassland in northeastern China. *Agric. For. Meteorol.*, 50, 1160-1167.
- Wang, X., Ma, M., Huang, G., Veroustraete, F., Zhang, Z., Song, Y., Tan, J., 2012. Vegetation primary production estimation at maize and alpine meadow over the Heihe River Basin, China. *Int. J. App.Earth*, 17, 94-101.
- Weiss, M., Baret, F., Garrigues, S., Lacaze, R., 2007. LAI and fAPAR CYCLOPES global products derived from VEGETATION. Part 2: validation and comparison with MODIS collection 4 products, *Remote Sens. Environ.*, 110, 317–331.
- Wilson, K., Goldstein, A., Falge, E., Aubinet, M., Baldocchi, D., Berbigier, P., Bernhofer, C., Ceulemans, R., Dolman, H., Field, C., Grelle, A., Ibrom, A., Law, B.E., Kowalski, A., Meyers, T., Moncrieff, J., Monson, R., Oechel, W.,

- Tenhunen, J., Valentini, R., Verma, S., 2002. Energy balance closure at FLUXNET sites. *Agric. For. Meteorol.*, 113, 223–243.
- Xiao, X., Zhang, Q., Saleskab, S., Hutyrab, L., De Camargoc, P., Wofsy, S., Frokinga, Bolesa, S., Keller, M., MooreII, B., 2005. Satellite-based modeling of gross primary production in a seasonally moist tropical evergreen forest. *Remote Sens. Environ.*, 94, 105–122.
- Yan, H., Fu, Y., Xiao, X., Huang, H.Q., He, H., Ediger, L., 2009. Modeling gross primary productivity for winter wheat–maize double cropping system using MODIS time series and CO₂ eddy flux tower data. *Agric. Ecosys. Environ.*, 129, 391–400.
- Yuan, W., Liu, S., Zhou, G., Zhou, G., Tieszen, L.L, Baldocchi, D., Bernhofer, CH., Gholz, H., Goldstein, A.H, Goulden, M.L., Hollinger, D.Y., Hu, Y., Law, B.E., Stoy P.C., Vesala, T., Wofsy, S.C and other AmeriFlux collaborators, 2007. Deriving a light use efficiency model from eddy covariance flux data for predicting daily gross primary production across biomes. *Agric. For. Meteorol.*, 143, 189-207.

ÍNDICE

Resumen

1.-Antecedentes

2.-Fundamentos

3.-Descripción del lugar de medidas

4.-Datos e instrumentación utilizada

4.1.-Micrometeorológica y meteorológica

4.2.-Índice foliar de la vegetación

4.3.-Imágenes satelitales

5.-Control de calidad de los datos. Relleno de huecos

6.-Estimación de la GPP a partir de imágenes satelitales

7.-Resultados

7.1.-Características meteorológicas generales durante el periodo de medidas

7.2.-Balance y distribución de la energía disponible

7.3.-Evolución fenológica de la vegetación

7.4.-LAI y FAPAR satelitales

7.5.-Evolución de la NEE

7.6.-Respiración del cultivo

7.7.-Ciclo diario. Influencia de la radiación fotosintética activa, PAR

7.8.-GPP

8.-Discusión de los resultados. Conclusiones

Agradecimientos

Bibliografía

