

VOL V

AGRÁRIAS

PESQUISA E INOVAÇÃO NAS CIÊNCIAS QUE
ALIMENTAM O MUNDO

EDUARDO EUGÊNIO
SPERS

(Organizador)

 EDITORA
ARTEMIS

2021

VOL V

AGRÁRIAS

PESQUISA E INOVAÇÃO NAS CIÊNCIAS QUE
ALIMENTAM O MUNDO

EDUARDO EUGÊNIO
SPERS

(Organizador)

 EDITORA
ARTEMIS

2021



O conteúdo deste livro está licenciado sob uma Licença de Atribuição Creative Commons Atribuição-Não-Comercial NãoDerivativos 4.0 Internacional (CC BY-NC-ND 4.0). Direitos para esta edição cedidos à Editora Artemis pelos autores. Permitido o download da obra e o compartilhamento, desde que sejam atribuídos créditos aos autores, e sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

A responsabilidade pelo conteúdo dos artigos e seus dados, em sua forma, correção e confiabilidade é exclusiva dos autores. A Editora Artemis, em seu compromisso de manter e aperfeiçoar a qualidade e confiabilidade dos trabalhos que publica, conduz a avaliação cega pelos pares de todos manuscritos publicados, com base em critérios de neutralidade e imparcialidade acadêmica.

Editora Chefe	Prof. ^a Dr. ^a Antonella Carvalho de Oliveira
Editora Executiva	M. ^a Viviane Carvalho Mocellin
Direção de Arte	M. ^a Bruna Bejarano
Diagramação	Elisangela Abreu
Organizadora	Prof. Dr. Eduardo Eugênio Spers
Imagem da Capa	Shutterstock
Bibliotecário	Maurício Amormino Júnior – CRB6/2422

Conselho Editorial

Prof. Dr. Adalberto de Paula Paranhos, Universidade Federal de Uberlândia
Prof.^a Dr.^a Amanda Ramalho de Freitas Brito, Universidade Federal da Paraíba
Prof.^a Dr.^a Ana Clara Monteverde, *Universidad de Buenos Aires, Argentina*
Prof. Dr. Ángel Mujica Sánchez, *Universidad Nacional del Altiplano, Peru*
Prof.^a Dr.^a Angela Ester Mallmann Centenaro, Universidade do Estado de Mato Grosso
Prof.^a Dr.^a Begoña Blandón González, *Universidad de Sevilla, Espanha*
Prof.^a Dr.^a Carmen Pimentel, Universidade Federal Rural do Rio de Janeiro
Prof.^a Dr.^a Catarina Castro, Universidade Nova de Lisboa, Portugal
Prof.^a Dr.^a Cláudia Neves, Universidade Aberta de Portugal
Prof. Dr. Cleberton Correia Santos, Universidade Federal da Grande Dourados
Prof.^a Dr.^a Deuzimar Costa Serra, Universidade Estadual do Maranhão
Prof.^a Dr.^a Eduarda Maria Rocha Teles de Castro Coelho, Universidade de Trás-os-Montes e Alto Douro, Portugal
Prof. Dr. Eduardo Eugênio Spers, Universidade de São Paulo
Prof. Dr. Eloi Martins Senhoras, Universidade Federal de Roraima
Prof.^a Dr.^a Elvira Laura Hernández Carballido, *Universidad Autónoma del Estado de Hidalgo, México*
Prof.^a Dr.^a Emilas Darlene Carmen Lebus, *Universidad Nacional del Nordeste/ Universidad Tecnológica Nacional, Argentina*
Prof.^a Dr.^a Erla Mariela Morales Morgado, *Universidad de Salamanca, Espanha*
Prof. Dr. Ernesto Cristina, *Universidad de la República, Uruguay*
Prof. Dr. Ernesto Ramírez-Briones, *Universidad de Guadalajara, México*
Prof. Dr. Gabriel Díaz Cobos, *Universitat de Barcelona, Espanha*
Prof. Dr. Geoffroy Roger Pointer Malpass, Universidade Federal do Triângulo Mineiro
Prof.^a Dr.^a Glória Beatriz Álvarez, *Universidad de Buenos Aires, Argentina*
Prof. Dr. Gonçalo Poeta Fernandes, Instituto Politécnico da Guarda, Portugal
Prof. Dr. Gustavo Adolfo Juarez, *Universidad Nacional de Catamarca, Argentina*
Prof.^a Dr.^a Iara Lúcia Tescarollo Dias, Universidade São Francisco
Prof.^a Dr.^a Isabel del Rosario Chiyon Carrasco, *Universidad de Piura, Peru*
Prof. Dr. Ivan Amaro, Universidade do Estado do Rio de Janeiro
Prof. Dr. Iván Ramon Sánchez Soto, *Universidad del Bío-Bío, Chile*
Prof.^a Dr.^a Ivânia Maria Carneiro Vieira, Universidade Federal do Amazonas



Prof. Me. Javier Antonio Albornoz, *University of Miami and Miami Dade College*, USA
Prof. Dr. Jesús Montero Martínez, *Universidad de Castilla - La Mancha*, Espanha
Prof. Dr. Joaquim Júlio Almeida Júnior, UniFIMES - Centro Universitário de Mineiros
Prof. Dr. Juan Carlos Mosquera Feijoo, *Universidad Politécnica de Madrid*, Espanha
Prof. Dr. Juan Diego Parra Valencia, *Instituto Tecnológico Metropolitano de Medellín*, Colômbia
Prof. Dr. Júlio César Ribeiro, Universidade Federal Rural do Rio de Janeiro
Prof. Dr. Leinig Antonio Perazolli, Universidade Estadual Paulista
Prof.ª Dr.ª Lúvia do Carmo, Universidade Federal de Goiás
Prof.ª Dr.ª Luciane Spanhol Bordignon, Universidade de Passo Fundo
Prof. Dr. Manuel Ramiro Rodriguez, *Universidad Santiago de Compostela*, Espanha
Prof. Dr. Marcos Augusto de Lima Nobre, Universidade Estadual Paulista
Prof. Dr. Marcos Vinicius Meiado, Universidade Federal de Sergipe
Prof.ª Dr.ª Margarida Márcia Fernandes Lima, Universidade Federal de Ouro Preto
Prof.ª Dr.ª Maria Aparecida José de Oliveira, Universidade Federal da Bahia
Prof.ª Dr.ª Maria do Céu Caetano, Universidade Nova de Lisboa, Portugal
Prof.ª Dr.ª Maria do Socorro Saraiva Pinheiro, Universidade Federal do Maranhão
Prof.ª Dr.ª Maria Lúcia Pato, Instituto Politécnico de Viseu, Portugal
Prof.ª Dr.ª Maurícea Silva de Paula Vieira, Universidade Federal de Lavras
Prof.ª Dr.ª Odara Horta Boscolo, Universidade Federal Fluminense
Prof.ª Dr.ª Patrícia Vasconcelos Almeida, Universidade Federal de Lavras
Prof.ª Dr.ª Paula Arcoverde Cavalcanti, Universidade do Estado da Bahia
Prof. Dr. Rodrigo Marques de Almeida Guerra, Universidade Federal do Pará
Prof. Dr. Sergio Bitencourt Araújo Barros, Universidade Federal do Piauí
Prof. Dr. Sérgio Luiz do Amaral Moretti, Universidade Federal de Uberlândia
Prof.ª Dr.ª Sílvia Inés del Valle Navarro, *Universidad Nacional de Catamarca*, Argentina
Prof.ª Dr.ª Teresa Cardoso, Universidade Aberta de Portugal
Prof.ª Dr.ª Teresa Monteiro Seixas, Universidade do Porto, Portugal
Prof. Dr. Turpo Gebera Osbaldo Washington, *Universidad Nacional de San Agustín de Arequipa*, Peru
Prof. Dr. Valter Machado da Fonseca, Universidade Federal de Viçosa
Prof.ª Dr.ª Vanessa Bordin Viera, Universidade Federal de Campina Grande
Prof.ª Dr.ª Vera Lúcia Vasilévski dos Santos Araújo, Universidade Tecnológica Federal do Paraná
Prof. Dr. Wilson Noé Garcés Aguilar, *Corporación Universitaria Autónoma del Cauca*, Colômbia

Dados Internacionais de Catalogação na Publicação (CIP)
(eDOC BRASIL, Belo Horizonte/MG)

A277 Agrárias [livro eletrônico] : pesquisa e inovação nas ciências que alimentam o mundo V / Organizador Eduardo Eugênio Spers. – Curitiba, PR: Artemis, 2021.

Formato: PDF
Requisitos de sistema: Adobe Acrobat Reader
Modo de acesso: World Wide Web
Edição bilingue
ISBN 978-65-87396-34-7
DOI 10.37572/EdArt_290421347

1. Ciências agrárias – Pesquisa. 2. Agronegócio. 3. Sustentabilidade. I. Spers, Eduardo Eugênio.

CDD 630

Elaborado por Maurício Amormino Júnior – CRB6/2422

APRESENTAÇÃO

As Ciências Agrárias são um campo de estudo multidisciplinar por excelência, e um dos mais profícuos em termos de pesquisas e aprimoramento técnico. A demanda mundial por alimentos e a crescente degradação ambiental impulsionam a busca constante por soluções sustentáveis de produção e por medidas visando à preservação e recuperação dos recursos naturais.

A obra **Agrárias: Pesquisa e Inovação nas Ciências que Alimentam o Mundo** compila pesquisas atuais e extremamente relevantes, apresentadas em linguagem científica de fácil entendimento. Na coletânea, o leitor encontrará textos que tratam dos sistemas produtivos em seus diversos aspectos, além de estudos que exploram diferentes perspectivas ou abordagens sobre a planta, o meio ambiente, o animal, o homem, o social e sobre a gestão.

Este Volume V traz 28 artigos de estudiosos de diversos países: são 18 trabalhos de autores da Argentina, Canadá, Colômbia, Cuba, Espanha, México e Portugal e dez trabalhos de pesquisadores brasileiros, divididos em três eixos temáticos.

Os dez trabalhos organizados sob o eixo temático **Clima, Solo e Água** desenvolvem temas relativos à importância desses elementos para a manutenção dos ecossistemas. Os 14 títulos que compõem o eixo temático **Agroecologia e Desenvolvimento Sustentável**, por outro lado, apresentam estudos sobre diferentes formas de se diminuir, reverter ou harmonizar as consequências da atividade humana sobre o meio ambiente. Seguindo a mesma linha, o eixo **Resíduos Agrícolas e Logística Reversa** traz quatro trabalhos que finalizam este importante volume.

Desejo a todos uma proveitosa leitura!

Eduardo Eugênio Spers

SUMÁRIO

CLIMA, SOLO E ÁGUA

CAPÍTULO 1.....1

LA VEGETACIÓN EN UN MUNDO CAMBIANTE: ESTADO BASAL, ESTABILIDAD Y RESILIENCIA DE UN SISTEMA COMPLEJO

Eduardo Alberto Pérez-García

Rodrigo Muñoz

Jorge A. Meave

DOI 10.37572/EdArt_2904213471

CAPÍTULO 2.....24

SALT AFFECTED SOILS IN PROTECTED PRODUCTIVE SYSTEMS. IRRIGATION WATER AND PRODUCTIVE MANAGEMENT

Margarita M. Alconada Magliano

Luciano Juan

DOI 10.37572/EdArt_2904213472

CAPÍTULO 3..... 40

CAMBIOS EN PROPIEDADES FÍSICO-HÍDRICA DE SUELOS PERTENECIENTES A UNA MICROCUENCA DEL ARROYO SAUCE CORTO EN LA PAMPAINTESSERRANA SUBHUMEDA ARGENTINA

Eduardo de Sá Pereira

Gonzalo Arroquy

Alberto Raul Quiroga

Cristian Álvarez

Romina Fernández

Juan Alberto Galantini

DOI 10.37572/EdArt_2904213473

CAPÍTULO 4.....55

PRODUCCIÓN PRIMARIA NETA AÉREA DEL COMPONENTE HERBÁCEO DE SISTEMAS SILVOPASTORILES EN LA LLANURA ONDULADA DEL SUR DE CÓRDOBA

José Omar Plevich

Marco Jesús Utello

Santiago Ignacio Fiandino

Juan Carlos Tarico

Ángel Ramón Sanchez Delgado

Javier Enrique Gyenge

DOI 10.37572/EdArt_2904213474

CAPÍTULO 5..... 65

DETECCIÓN DE CAMBIOS CON IMÁGENES DE SATÉLITE EN EL DEPARTAMENTO PELLEGRINI, SANTIAGO DEL ESTERO

[Liria Boix](#)

DOI 10.37572/EdArt_2904213475

CAPÍTULO 6..... 74

CAMBIOS EN EL PROMEDIO DE LA PRECIPITACIÓN ANUAL DEL SUDOESTE DE LA PROVINCIA DE BUENOS AIRES, ARGENTINA

[Silvia Patricia Pérez](#)

[Mariano Tomás Cassani](#)

[Marcelo Juan Massobrio](#)

DOI 10.37572/EdArt_2904213476

CAPÍTULO 7 84

INTEGRACIÓN DE MODELOS HIDRÁULICOS Y FOTOVOLTAICOS EN BOMBEO SOLAR

[Jorge Cervera Gascó](#)

[Miguel Ángel Moreno Hidalgo](#)

[Jesús Montero Martínez](#)

DOI 10.37572/EdArt_2904213477

CAPÍTULO 8..... 95

PREDICCIÓN DE LA IRRADIACIÓN SOLAR GLOBAL DIARIA MEDIANTE REDES NEURONALES ARTIFICIALES EN LA PENÍNSULA IBÉRICA

[Francisco Javier Diez](#)

[Luis Manuel Navas Gracia](#)

[Andrés Martínez Rodríguez](#)

[Adriana Corrêa Guimarães](#)

[Leticia Chico Santamarta](#)

DOI 10.37572/EdArt_2904213478

CAPÍTULO 9..... 120

EFEITO DAS MUDANÇAS DO USO DA TERRA NAS PROPRIEDADES DOS SOLOS TEMPERADOS E TROPICAIS

[Dilier Olivera Vicedo](#)

[Rodolfo Lizcano Toledo](#)

[Deborah Henderson](#)

[Paul Richard](#)

[Lisa Wegener](#)

[Alberto González Arcia](#)

DOI 10.37572/EdArt_2904213479

CAPÍTULO 10.....132
CHANGES IN SHRUB INVASION IN SOUTH AMERICA PROTECTED TEMPERATE
NATIVE FORESTS

Julian Alberto Sabattini

Rafael Alberto Sabattini

DOI 10.37572/EdArt_29042134710

AGROECOLOGIA E DESENVOLVIMENTO SUSTENTÁVEL

CAPÍTULO 11.....143
MANEJO AGROECOLÓGICO DO SOLO: ANÁLISE E CONSERVAÇÃO DE SOLOS NO
MODELO AGROFLORESTAL

William Ortega Gonçalves

Diego Resende Rodrigues

Marcus Vinicius da Silva Rodrigues

Igor Graciano

Erika Cosendey Toledo de Mello Peixoto

DOI 10.37572/EdArt_29042134711

CAPÍTULO 12152
DIAGNÓSTICO DE LA COMPLEJIDAD DE UN SISTEMA AGROSILVOPASTORIL EN
TRANSICIÓN HACIA LA SOSTENIBILIDAD Y RESILIENCIA

Eduardo Blanco Contreras

Alma Yasmin Moreno Esquivel

Emilio Duarte Ayala

Gerardo Zapata Sifuentes

Agustín Cabral Martell

DOI 10.37572/EdArt_29042134712

CAPÍTULO 13.....159
¿QUÉ ENSEÑAN LAS REDES ALIMENTARIAS ALTERNATIVAS A LAS POLÍTICAS
PÚBLICAS?

Martha Alicia Cadavid Castro

Luz Stella Álvarez Castaño

Sara Eloísa Del Castillo Matamoros

Diana Patricia Giraldo Ramírez

Lina María Vélez Acosta

DOI 10.37572/EdArt_29042134713

CAPÍTULO 14..... 168

METABOLITOS MAYORITARIOS DE DIOSPYROS REKOI Y SU CORRELACIÓN AMBIENTAL PARA APLICACIONES SUSTENTABLES

Antonio Hilario Lara-Rivera

Sinuhé Galván Gómez

Gabriela Rodríguez-García

Mario A. Gómez-Hurtado

Rosa Elva Norma del Río

Ernesto Ramírez-Briones

DOI 10.37572/EdArt_29042134714

CAPÍTULO 15..... 180

AMARANTO: UNA ALTERNATIVA DE DIVERSIFICACIÓN PRODUCTIVA DE CALIDAD NUTRICIONAL EN LA NORPATAGONIA ARGENTINA

Maria Fany Zubillaga

Juan José Gallego

Maite Alder

DOI 10.37572/EdArt_29042134715

CAPÍTULO 16.....193

HIDRATAÇÃO DESCONTÍNUA DE SEMENTES EM REGIÕES SEMIÁRIDAS E SUAS IMPLICAÇÕES ECOLÓGICAS: UMA REVISÃO COM FOCO NA FLORESTA TROPICAL SECA BRASILEIRA

Joana Paula Bispo Nascimento

Marcos Vinicius Meiado

DOI 10.37572/EdArt_29042134716

CAPÍTULO 17220

USO DE NUTRAGREEN® COMO TRANSPORTADOR COLOIDAL PARA REDUCIR EL USO DE FERTILIZANTES Y PESTICIDAS EN PERAL

Guzmán Carro-Huerga

Álvaro Rodríguez-González

Sara Mayo-Prieto

Samuel Álvarez-García

Santiago Gutiérrez

Pedro Antonio Casquero Luelmo

DOI 10.37572/EdArt_29042134717

CAPÍTULO 18228

CARACTERIZAÇÃO AGROECOLÓGICA DE SISTEMAS INTEGRADOS DE PRODUÇÃO AGROPECUARIOS SIPAS

[Gustavo Adolfo Alegria Fernández](#)

DOI 10.37572/EdArt_29042134718

CAPÍTULO 19238

LEITE A PASTO EM SISTEMA DE PASTOREIO RACIONAL VOISIN (PRV) COMO FORMA DE RESISTÊNCIA À “SOJIFICAÇÃO DA SOCIEDADE”: O CASO DA FAMÍLIA SCHIMITH DA ROCHA

[Tatiana Aparecida Balem](#)

[Ricardo Lopes Machado](#)

DOI 10.37572/EdArt_29042134719

CAPÍTULO 20255

RESGATE E REPRODUÇÃO DE SEMENTES DE MILHO CRIOULO NO ASSENTAMENTO VALE DA ESPERANÇA

[Luís Pedro Alves Gonçalves](#)

DOI 10.37572/EdArt_29042134720

CAPÍTULO 21261

A PNATER E OS DESAFIOS IMPOSTOS ÀS ENTIDADES PÚBLICAS DE ATER: O CASO DA EMPAER EM MATO GROSSO

[Murilo Didonet de Moraes](#)

[Antonio Lázaro Sant’Ana](#)

DOI 10.37572/EdArt_29042134721

CAPÍTULO 22271

CULTURA & DESENVOLVIMENTO RURAL - O TEATRO REGIONAL DA SERRA DE MONTEMURO – PORTUGAL

[Maria Lúcia de Jesus Pato](#)

[Vitor Manuel Pinto de Figueiredo](#)

DOI 10.37572/EdArt_29042134722

CAPÍTULO 23281

TOURIST MOTIVATIONS TOWARDS THE HERITAGE OF THE NATIONAL PARK “PICOS DE EUROPA”

[Orlando Simões](#)

[Isabel Dinis](#)

[Rui Gomes](#)

DOI 10.37572/EdArt_29042134723

CAPÍTULO 24289

ATIVIDADES COMO BOLSISTA DE COOPERAÇÃO TÉCNICA NO JARDIM BOTÂNICO DO RECIFE

Brendo Ramonn Coutinho Paes
Bruno Leal Viana
Adalberto Francisco da Silva Júnior
Eduarda Maria Ribeiro dos Santos
Elmir Bezerra de Lima
Karina de Macena Silva
Maria Isabela Carvalho dos Santos Lima

DOI 10.37572/EdArt_29042134724

RESÍDUOS AGRÍCOLAS E LOGÍSTICA REVERSA

CAPÍTULO 25296

REUTILIZACIÓN DE RESIDUOS AGRÍCOLAS COMO ADSORBENTES DE BAJO COSTO PARA TRATAMIENTO DE AGUAS Y EFLUENTES

Néstor Caracciolo
María Natalia Piol
Andrea Beatriz Saralegui
Susana Patricia Boeykens

DOI 10.37572/EdArt_29042134725

CAPÍTULO 26 311

CARACTERIZAÇÃO POR DRX DE BIOCOMPÓSITOS A BASE DE PLA CARREGADOS COM RESÍDUOS DO CAROÇO DE MANGA E NANO-ORGANO-MONTMORILONITA

Edla Maria Bezerra Lima
Antonieta Middea
Jessica Fernandes Pereira
Ingrid Cristina Soares Pereira
Natália Rodrigues Rojas dos Santos
Renata Nunes Oliveira
Reiner Neumann

DOI 10.37572/EdArt_29042134726

CAPÍTULO 27.....318

DESENVOLVIMENTO DE CARBOXIMETILCELULOSE A PARTIR DO RESÍDUO DO MILHO PRODUZIDO EM COXIM-MS E REGIÃO

Felicia Megumi Ito
Adriana Gomes Pereira da Silva
Talina Meirely Nery dos Santos
Geziel Rodrigues de Andrade
Lincoln Carlos Silva de Oliveira
DOI 10.37572/EdArt_29042134727

CAPÍTULO 28329

RESPONSABILIDADES E RISCOS COMPARTILHADOS? A COMUNICAÇÃO DE RISCOS NA LOGÍSTICA REVERSA DE EMBALAGENS DE AGROTÓXICOS

Daniela de Ulysséa Leal
Ivonete da Silva Lopes
DOI 10.37572/EdArt_29042134728

SOBRE O ORGANIZADOR.....344

ÍNDICE REMISSIVO 345

CAPÍTULO 8

PREDICCIÓN DE LA IRRADIACIÓN SOLAR GLOBAL DIARIA MEDIANTE REDES NEURONALES ARTIFICIALES EN LA PENÍNSULA IBÉRICA¹

Data de submissão: 04/02/2021

Data de aceite: 26/02/2021

Francisco Javier Diez

Departamento de Ingeniería
Agrícola y Forestal,
Universidad de Valladolid.
Campus La Yutera, Palencia, España.
x5pino@yahoo.es
[https://www.scopus.com/authid/detail.
uri?authorId=57192252070](https://www.scopus.com/authid/detail.uri?authorId=57192252070)

Luis Manuel Navas Gracia

Departamento de Ingeniería
Agrícola y Forestal,
Universidad de Valladolid.
Campus La Yutera, Palencia, España.
luismanuel.navas@uva.es
<https://orcid.org/0000-0002-7895-925X>

Andrés Martínez Rodríguez

Departamento de Ingeniería
Agrícola y Forestal,
Universidad de Valladolid.
Campus La Yutera, Palencia, España.
andres.martinez.rodriguez@uva.es
[https://www.scopus.com/authid/detail.
uri?authorId=56112450900](https://www.scopus.com/authid/detail.uri?authorId=56112450900)

Adriana Corrêa Guimarães

Departamento de Ingeniería
Agrícola y Forestal,
Universidad de Valladolid.
Campus La Yutera, Palencia, España.
adriana.correa@uva.es
[https://www.scopus.com/authid/detail.
uri?authorId=23099135000](https://www.scopus.com/authid/detail.uri?authorId=23099135000)

Leticia Chico Santamarta

International Department,
HarperAdams University.
Newport, Shropshire, United Kingdom.
lchico-santamarta@harper-adams.ac.uk
[https://www.scopus.com/authid/detail.
uri?authorId=35423331600](https://www.scopus.com/authid/detail.uri?authorId=35423331600)

RESUMEN: Este artículo, se centra en la predicción de la irradiación solar global diaria horizontal, por ser el caso más interesante en la meteorología agrícola, por ejemplo, en las previsiones de necesidades de riego, utilizando la técnica de las redes neuronales artificiales (RNAs) de la inteligencia computacional, a partir de variables accesibles en las estaciones agrometeorológicas. El lugar donde fueron medidos los datos, utilizados para entrenar las RNAs, caracterizan donde se pueden volver a utilizar este tipo de modelos, en este estudio fueron las estaciones meteorológicas de la red SIAR en Castilla y León (España),

¹ Presentado anteriormente en el X Congreso Ibérico de Agroingeniería / X Congresso Ibérico de Agroengenharia, 3-6 septiembre 2019, Huesca - España.

en concreto la situada en Mansilla Mayor (León), durante los años 2004-2010. Los modelos RNAs se construyeron en la entrada con los datos medidos de irradiación solar global diaria de uno, dos y tres días anteriores, añadiendo el día del año $J(t)=1.365$, para predecir su valor el día siguiente. Los resultados obtenidos, validados durante el año 2011 completo $RMSE=3,8012$ MJ/(m²d), concluyen que las RNAs estudiadas mejoran los métodos clásicos comparados: 1) año típico CENSOLAR $RMSE=5,1829$ MJ/(m²d), 2) media móvil ponderada con la autocorrelación parcial de 11 días de retardo $RMSE=3,9810$ MJ/(m²d), 3) regresión lineal sobre el valor del día anterior $RMSE=4,2434$ MJ/(m²d), 4) año típico Fourier utilizado el 1^{er} armónico $RMSE=4,2747$ MJ/(m²d), y 5) las matrices de transición de Markov para 33 estados posibles $RMSE=4,3653$ MJ/(m²d). Durante los días de cambio brusco en el nivel de irradiación solar, se observan los mayores errores de predicción. Se plantea utilizar en la entrada otras variables para mejorar la eficacia del modelo RNA. Una de las variables probadas fue el índice de claridad diario $K_t=H/H_0$, resultando una mejora $RMSE=3,7703$ MJ/(m²d).

PALABRAS CLAVE: Predicción. Insolación. Evapotranspiración. Agrometeorología. Inteligencia computacional.

PREDICTION OF DAILY GLOBAL SOLAR IRRADIATION THROUGH ARTIFICIAL NEURONAL NETWORKS IN THE IBERIAN PENINSULA

ABSTRACT: This article focuses on the prediction of the horizontal daily global solar irradiation, as it is the most interesting case in agricultural meteorology (e.g., in forecasting irrigation needs), using the technique of artificial neural networks (ANNs) of computational intelligence, based on accessible variables at agrometeorological stations. The place where the data were measured, used to train the ANNs, characterize where this type of model can be used again, in this study it was the meteorological stations of the SIAR network in Castile and León (Spain), specifically the one located in Mansilla Mayor (León), during the years 2004-2010. ANNs models were built at the entrance with the measured data of daily global solar irradiation of one, two and three previous days, adding the day of the year $J(t)=1.365$, to predict its value the following day. The results obtained, validated during the full year 2011 $RMSE=3.8012$ MJ/(m²d), conclude that the ANNs studied improve the classic compared methods: 1) typical year CENSOLAR $RMSE=5.1829$ MJ/(m²d), 2) weighted moving average with the partial autocorrelation of 11 days of delay $RMSE=3.9810$ MJ/(m²d), 3) linear regression on the value of the previous day $RMSE=4.2434$ MJ/(m²d), 4) typical Fourier year used the 1st harmonic $RMSE=4.2747$ MJ/(m²d), and 5) the Markov transition matrices for 33 possible states $RMSE=4.3653$ MJ/(m²d). During the days of sudden change in the level of solar irradiation, the largest prediction errors are observed. It is proposed to use other variables in the input to improve the efficiency of the ANN model. One of the variables tested was the daily clearness index $K_t=H/H_0$, resulting in an improvement in $RMSE=3.7703$ MJ/(m²d).

KEYWORDS: Prediction. Insolation. Evapotranspiration. Agrometeorology. Computational intelligence.

1 INTRODUCCIÓN

El modelado de la irradiación solar comprende múltiples variantes según se trate con su valor global o sus componentes (directa o difusa), el tipo de variables predictivas utilizadas (meteorológicas o geográficas), la resolución espacial o temporal (minuto, horaria, diaria o mensual) dada al modelo, el ancho de banda estudiado, la metodología o algoritmo (determinista o estocástica) aplicado, la superficie estudiada (horizontal, inclinada o con seguimiento solar) y el tipo de cielo.

Los modelos de irradiación solar se pueden clasificar de diferentes maneras, a partir de una revisión exhaustiva Gueymard y Myers (2008) identifica nueve criterios de clasificación, como siguen: 1) Tipo de datos de salida como la irradiación directa, difusa y global. 2) Tipo de datos de entrada de las variables meteorológicas y componentes de la irradiación solar. 3) Resolución espacial para un lugar concreto o con resultados reticulados. 4) Tiempo de resolución para cada minuto utilizado en concentradores solares, horaria para simulaciones de sistemas solares, o diaria en meteorología agrícola, además de los promedios horarios o diarios mensuales. 5) Resolución espectral de onda corta, ultravioleta, para dos o más bandas. 6) Tipo de metodología como puede ser determinista durante un tiempo específico, pasado, presente o futuro, y estocástica respetando las propiedades estadísticas de las series de tiempo de la irradiación solar. 7) Tipo de algoritmo entre modelos derivados de los principios físicos y los modelos empíricos basados en los datos de irradiancia solar medidos en un lugar y periodo específico. 8) Geometría de la superficie con datos de la irradiación solar sobre superficies (horizontales, inclinadas o con seguimiento solar). 9) Tipos de cielo (despejado, parcialmente nuboso y cubierto) según el efecto de las nubes. Los resultados finales pueden requerir del uso de varios modelos sucesivamente cuyos resultados están vinculados.

Las técnicas de la inteligencia artificial (redes neuronales artificiales, algoritmos genéticos, lógica borrosa y sistemas híbridos) han sido utilizadas de diferentes formas para la estimación de la irradiación solar, en diferentes escalas de tiempo (mensual, diaria u horaria), utilizando variables meteorológicas, como por ejemplo (temperatura del aire, humedad relativa, velocidad del viento, nubosidad, duración de la insolación, índice de claridad, presión atmosférica) y las coordenadas geográficas (latitud, longitud y altura). También han sido utilizadas para la predicción de la irradiación solar (global, directa o difusa) futura, sobre la base de los últimos datos observados (Camacho *et al.*, 2012).

Los resultados obtenidos por las redes neuronales artificiales (RNAs) se han comparado con las técnicas estadísticas clásicas, describiendo las ventajas de las RNAs en las ciencias atmosféricas (Gardner & Dorling, 1998), cuando las situaciones

ambientales de interés son lo suficientemente complejas y no lineales, haciendo a estos modelos RNAs de utilidad por su dinámica, que solo se pueden obtener a través de datos empíricos, no a través de ecuaciones analíticas (Aitkenhead *et al.*, 2003), y donde las relaciones subyacentes son poco conocidas (Lek & Guégan, 1999). Oliveira *et al.* (2000) investiga la estructura óptima para las RNAs utilizadas en la predicción de las series de tiempo, de las cuales, los datos ambientales son un buen ejemplo. A continuación, se exponen diversos estudios con referencia al lugar de los datos utilizados para la construcción de los modelos.

Las RNAs se han utilizado para la estimación de la irradiación solar en lugares que no cuentan con instrumentos de medida. En Omán, Al-Alawi y Al-Hinai (1998) analiza la relación de la irradiación solar global mensual y las variables climatológicas (localización, mes, presión media, temperatura media, presión de vapor media, humedad relativa media, velocidad del viento media y duración de la insolación media) y Dorvlo *et al.* (2002) con una primera estimación del índice de claridad, en función de su latitud, longitud, horas de sol y el mes del año.

En la India, Shah *et al.* (2009) realiza la estimación de la irradiación solar difusa diaria y horaria media mensual, bajo diferentes condiciones climáticas, las neuronas de la capa de entrada reciben nueve entradas (latitud, longitud, altura, mes del año, temperatura del aire, humedad relativa, precipitación, velocidad del viento y longitud de onda larga), Reddy y Ranjan (2003) mejora otros modelos de correlación.

Las RNAs se han utilizado para obtener mapas de la irradiación solar mensuales en Turquía, Sözen *et al.* (2004) y en la provincia de Jaén, España, Hontoria *et al.* (2005) cuando la calidad de los datos y su densidad espacial no es tan buena como debería ser para la mayoría de los propósitos.

En Eslovenia, Seme *et al.* (2009) estima la irradiación solar global cada media hora con las entradas al modelo (irradiación solar extraterrestre, ángulo cenital solar, día del año, temperatura y presión atmosférica relativa) con buen resultado para los días claros. En Arabia Saudí, Mohandes *et al.* (1998), Mohandes *et al.* (2000), y Benghanem *et al.* (2009) utilizando diferentes combinaciones.

La ecuación de regresión de Ångström es mejorada por la lógica borrosa en la parte occidental de Turquía (Sen, 1998) y por las RNAs en Athalassa, Chipre (Tymvios *et al.*, 2005), en Irán (Azadeh *et al.*, 2009) con un modelo independiente para seis ciudades, y en Dehful, Irán (Behrang *et al.*, 2010).

Las RNAs son aplicadas para la generación de series sintéticas de irradiación solar horaria en varias ciudades de España (Hontoria *et al.*, 2002) y diaria en Sao Paulo y Río Grande del Sur, Brasil (Siqueira *et al.*, 2010). En Argelia, Mellit *et al.* (2008) presenta un

sistema de inferencia neuro-difuso adaptativo ANFIS para la estimación de las secuencias del índice de claridad media mensual y la irradiación solar global en lugares aislados sobre la base de las coordenadas geográficas (latitud, longitud y altitud) obteniendo 12 valores del índice de claridad medio mensual, posteriormente las matrices de Markov se utilizan para generar las secuencias de datos de irradiación solar global diaria.

En Desert Rock, USA, López *et al.* (2005) utiliza el método bayesano para evaluar la importancia relativa de las variables atmosféricas y radiométricas como entradas a un modelo de RNAs, resultando el índice de claridad y la masa relativa del aire en la estimación de la irradiación solar directa horaria. En Mahasarakham, Tailandia, Pattanasethanon *et al.* (2008) estudia sobre todos los tipos de cielo la disponibilidad de la iluminación e irradiación solar global horizontal para un clima tropical, desarrollando un modelo senoidal que consta de funciones polinómicas o exponenciales y una RNA se propone como modelo alternativo.

Por otra parte, está la predicción de la irradiación solar mediante las técnicas de la inteligencia artificial (Mellit, 2008), utilizando diferentes estructuras de RNAs en Argelia, Mellit *et al.* (2007) realiza la predicción de la irradiación solar global diaria en base de los valores anteriores y con un modelo híbrido (RNA y matrices de transición de Markov) (Mellit *et al.*, 2005). En Shanghái, China, Cao y Cao (2008), Cao y Lin (2008ab) utilizan las redes neuronales wavelet. La predicción de la irradiación solar se ve afectada por muchos factores como la masa de aire, las nubes y otras condiciones de entorno de la tierra de acuerdo a diferentes frecuencias de la luz solar (Cao & Cao, 2006).

En tres zonas de Egipto, Elminir *et al.* (2007) predice la fracción difusa diaria y horaria, mejorando los modelos de regresión. En Dakhla, Marruecos, Iqdour y Zeroual (2007) utiliza datos de hasta el quinto día, comparando con los resultados de los modelos ARMA. En Brue, UK, Moghaddamnia *et al.* (2009) utiliza la prueba Gamma para seleccionar las variables de entrada y la longitud de los datos de entrenamiento. En Jeddah, Arabia Saudí, Mellit *et al.* (2010) utiliza RNAs para predecir la irradiancia solar horaria global, directa y difusa.

En Golden, Colorado, USA, Ruffing y Venayagamoorthy (2009) utiliza la RNA recurrente echo state para realizar predicciones a corto y medio plazo de la irradiación solar a 30, 60, ..., 270 minutos. En Uganda, Mubiru (2008) desarrolla un modelo con RNAs para predecir la irradiación solar global diaria media mensual para ubicaciones sobre la base de datos geográficos y meteorológicos (latitud, longitud, altitud, duración de la insolación, humedad relativa y temperatura máxima). En Omaezaki, Japón, Kemmoku *et al.* (1999) desarrolla una RNA en varias etapas para predecir la insolación del día siguiente utilizando la previsión de la presión atmosférica media.

En Eskisehir, Turquía, Hoccoğlu *et al.* (2008) utiliza un modelo de representación 2D de los datos de irradiancia solar horaria, proporcionando una visualización única y compacta de los datos. En Trieste, Italia, Mellit y Pavan (2010) predice la irradiancia solar en una base de 24 horas para cada hora del día de mañana, usando los valores actuales del día de hoy de la irradiación diaria y la temperatura del aire diaria media, comprobando que el modelo funciona satisfactoriamente para días soleados y baja ligeramente su rendimiento en los días nublados.

En Córcega, Francia, Paoli *et al.* (2010) utiliza una normalización sobre los datos de irradiación solar respecto a los datos de irradiación solar extraterrestre mejorando la correlación entre las mediciones y los datos predichos, utilizando de una a 15 entradas de los valores diarios anteriores, Sfetsos y Coonick (2000) predice a un paso por delante la irradiancia solar horaria media.

En Madrid, Lleida, Albacete y Murcia, España, Martín *et al.* (2010) compara los modelos estadísticos basados en series de tiempo aplicados a la predicción de la irradiación solar global diaria con un horizonte temporal de tres días, utilizando el valor mitad diario. En Atenas, Grecia, Zervas *et al.* (2008) utiliza seis estados de nubosidad diferentes y el número de periodos de 10 minutos de tiempo desde el que se realiza la predicción y el mediodía solar y con predicciones de la irradiación solar global horaria (Mihalakakou *et al.*, 2000) encuentra que de cinco a ocho valores anteriores aumenta la eficiencia y que con más de nueve se mantiene.

En este artículo, se realiza la predicción de la irradiación solar global diaria mediante redes neuronales artificiales (RNAs), utilizando la base de datos de la red SIAR en Castilla y León, en concreto de la estación agrometeorológica situada en Mansilla Mayor (León). El objetivo principal es realizar la mejor predicción utilizando como variables, las propias medidas registradas en la estación, ya que estos modelos representan al propio lugar de los datos utilizados para entrenar las RNAs. Para ello, se probaron RNAs con los datos de uno, dos y tres días de retardo, resultando un rendimiento similar a los modelos clásicos, pero que se mejora añadiendo como predictor el día del año $J(t)=1..365$, que sitúa la predicción en la época del año, y/o el índice de claridad diario $K_t=H/H_0$ como relación del irradiación solar global diaria, que incide sobre la superficie, y la irradiación solar extraterrestre, que llega al tope de la atmósfera para cada día concreto, calculada para cada latitud (Allen, 2006).

2 EQUIPO EXPERIMENTAL

Los datos irradiación solar global diaria utilizados de los años 2004-2011 están recogidos por la estación agrometeorológica de la red SIAR, situada en la localidad

de Mansilla Mayor (León) [Coordenadas: 42°30'43"N 5°26'46"O. Altitud: 791 msnm. Hora local: GMT-21, 725555], proyecto de la Dirección General de Desarrollo Rural del Ministerio de Medio Ambiente y Medio Rural y Marino. En Castilla y León esta información está gestionada por el servicio InfoRiego de asesoramiento al regante desde el Instituto Tecnológico Agrario de Castilla y León (ITACyL), que pretende fomentar el acceso del público a la información relativa de la meteorología en Castilla y León, además de facilitar a los regantes recomendaciones que sirvan para ahorrar agua en el riego.

La irradiancia solar está medida con un piranómetro Skye SP1110 Campbell, que es una fotocélula de silicio sensible a la radiación entre 350-1100 nm, los cambios son detectados, linealizados y amplificados por un circuito electrónico situado en la sonda Vaisala HMP45C Campbell.

3 LA PREDICCIÓN DE LA IRRADIACIÓN SOLAR GLOBAL DIARIA MEDIANTE REDES NEURONALES ARTIFICIALES (RNAs)

En este artículo, para la predicción de la irradiación solar global se utilizan varios modelos black-box, implementados con la técnica de las redes neuronales artificiales (RNAs). El preprocesamiento y el posprocesamiento automático de los datos medidos en la estación agrometeorológica se realiza mediante la interfaz gráfica de usuario (GUI) Neural Network Fitting Toolbox '*nftool*' Matlab. La arquitectura diseñada para ocho modelos RNA 1.8 con diferentes combinaciones de entradas para la predicción de la irradiación solar global del día de mañana [$H(t+1)$] son las presentadas en Figura 1-8.

La capa de salida de los modelos RNA 1.8 tiene una neurona correspondiente a la predicción de la irradiación solar global del día de mañana [$H(t+1)$] en el mismo lugar. En la capa oculta, se probaron diferente número de neuronas, calculando el valor RMSE obtenido para la salida, para seleccionar la arquitectura con los mejores resultados.

La creación de las RNAs se realiza mediante la función '*feedforwardnet*' con los vectores de datos de entrada y salida que determinan el tamaño de sus respectivas capas, para crear una RNA multilayer feed-forward perceptron (MLP), con una capa oculta, donde la función de transferencia de sus neuronas es la tangente sigmoideal hiperbólica '*tansig*' y en la neurona de la capa de salida como lineal '*purelin*'.

El algoritmo back-propagation (BP) Levenberg-Marquardt (LM) se aplica para lograr una optimización rápida '*trainlm*', la función de aprendizaje del sesgo y el momento del peso con gradiente descendente '*learnngdm*', la función normalizada de error cuadrado '*mse*', las funciones de procesamiento de los elementos de la matriz de entrada como el procesamiento de datos para recodificar las filas con datos desconocidos '*fixunknowns*' y los vectores de datos repetidos en la entrada que no proporcionan información útil

'removeconstantrows', y el procesamiento de matrices para normalizar los vectores con valores mínimos y máximos en el rango [-1 1] 'mapminmax'.

El entrenamiento de las RNAs se realiza mediante la función 'train', para cada modelo RNA 1..8, con la matriz de vectores de datos de entrada y la matriz de vectores de datos de salida de los años 2004-2010, registrando el proceso de entrenamiento (*epoch* and *performance*).

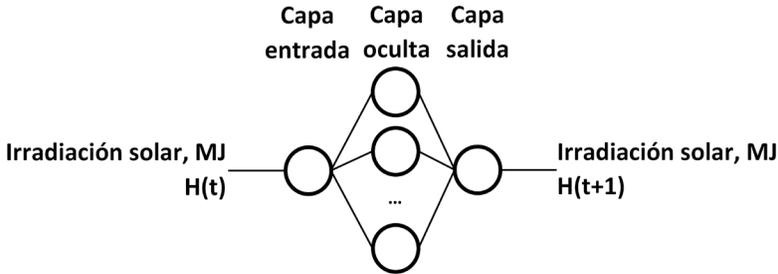
La función 'sim' se utiliza con las RNAs previamente entrenadas, para realizar la predicción de $[H(t+1)]$, con una matriz de vectores de datos de entrada del año 2011.

La GUI Neural Network Fitting Toolbox 'nftool' Matlab muestra los resultados del entrenamiento y la simulación, la arquitectura RNA elegida, los algoritmos de entrenamiento, el rendimiento, cómo se realizaron los conjuntos de datos, la evolución de la progresión en el entrenamiento y la validación.

3.1 MODELO RNA 1

Un modelo RNA 1 con una entrada para la irradiación solar global diaria del día anterior $[H(t)]$ en Figura 1.

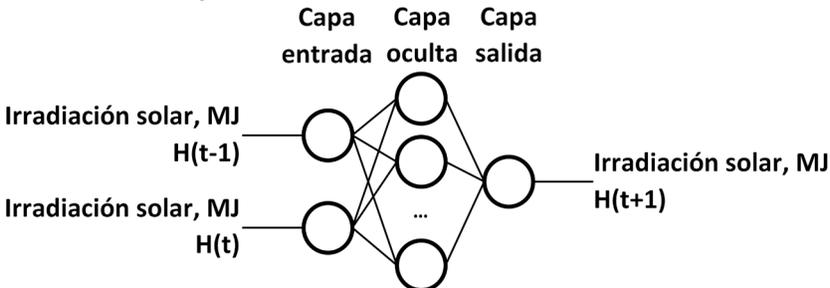
Figura 1. Modelo RNA 1 con una entrada $[H(t)]$.



3.2 MODELO RNA 2

Un modelo RNA 2 con dos entradas para la irradiación solar global diaria de los dos días anteriores $[H(t-1), H(t)]$ en Figura 2.

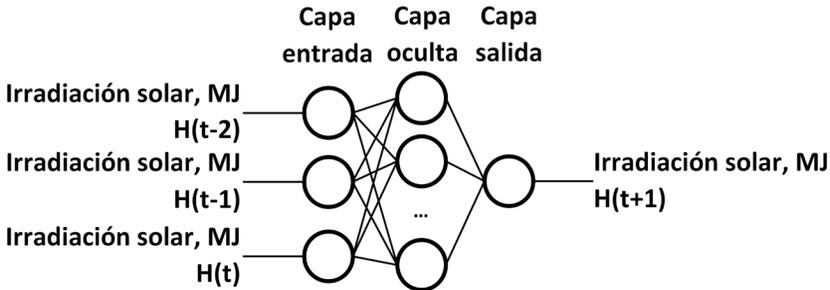
Figura 2. Modelo RNA 2 con dos entradas $[H(t-1), H(t)]$.



3.3 MODELO RNA 3

Un modelo RNA 3 con tres entradas para la irradiación solar global diaria de los tres días anteriores [$H(t-2), H(t-1), H(t)$] en Figura 3.

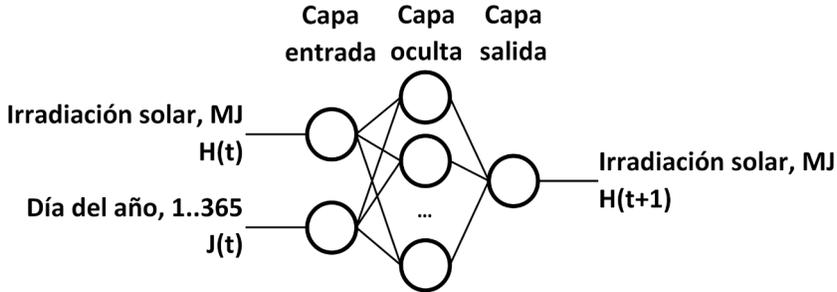
Figura 3. Modelo RNA 3 con tres entradas [$H(t-2), H(t-1), H(t)$].



3.4 MODELO RNA 4

Un modelo RNA 4 con dos entradas para la irradiación solar global diaria del día anterior y el día del año [$H(t), J(t)$] en Figura 4.

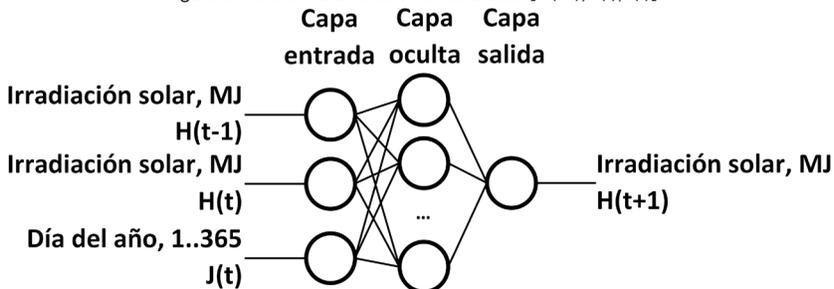
Figura 4. Modelo RNA 4 con dos entradas [$H(t), J(t)$].



3.5 MODELO RNA 5

Un modelo RNA 5 con tres entradas para la irradiación solar global diaria de los dos días anteriores y el día del año [$H(t-1), H(t), J(t)$] en Figura 5.

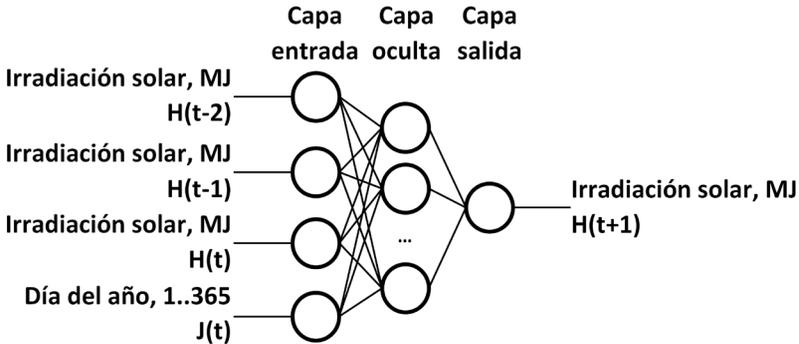
Figura 5. Modelo RNA 5 con tres entradas [$H(t-1), H(t), J(t)$].



3.6 MODELO RNA 6

Un modelo RNA 6 con cuatro entradas para la irradiación solar global diaria de los tres días anteriores y el día del año $[H(t-2), H(t-1), H(t), J(t)]$ en Figura 6.

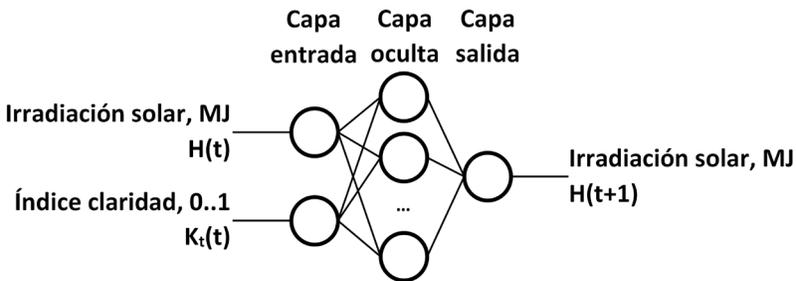
Figura 6. Modelo RNA 6 con cuatro entradas $[H(t-2), H(t-1), H(t), J(t)]$.



3.7 MODELO RNA 7

Un modelo RNA 7 con dos entradas para la irradiación solar global diaria y el índice de claridad $K_t = H/H_0$ del día anterior $[H(t), K_t(t)]$ en Figura 7.

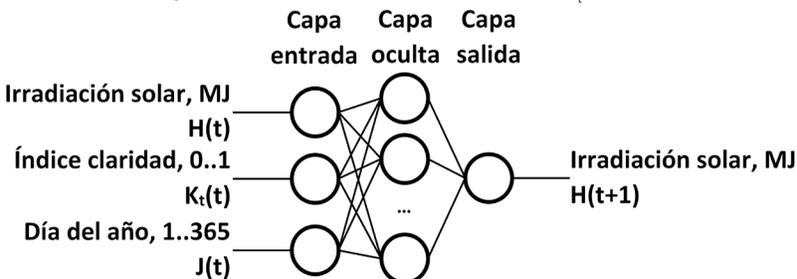
Figura 7. Modelo RNA 7 con dos entradas $[H(t), K_t(t)]$.



3.8 MODELO RNA 8

Un modelo RNA 8 con tres entradas para la irradiación solar global diaria, el índice de claridad $K_t = H/H_0$ del día anterior y el día del año $[H(t), K_t(t), J(t)]$ en Figura 8.

Figura 8. Modelo RNA 8 con tres entradas $[H(t), K_t(t), J(t)]$.



4 LA PREDICCIÓN DE LA IRRADIACIÓN SOLAR GLOBAL DIARIA MEDIANTE MODELOS CLÁSICOS

En este apartado se presentan los modelos clásicos de predicción de la irradiación solar global diaria sobre la superficie horizontal: 1) año típico CENSOLAR a escala provincial, 2) media móvil ponderada, en este caso, con la autocorrelación parcial de 2 a 20 días de retardo, 3) regresión lineal del valor diario de irradiación solar, sobre el valor del día anterior, 4) año típico del análisis de Fourier para 1 a 8 armónicos, y 5) análisis de Markov para 33 estados posibles de irradiación solar diaria. La construcción de los modelos se realizó con la serie de datos de los años 2004-2010 y para la comparación de sus predicciones se utilizaron los datos del año 2011.

4.1 AÑO TÍPICO CENSOLAR

Los valores de la irradiación solar global horizontal de las tablas CENSOLAR (2009) representan un año típico a escala provincial de un día medio para cada mes del año.

4.2 MEDIA MÓVIL PONDERADA CON LA AUTOCORRELACIÓN PARCIAL

La autocorrelación parcial hace referencia a la dependencia del valor de una determinada variable estadística con valores de esa misma variable precedentes en el tiempo. La media móvil ponderada se utiliza dando más peso a los valores más próximos y menos a los más alejados intentando que la media se comporte de forma más ágil en relación a una media móvil simple.

En este artículo, se utilizaron los coeficientes de autocorrelación parcial de la serie de datos de los años 2004-2010 de irradiación solar global diaria, obtenidos con la función '*parcorr*' Matlab, para realizar la media móvil ponderada con retardos de tiempo de 2 a 20 días durante el año 2011. Los coeficientes de autocorrelación parcial se aplican con el valor de irradiación solar correspondiente a su día de retardo, realizando el sumatorio de sus productos y dividiendo por el sumatorio de los pesos asignados por los coeficientes de autocorrelación parcial del orden utilizado, dando más importancia a los valores más próximos que a los valores más alejados.

4.3 REGRESIÓN LINEAL

La predicción de la irradiación solar global diaria del día de mañana se realizó mediante la regresión lineal, que modela la relación entre una variable dependiente en este caso el valor de la irradiación solar global del día de mañana $H(t+1)$, la variable independiente, en este caso, con el valor de la irradiación solar global del día de hoy $H(t)$ y

un término aleatorio calculado con Curve Fitting Toolbox 'cftool' Matlab, aplicando la serie de datos de los años 2004-2010.

4.4 ANÁLISIS DE FOURIER

El análisis de Fourier se aplica a las variables que muestran frecuencias significativas como es el caso de la irradiación solar global diaria. La ecuación representativa del año se obtiene con varios armónicos. Para el cálculo de los coeficientes de los ocho primeros armónicos se utilizó Curve Fitting Toolbox 'cftool' Matlab, aplicando la serie de datos de los años 2004-2010.

4.5 ANÁLISIS DE MARKOV

En un proceso aleatorio donde se produce un cambio de estado entre ciertos estados en el tiempo, teniendo un número finito de estados posibles, surge una sucesión o cadena de situaciones, donde cada una es igual a uno de los estados, este proceso se llama cadena de Markov.

En este artículo, se definieron los estados, uno por cada valor entero de la irradiación solar global diaria en los valores enteros de la unidad en Megajulios (MJ) posibles de la serie de datos de los años 2004-2010, para ello:

1. Se redondea todos los valores y se les asignó ese estado, para ello se utilizó la función 'round' MATLAB.
2. Se busca el valor máximo y mínimo de la serie de datos de la irradiación solar global diaria resultando 33 estados posibles, con las funciones 'max' y 'min' Matlab.
3. Se crea una matriz con las transiciones, existentes en la serie de datos de los años 2004-2010, una para cada fila en la matriz b .

$$b = \begin{bmatrix} x_1 & x_2 \\ x_2 & x_3 \\ \dots & \dots \\ x_{n-1} & x_n \end{bmatrix}$$

4. Se crea una matriz de probabilidades, matriz de transiciones de Markov (MTM), con el número de transiciones para cada estado en la serie de datos mediante la función Matlab en Figura 9, que recorre los cambios de estado de la serie de datos matriz b y actualiza la matriz de transición de Markov (MTM), donde cada elemento de la matriz tiene el número de cambios habidos en la serie de datos entre el estado representado por el número de la fila hacia el estado representado por el número de la columna.

Figura 9. Función Matlab para crear la matriz de probabilidades, Matriz de Transiciones de Markov MTM.

$$MTM = \begin{bmatrix} 1 \rightarrow 1 & 1 \rightarrow 2 & \dots & 1 \rightarrow 33 \\ 2 \rightarrow 1 & 2 \rightarrow 2 & \dots & 2 \rightarrow 33 \\ \vdots & \vdots & \ddots & \vdots \\ 33 \rightarrow 1 & 33 \rightarrow 2 & \dots & 33 \rightarrow 33 \end{bmatrix}$$

```
function a=mtm(b) %Matriz de Transición de Markov
a=zeros(33);
for i=1:2556 %Recorrer cambios estados de la base de datos
    x=b(i,1);
    y=b(i,2);
    a(x,y)=a(x,y)+1; %Actualiza la Matriz de Transición de Markov
end
```

5. Se normaliza la matriz de transición de Markov (MTM) para cada fila, dividiendo cada elemento de la fila por el valor de la suma de todos sus elementos, resultando la matriz de transición de Markov normalizada (MTMN), que tiene como suma de los elementos en todas las filas el valor 1.
6. Se calcula la probabilidad de cambio de estado para el día de mañana a partir del estado de hoy, multiplicando el vector del estado inicial de hoy con la matriz de transición de Markov normalizada (MTMN), resultando un vector, en el que la posición, donde se encuentre el valor más alto, será el estado, que tenga más probabilidad de suceder mañana, mediante la función Matlab en Figura 10.

Figura 10. Función Matlab para realizar la predicción [H(t+1)] multiplicando el vector de estado del día [H(t)] con la matriz de transición de Markov normalizada (MTMN).

```
function p=pmarkov(a,d) %Pronóstico para un año, respecto del día anterior
p=zeros(365,1);
r=zeros(1,33);
for i=1:365
    x=d(i,1);
    r(1,x)=1;
    m=r*a; %Multiplica vector del estado inicial por matriz de transición
    [ymax,posimax]=max(m);
    p(i,1)=posimax; %Estado de la máxima probabilidad
    r=zeros(1,33);
end
```

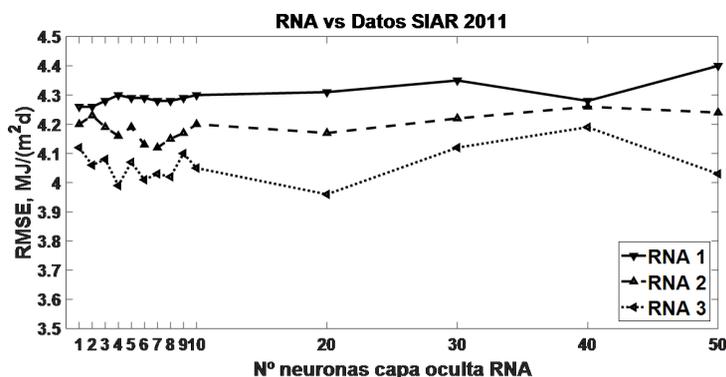
5 RESULTADOS Y DISCUSIÓN

En este apartado se aplican las metodologías desarrolladas, propuestas para la predicción de la irradiación solar global diaria. Los resultados de las metodologías de predicción se aplican y validan con la base de datos SIAR en la estación de Mansilla Mayor (León) durante el año 2011, mediante el estadístico Root Mean Square Error (RMSE) para realizar una primera selección de los modelos predictivos, encontrando el modelo de predicción que presente el mínimo error con la ventaja de que sus resultados están en las unidades originales de la información. También se utiliza el Coeficiente de Determinación (R^2) para describir la bondad o ajuste del modelo, Durbin-Watson (DW) para detectar la autocorrelación de primer orden, Mean Percentage Error (MPE) para el sesgo del error de la predicción, Forecast Accuracy (FA) para realizar una medida de la precisión de los modelos de predicción a corto plazo, y Akaike Information Criterion (AIC) para seleccionar el mejor modelo tomando en cuenta el número de variables penalizando la complejidad del modelo.

Los resultados de la metodología para la predicción de la irradiación solar global diaria mediante los modelos RNA 1,2,3 a partir de los datos de la irradiación solar global diaria con uno, dos o tres días de retardo, implementadas con distinto número de neuronas en la capa oculta se estudian mediante el estadístico RMSE en Figura 11. Los mejores resultados de la predicción realizada para el modelo RNA 1 fue con la red (1-1-1) RMSE=4,26 MJ/(m²d), para el modelo RNA 2 fue con la red (2-7-1) RMSE=4,12 MJ/(m²d) y para el modelo RNA 3 fue con la red (3-20-1) RMSE=3,96 MJ/(m²d).

El rendimiento de los modelos aumenta, al considerar la irradiación solar global diaria de más días de retardo de forma parecida a la media móvil ponderada. El ajuste es similar a los métodos clásicos de la literatura probados.

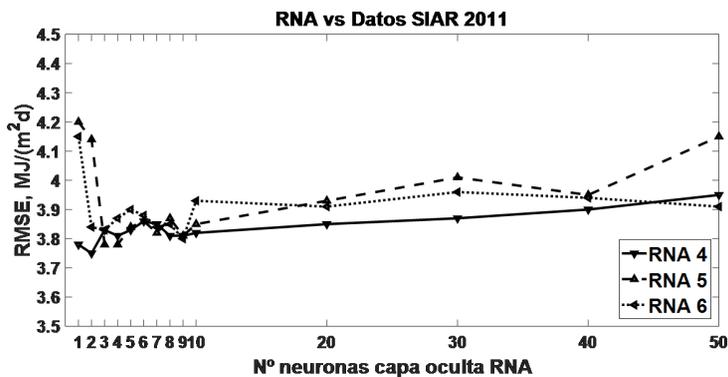
Figura 11. Eficacia de los modelos RNA 1,2,3 con diferente número de neuronas en la capa oculta vs Datos año 2011 SIAR.



Los resultados de la metodología para la predicción de la irradiación solar global diaria mediante los modelos RNA 4,5,6 a partir de los datos de la irradiación solar global diaria con uno, dos o tres días de retardo y el día del año, implementadas con distinto número de neuronas en la capa oculta se estudia mediante el estadístico RMSE en Figura 12. Los mejores resultados de la predicción realizada para el modelo RNA 4 fue con la red (2-2-1) RMSE=3,75 MJ/(m²d), para el modelo RNA 5 fue con la red (3-4-1) RMSE=3,78 MJ/(m²d) y para el modelo RNA 6 fue con la red (4-4-1) RMSE=3,80 MJ/(m²d).

El rendimiento de los modelos, para estos casos, no varía significativamente al considerar la irradiación solar global diaria de más días de retardo. El ajuste es mejor que la primera serie de modelos RNA 1,2,3 que no utilizan el día del año como variable predictiva, mejorando a los métodos clásicos de la literatura probados. También se observa, que utilizar el día del año como predictor mejora el rendimiento del modelo, ya que se introduce un parámetro que indica la época o estación del año cuando se realiza la predicción, porque la irradiación solar extraterrestre diaria en el tope de la atmosfera varía anualmente en forma senoidal.

Figura 12. Eficacia de los modelos RNA 4,5,6 con diferente número de neuronas en la capa oculta vs Datos año 2011 SIAR.

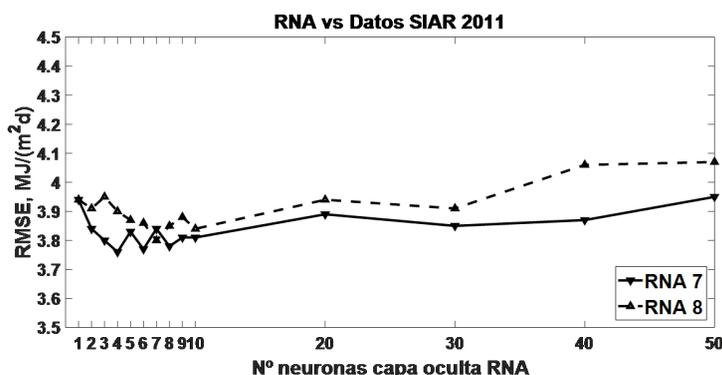


Los resultados de la metodología para la predicción de la irradiación solar global diaria mediante los modelos RNA 7,8 a partir de los datos de la irradiación solar global diaria con un de retardo, el día del año o el índice de claridad, implementadas con distinto número de neuronas en la capa oculta se estudia mediante el estadístico RMSE en Figura 13. Los mejores resultados de la predicción realizada para el modelo RNA 7 fue con la red (2-4-1) RMSE=3,76 MJ/(m²d) y para el modelo RNA 8 fue con la red (3-7-1) RMSE=3,80 MJ/(m²d).

El rendimiento del modelo mejora al considerar el índice de claridad diario, pero utilizar el día del año o el índice de claridad como predictor obtiene resultados parecidos,

con lo que utilizar el día del año es un valor más sencillo de manejar que el índice de claridad y produce rendimientos similares.

Figura 13. Eficacia de los modelos RNA 7,8 con diferente número de neuronas en la capa oculta vs Datos año 2011 SIAR.



Por lo que se observa de las predicciones realizadas con los modelos RNA 1..8 durante el año 2011 en Figura 14 y los resultados estadísticos evaluados para comprobar su efectividad en Tabla 1.

Los modelos RNA 2 [H(t-1),H(t)], RNA 4 [H(t),J(t)] y RNA 7 [H(t),Kt(t)] presentan el menor grado de autocorrelación mediante el estadístico DW.

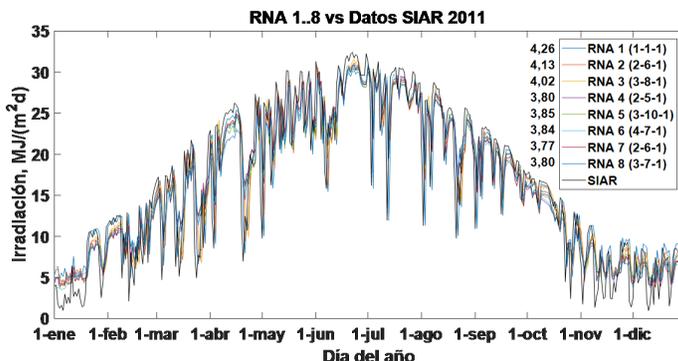
La efectividad del modelo RNA 7 [H(t),Kt(t)] y RNA 6 [H(t-2),H(t-1),H(t),J(t)] consigue los mejores resultados, mediante el estadístico FA que analiza las predicciones a corto plazo y mediante el estadístico MPE que valora el sesgo del error la predicción.

La efectividad del modelo RNA 7 [H(t),Kt(t)] y RNA 4 [H(t),J(t)] obtiene los mejores resultados, respecto al mínimo error RMSE, a su ajuste mediante el estadístico R² y a su complejidad mediante el estadístico AIC.

Tabla 1. Efectividad de los modelos RNA 1..8 de predicción vs Datos SIAR en Mansilla Mayor (León) para el año 2011

Modelos RNA 1..8 [H(t+1)] vs Irradiación solar global diaria horizontal año 2011 Mansilla Mayor (León)							
	Red	RMSE, MJ/ (m²d)	R²	DW	MPE	FA	AIC
RNA 1 [H(t)]	(1-1-1)	4,2609	0,7862	2,2632	-0,2523	0,5884	4,2835
RNA 2 [H(t-1),H(t)]	(2-6-1)	4,1292	0,7988	1,9703	-0,2517	0,5940	4,1733
RNA 3 [H(t-2),H(t-1),H(t)]	(3-8-1)	4,0204	0,8088	1,8543	-0,2507	0,5938	4,0830
RNA 4 [H(t),J(t)]	(2-5-1)	3,8012	0,8299	1,9263	-0,2154	0,6196	3,8427
RNA 5 [H(t-1),H(t),J(t)]	(3-10-1)	3,8467	0,8253	1,9061	-0,2232	0,6160	3,9106
RNA 6 [H(t-2),H(t-1),H(t),J(t)]	(4-7-1)	3,8431	0,8253	1,8007	-0,2032	0,6277	3,9261
RNA 7 [H(t),K _t (t)]	(2-6-1)	3,7703	0,8326	1,9183	-0,2022	0,6324	3,8118
RNA 8 [H(t),K _t (t),J(t)]	(3-7-1)	3,8043	0,8297	1,8716	-0,2273	0,6098	3,8662

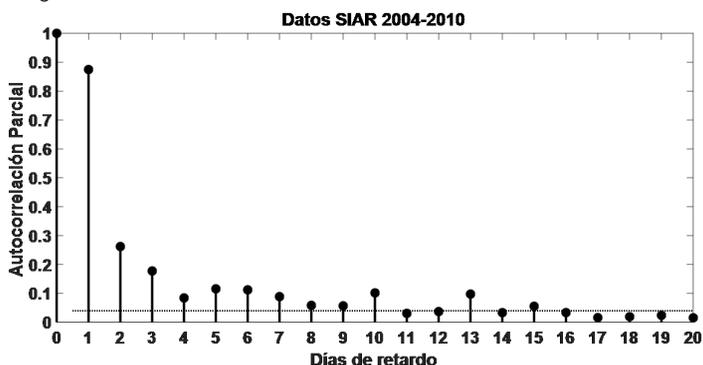
Figura 14. Modelos RNA 1..8 vs Datos año 2011 SIAR.



Los valores de la irradiación solar global diaria horizontal para la provincia de León en las tablas CENSOLAR, se representan junto a los datos del año 2011 SIAR en Mansilla Mayor (León) con un RMSE=5,1829 MJ/(m²d) en Figura 19. Este año típico ofrece una buena aproximación, además de ser rápida y sencilla su aplicación, pero no tienen en cuenta las variaciones diarias para cada día del mes.

Los coeficientes de autocorrelación parcial resultantes de la serie de datos de los años 2004-2010 SIAR en Mansilla Mayor (León) para retardos de tiempo de 1 a 20 días en Figura 15, muestran que la dependencia de la irradiación solar global diaria en un determinado día es máxima con la del día anterior 0,8747, disminuyendo esa dependencia rápidamente con la irradiación solar recibida en días anteriores: 0,2622 para 2 días, 0,1777 para 3 días, 0,0843 para 4 días.

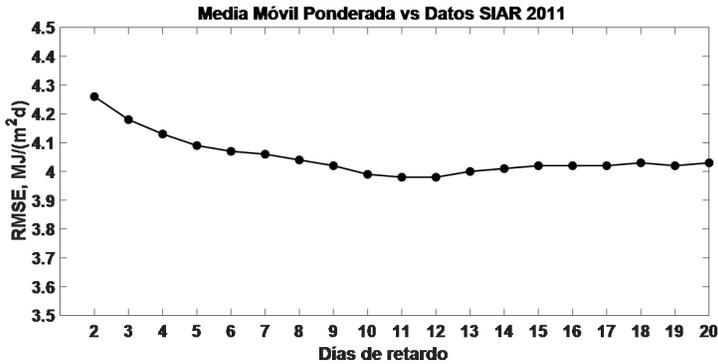
Figura 15. Autocorrelación parcial para retardos de tiempo de 1-20 días en los datos de los años 2004-2010 SIAR de irradiación solar global diaria.



La media móvil ponderado con los coeficientes de autocorrelación parcial de 2 a 20 días de retardo se utiliza para la predicción de la irradiación solar global diaria durante el año 2011 con un error para cada predicción RMSE en Figura 16. Obteniendo el mejor resultado para 11 días de retardo mediante la ecuación (Ec. 1) con un valor RMSE=3,9810 MJ/(m²d) en Figura 19.

$$H_{t+1} = \frac{0,8747 H_t + 0,2622 H_{t-1} + 0,1777 H_{t-2} + 0,0843 H_{t-3} + 0,1158 H_{t-4} + 0,1123 H_{t-5} + 0,0888 H_{t-6} + 0,0585 H_{t-7} + 0,0570 H_{t-8} + 0,1018 H_{t-9} + 0,0309 H_{t-10}}{0,8747 + 0,2622 + 0,1777 + 0,0843 + 0,1158 + 0,1123 + 0,0888 + 0,0585 + 0,0570 + 0,1018 + 0,0309} \quad (1)$$

Figura 16. Eficacia de la media móvil ponderada de 2-20 días de retardo vs Datos año 2011 SIAR.

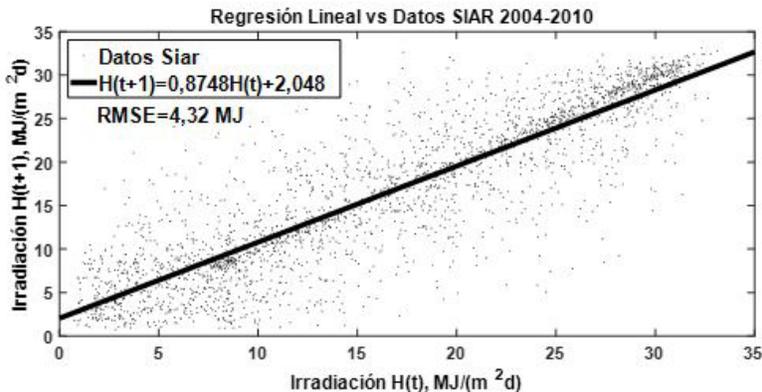


Se pueden utilizar estas correlaciones para una buena predicción, mejorando los resultados de las tablas CENSOLAR, al realizar una predicción diaria sobre los valores registrados en los días anteriores. La autocorrelación parcial más fuerte se produce con un día de retardo, que confirma la persistencia radiativa de un día para el siguiente, disminuyendo drásticamente para los días siguientes, pero que se pueden utilizar para mejorar ligeramente las predicciones.

La regresión lineal respecto a un día de retardo mediante la ecuación (Ec. 2) obtenida de los datos de la irradiación solar global de los años 2004-2010 SIAR en Mansilla Mayor (León) con un valor RMSE=4,32 MJ/(m²d) en Figura 17. Se utiliza para la predicción de la irradiación solar global diaria durante el año 2011 con un valor RMSE=4,2434 MJ/(m²d) en Figura 19. Se puede utilizar esta regresión para una buena predicción, similar a la media móvil ponderada, debido a la persistencia radiativa diaria.

$$H(t+1)=0,8748 H(t)+2,048 \quad (2)$$

Figura 17. Regresión lineal de un día de retardo vs Datos de los años 2004-2010 SIAR.

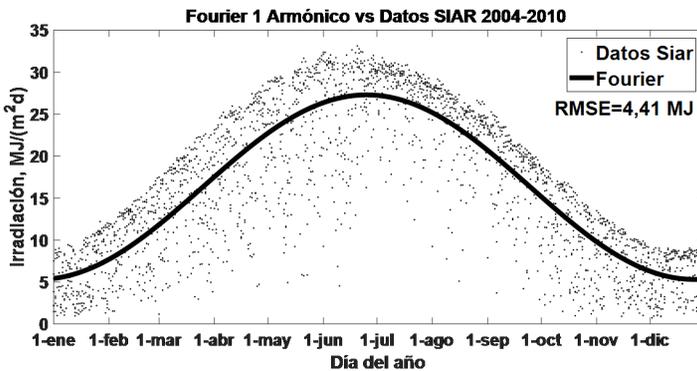


El análisis de Fourier efectuado con el cálculo de los coeficientes de los datos de la irradiación solar global diaria de los años 2004-2010 SIAR en Mansilla Mayor (León), obtienen las funciones anuales típicas que se muestran en la Tabla 2 desde el primer al octavo armónico, el error producido para cada función disminuye ligeramente con el número de armónicos considerados. En Figura 18 se muestra el caso del primer armónico respecto a los datos de los años 2004-2011 con un valor RMSE=4,417 MJ/(m²d) y respecto a los datos del año 2011 con un valor RMSE=4,2747 MJ/(m²d) en Figura 19. El ajuste es similar a la media móvil ponderada, pero la utilización de más de un armónico no aporta mejora significativa.

Tabla 2. Funciones anuales típicas de Fourier de los datos de los años 2004-2010 de la irradiación solar global diaria en Mansilla Mayor (León), del primer al octavo armónico y el RMSE

Irradiación solar global diaria años 2004-2010 SIAR Mansilla Mayor		
Nº de armónicos	Función anual típica de Fourier	RMSE, MJ/(m²d)
1	$H(t) = 16,31 - 10,9 \cos(0,01712 t) + 1,383 \sin(0,01712 t)$	4,417
2	$H(t) = 16,79 - 10,75 \cos(0,01792 t) - 0,1918 \sin(0,01792 t) - 0,4302 \cos(2 \cdot 0,01792 t) + 0,9119 \sin(2 \cdot 0,01792 t)$	4,372
3	$H(t) = 16,82 - 10,72 \cos(0,01795 t) - 0,2652 \sin(0,01795 t) - 0,4444 \cos(2 \cdot 0,01795 t) + 0,9129 \sin(2 \cdot 0,01795 t) - 0,1614 \cos(3 \cdot 0,01795 t) - 0,2203 \sin(3 \cdot 0,01795 t)$	4,370
4	$H(t) = 14 - 8,82 \cos(0,01374 t) + 7,663 \sin(0,01374 t) + 0,4119 \cos(2 \cdot 0,01374 t) - 1,859 \sin(2 \cdot 0,01374 t) - 1,071 \cos(3 \cdot 0,01374 t) + 0,2203 \sin(3 \cdot 0,01374 t) - 0,1655 \cos(4 \cdot 0,01374 t) + 0,1346 \sin(4 \cdot 0,01374 t)$	4,365
5	$H(t) = 15,95 - 10,9 \cos(0,01659 t) + 2,442 \sin(0,01659 t) + 0,4894 \cos(2 \cdot 0,01659 t) + 0,62 \sin(2 \cdot 0,01659 t) - 0,2298 \cos(3 \cdot 0,01659 t) - 0,438 \sin(3 \cdot 0,01659 t) - 0,08166 \cos(4 \cdot 0,01659 t) - 0,2479 \sin(4 \cdot 0,01659 t) - 0,4204 \cos(5 \cdot 0,01659 t) - 0,1472 \sin(5 \cdot 0,01659 t)$	4,360
6	$H(t) = 15,59 - 10,71 \cos(0,01601 t) + 3,58 \sin(0,01601 t) + 0,8222 \cos(2 \cdot 0,01601 t) + 0,2469 \sin(2 \cdot 0,01601 t) - 0,3552 \cos(3 \cdot 0,01601 t) - 0,5187 \sin(3 \cdot 0,01601 t) - 0,1731 \cos(4 \cdot 0,01601 t) - 0,2608 \sin(4 \cdot 0,01601 t) - 0,3646 \cos(5 \cdot 0,01601 t) + 0,01903 \sin(5 \cdot 0,01601 t) + 0,1542 \cos(6 \cdot 0,01601 t) - 0,2483 \sin(6 \cdot 0,01601 t)$	4,358
7	$H(t) = 15,62 - 10,77 \cos(0,01608 t) + 3,439 \sin(0,01608 t) + 0,7548 \cos(2 \cdot 0,01608 t) + 0,3084 \sin(2 \cdot 0,01608 t) - 0,3652 \cos(3 \cdot 0,01608 t) - 0,502 \sin(3 \cdot 0,01608 t) - 0,1898 \cos(4 \cdot 0,01608 t) - 0,2505 \sin(4 \cdot 0,01608 t) - 0,4033 \cos(5 \cdot 0,01608 t) + 0,0155 \sin(5 \cdot 0,01608 t) + 0,1429 \cos(6 \cdot 0,01608 t) - 0,2134 \sin(6 \cdot 0,01608 t) - 0,2898 \cos(7 \cdot 0,01608 t) + 0,05327 \sin(7 \cdot 0,01608 t)$	4,355
8	$H(t) = 15,9 - 10,88 \cos(0,01608 t) + 2,604 \sin(0,01608 t) + 0,5436 \cos(2 \cdot 0,01608 t) + 0,5728 \sin(2 \cdot 0,01608 t) - 0,243 \cos(3 \cdot 0,01608 t) - 0,4557 \sin(3 \cdot 0,01608 t) - 0,09469 \cos(4 \cdot 0,01608 t) - 0,2583 \sin(4 \cdot 0,01608 t) - 0,4202 \cos(5 \cdot 0,01608 t) - 0,1266 \sin(5 \cdot 0,01608 t) + 0,2067 \cos(6 \cdot 0,01608 t) - 0,1177 \sin(6 \cdot 0,01608 t) - 0,2595 \cos(7 \cdot 0,01608 t) - 0,1288 \sin(7 \cdot 0,01608 t) - 0,1798 \cos(8 \cdot 0,01608 t) - 0,04178 \sin(8 \cdot 0,01608 t)$	4,355

Figura 18. Función anual típica de Fourier con el primer armónico vs Datos de los años 2004-2010 SIAR.



El análisis de Markov utilizado para la predicción de la irradiación solar global diaria del año 2011 resulta con un valor $RMSE=4,3653 \text{ MJ}/(\text{m}^2\text{d})$ en Figura 19. El ajuste es similar al análisis de Fourier, pero en este caso se basa en las probabilidades de cambio de estado de un día para otro.

Por lo que se observa de las predicciones realizadas con los modelos clásicos durante el año 2011 en Figura 19 y los resultados estadísticos evaluados para comprobar su efectividad en Tabla 3.

Los modelos Media Móvil $[H(t-1),H(t)]$, Media Móvil $[H(t-10),\dots,H(t)]$ y Regresión Lineal $[H(t)]$ presentan el menor grado de autocorrelación mediante el estadístico DW.

La efectividad del modelo Media Móvil $[H(t-10),\dots,H(t)]$ consigue el mejor resultado, respecto al mínimo error RMSE, a su ajuste mediante el estadístico R^2 y a su complejidad mediante el estadístico AIC. Pero, los demás modelos clásicos les siguen con resultados parecidos, excepto el año típico CENSOLAR, que obtiene el peor resultado, salvo mediante el estadístico MPE que valora el sesgo del error la predicción, al ser una media diaria mensual.

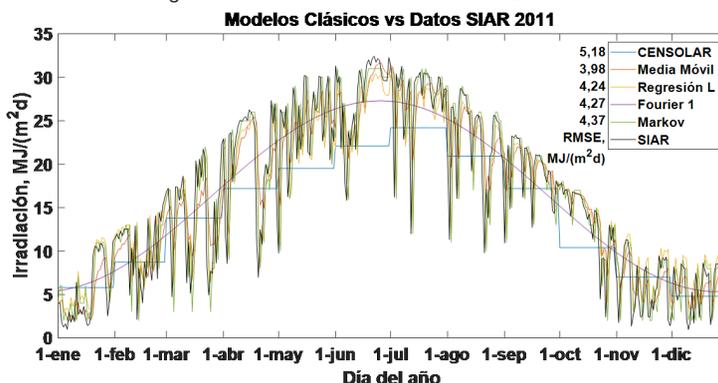
La efectividad del modelo Media Móvil $[H(t-1),H(t)]$ consigue el mejor resultado, mediante el estadístico FA que analiza las predicciones a corto plazo, al utilizar dos días de retardo.

Tabla 3. Efectividad de los modelos clásicos de predicción vs Datos SIAR en Mansilla Mayor (León) para el año 2011

Modelos Clásicos $[H(t+1)]$ vs Irradiación solar global diaria horizontal año 2011 Mansilla Mayor (León)						
	RMSE, MJ/(m²d)	R²	DW	MPE	FA	AIC
CENSOLAR [León]	5,1829	0,6837	0,7092	-0,1342	0,5286	5,2105
Media Móvil $[H(t-1),H(t)]$	4,2582	0,7865	2,0952	-0,1366	0,6589	4,3048
Media Móvil $[H(t-10),\dots,H(t)]$	3,9810	0,8134	1,7265	-0,1682	0,6493	4,2283

	RMSE, MJ/(m ² d)	R ²	DW	MPE	FA	AIC
Regresión Lineal [H(t)]	4,2434	0,7880	2,2880	-0,2234	0,6103	4,2666
Fourier 1 ^{er} Armónico	4,2747	0,7848	1,0439	-0,2692	0,5294	4,2974
Fourier 2 ^o Armónico	4,2626	0,7861	1,0498	-0,2629	0,5381	4,3086
Fourier 3 ^o Armónico	4,2675	0,7856	1,0474	-0,2617	0,5388	4,3374
Fourier 4 ^o Armónico	4,2618	0,7861	1,0499	-0,2560	0,5466	4,3562
Fourier 5 ^o Armónico	4,2465	0,7877	1,0575	-0,2580	0,5439	4,3642
Fourier 6 ^o Armónico	4,2552	0,7868	1,0532	-0,2577	0,5444	4,3971
Fourier 7 ^o Armónico	4,2537	0,7869	1,0539	-0,2547	0,5490	4,4199
Fourier 8 ^o Armónico	4,2557	0,7867	1,0529	-0,2543	0,5495	4,4463
Markov [H(t)]	4,3653	0,7756	2,4099	-0,1525	0,6497	4,3892

Figura 19. Modelos clásicos vs Datos año 2011 SIAR.



6 CONCLUSIONES

Una de las características más interesantes de las redes neuronales artificiales es su capacidad de aprender y modelar un fenómeno. Para establecer la predicción, un número fijo de valores anteriores se establece como entradas de la RNA, la salida es la predicción del valor futuro de la serie de tiempo.

La predicción de la irradiación solar global que recibirá la superficie horizontal el día de mañana, se realizó utilizando las redes neuronales artificiales (RNAs), procurando el mínimo número de entradas para facilitar su uso, con datos de una estación agrometeorológica local. Se probaron los modelos más sencillos posibles, para que su utilización sea práctica en cualquier lugar, donde se disponga de una serie de datos de irradiación solar global diaria horizontal, ya sea medida en el propio lugar o como alternativa, la estimada por los satélites artificiales o desde otras variables ambientales (temperatura ambiente y horas de insolación).

En las predicciones realizadas se utilizaron los datos de irradiación solar global del día anterior, dos días y tres días de retardo, con lo que se mejora su rendimiento respecto a los modelos clásicos estudiados (año típico CENSOLAR, media móvil con 2 días de retardo, regresión lineal, análisis de Fourier y Markov), salvo la media móvil con 11 días de retardo que obtiene mejor resultado. Pero, que los modelos RNA superan a este último cuando la red utiliza como variable de entrada el día del año $J(t) = [1..365]$ al tener conocimiento de la época del año en la que se hace la predicción. Se observa para este caso, que utilizar los datos de irradiación solar de más días de retardo ya no aporta mejora en la predicción como en los primeros modelos.

Una segunda mejora en el modelo RNA se consigue utilizando el índice de claridad $K_t = H/H_0$ como relación de la irradiación solar que incide en la superficie y la irradiación solar que llega al tope de la atmosfera, al tener conocimiento de la proporción de irradiación solar diaria que es absorbida y dispersada por la atmósfera.

Para mejorar la predicción de la irradiación solar global diaria sobre la superficie horizontal, se pretende seguir desarrollando nuevos modelos RNA: 1) Utilizando otras variables explicativas como pueden ser la humedad, la presión atmosférica, la nubosidad,... que contribuyan a detectar cambios en su evolución, principalmente, durante los días de cambios bruscos, que es donde presenta los peores resultados los modelos RNA utilizados en este artículo. 2) El estudio por separado de los datos para cada época del año que tienen características similares. 3) La mejora del rendimiento de los modelos neurales también puede realizarse a partir de las predicciones de los servicios meteorológicos en lugar de utilizar únicamente los datos históricos registrados en la zona. 4) Otra posibilidad de mejora en las predicciones es la combinación de los modelos de predicción para el aumento de su rendimiento.

REFERENCIAS

Aitkenhead, M.J., McDonald, A.J.S., Dawson, J.J., Couper, G., Smart, R.P., Billett, M., Hope D. & Palmer S. (2003). A novel method for training neural networks for time-series prediction in environmental systems. *Ecological Modelling*, 162(1–2), 87–95.

Al-Alawi, S.M. & Al-Hinai, H.A. (1998). An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation. *Renewable Energy*, 14(1–4), 199–204.

Allen, R.G. (2006). *Evapotranspiración del cultivo: Guías para la determinación de los requerimientos de agua de los cultivos*. Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO).

Azadeh, A., Maghsoudi, A. & Sohrabkhani, S. (2009). An integrated artificial neural networks approach for predicting global radiation. *Energy Conversion and Management*, 50(6), 1497–1505.

- Behrang, M.A., Assareh, E., Ghanbarzadeh, A. & Noghrehabadi, A.R. (2010). The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. *Solar Energy*, 84(8), 1468–1480.
- Benghanem, M., Mellit, A. & Alamri S.N. (2009). ANN-based modelling and estimation of daily global solar radiation data: A case study. *Energy Conversion and Management*, 50(7), 1644–1655.
- Camacho, E.F., Berenguel, M., Rubio, F.R. & Martínez, D. (2012). *Control of solar energy systems*. Springer.
- Cao, J. & Lin, X. (2008a). Application of the diagonal recurrent wavelet neural network to solar irradiation forecast assisted with fuzzy technique. *Engineering Applications of Artificial Intelligence*, 21(8), 1255–1263.
- Cao, J. & Lin, X. (2008b). Study of hourly and daily solar irradiation forecast using diagonal recurrent wavelet neural networks. *Energy Conversion and Management*, 49(6), 1396–1406.
- Cao, J.C. & Cao, S.H. (2006). Study of forecasting solar irradiance using neural networks with preprocessing sample data by wavelet analysis. *Energy*, 31(15), 3435–3445.
- Cao, S. & Cao, J. (2005). Forecast of solar irradiance using recurrent neural networks combined with wavelet analysis. *Applied Thermal Engineering*, 25(2–3), 161–172.
- CENSOLAR. (2009). *Instalaciones de energía solar térmica. Pliego de condiciones técnicas de instalaciones de baja temperatura*. Instituto para la Diversificación y Ahorro de la Energía (IDAE).
- Dorvlo, A.S.S., Jervase, J.A. & Al-Lawati A. (2002). Solar radiation estimation using artificial neural networks. *Applied Energy*, 71(4), 307–319.
- Elminir, H.K., Azzam, Y.A. & Younes, F.I. (2007). Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. *Energy*, 32(8), 1513–1523.
- Gardner, M.W. & Dorling, S.R. (1998). Artificial neural networks (the multilayer perceptron) – a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14–15): 2627–2636.
- Gueymard, C.A. & Myers, D.R. (2008). Validation and ranking methodologies for solar radiation models. En Badescu V. (ed.), *Modeling solar radiation at the earth's surface* (pp. 479–509). Springer.
- Hocaoğlu, F.O., Gerek, Ö.N. & Kurban, M. (2008). Hourly solar radiation forecasting using optimal coefficient 2-D linear filters and feed-forward neural networks. *Solar Energy*, 82(8), 714–726.
- Hontoria, L., Aguilera, J. & Zufiria, P. (2002). Generation of hourly irradiation synthetic series using the neural network multilayer perceptron. *Solar Energy*, 72(5), 441–446.
- Hontoria, L., Aguilera, J. & Zufiria, P. (2005). An application of the multilayer perceptron: Solar radiation maps in Spain. *Solar Energy*, 79(5), 523–530.
- Iqdour, R. & Zeroual, A. (2007). The multi-layered perceptrons neural networks for the prediction of daily solar radiation. *International Journal of Information and Communication Engineering*, 3(1), 24–29.
- Kemmoku, Y., Orita, S., Nakagawa, S. & Sakakibara, T. (1999). Daily insolation forecasting using a multi-stage neural network. *Solar Energy*, 66(3), 193–199.
- Lek, S. & Guégan, J.F. (1999). Artificial neural networks as a tool in ecological modelling, an introduction. *Ecological Modelling*, 120(2–3), 65–73.

- López, G., Battles, F.J. & Tovar-Pescador, J. (2005). Selection of input parameters to model direct solar irradiance by using artificial neural networks. *Energy*, 30(9), 1675–1684.
- Martín, L., Zarzalejo, L.F., Polo, J., Navarro, A., Marchante, R. & Cony, M. (2010). Prediction of global solar irradiance based on time series analysis: Application to solar thermal power plants energy production planning. *Solar Energy*, 84(10), 1772–1781.
- Mellit, A. (2008). Artificial intelligence technique for modelling and forecasting of solar radiation data: A review. *International Journal of Artificial Intelligence and Soft Computing*, 1(1), 52–76.
- Mellit, A., Benghanem, M., Arab, A.H. & Guessoum, A. (2005). A simplified model for generating sequences of global solar radiation data for isolated sites: Using artificial neural network and a library of Markov transition matrices approach. *Solar Energy*, 79(5), 469–482.
- Mellit, A., Benghanem, M. & Kalogirou, S.A. (2006). An adaptive wavelet-network model for forecasting daily total solar-radiation. *Applied Energy*, 83(7), 705–722.
- Mellit, A., Eleuch, H., Benghanem, M., Elaoun, C. & Pavan, A.M. (2010). An adaptive model for predicting of global, direct and diffuse hourly solar irradiance. *Energy Conversion and Management*, 51(4), 771–782.
- Mellit, A., Kalogirou, S.A., Shaari, S., Salhi, H. & Hadj Arab, A. (2008). Methodology for predicting sequences of mean monthly clearness index and daily solar radiation data in remote areas: Application for sizing a stand-alone PV system. *Renewable Energy*, 33(7), 1570–1590.
- Mellit, A. & Pavan, A.M. (2010). A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar Energy*, 84(5), 807–821.
- Mihalakakou, G., Santamouris, M. & Asimakopoulos D.N. (2000). The total solar radiation time series simulation in Athens, using neural networks. *Theoretical and Applied Climatology*, 66(3), 185–197.
- Moghaddamnia, A., Remesan, R., Kashani, M.H., Mohammadi, M., Han, D. & Piri, J. (2009). Comparison of LLR, MLP, Elman, NNARX and ANFIS Models – with a case study in solar radiation estimation. *Journal of Atmospheric and Solar-Terrestrial Physics*, 71(8–9), 975–982.
- Mohandes, M., Balghonaim, A., Kassas, M., Rehman, S. & Halawani, T.O. (2000). Use of radial basis functions for estimating monthly mean daily solar radiation. *Solar Energy*, 68(2): 161–168.
- Mohandes, M., Rehman, S. & Halawani, T.O. (1998). Estimation of global solar radiation using artificial neural networks. *Renewable Energy*, 14(1–4), 179–184.
- Mubiru, J. (2008). Predicting total solar irradiation values using artificial neural networks. *Renewable Energy*, 33(10), 2329–2332.
- Oliveira, K.A., Vannucci, Á. & da Silva, E.C. (2000). Using artificial neural networks to forecast chaotic time series. *Physica A: Statistical Mechanics and its Applications*, 284(1–4), 393–404.
- Paoli, C., Voyant, C., Muselli, M. & Nivet, M. (2010). Forecasting of preprocessed daily solar radiation time series using neural networks. *Solar Energy*, 84(12), 2146–2160.
- Pattanasethanon, S., Lertsatitthanakorn, C. & Atthajariyakul, S., Soponronnarit S. (2008). An accuracy assessment of an empirical sine model, a novel sine model and an artificial neural network model for forecasting illuminance/irradiance on horizontal plane of all sky types at Mahasarakham, Thailand. *Energy Conversion and Management*, 49(8), 1999–2005.

- Reddy, K.S. & Ranjan, M. (2003). Solar resource estimation using artificial neural networks and comparison with other correlation models. *Energy Conversion and Management*, 44(15), 2519–2530.
- Ruffing, S.M. & Venayagamoorthy, G.K. (2009, 8–12 de noviembre). *Short to medium range time series prediction of solar irradiance using an echo state network*. 15th International Conference on Intelligent System Applications to Power Systems ISAP'09, Curitiba, Brazil.
- Seme, S., Štumberger, G. & Pihler, J. (2009, 15–17 de abril). *Predicting daily distribution of solar irradiation by neural networks*. International Conference on Renewable Energies and Power Quality ICREPQ'09, Valencia, España.
- Sen, Z. (1998). Fuzzy algorithm for estimation of solar irradiation from sunshine duration. *Solar Energy*, 63(1), 39–49.
- Sfetsos, A. & Coonick, A.H. (2000). Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. *Solar Energy*, 68(2), 169–178.
- Shah, A., Kaushik, S.C. & Garg, S.N. (2009). Assessment of diffuse solar energy under general sky condition using artificial neural network. *Applied Energy*, 86(4), 554–564.
- Siqueira, A.N., Tiba, C. & Fraidenraich, N. (2010). Generation of daily solar irradiation by means of artificial neural networks. *Renewable Energy*, 35(11), 2406–2414.
- Sözen, A., Arcaklioglu, E. & Özalp, M. (2004). Estimation of solar potential in turkey by artificial neural networks using meteorological and geographical data. *Energy Conversion and Management*, 45(18–19), 3033–3052.
- Tymvios, F.S., Jacovides, C.P., Michaelides, S.C. & Scouteli, C. (2005). Comparative study of Ångström's and artificial neural networks' methodologies in estimating global solar radiation. *Solar Energy*, 78(6), 752–762.
- Zervas, P.L., Sarimveis, H., Palyvos, J.A. & Markatos, N.C.G. (2008). Prediction of daily global solar irradiance on horizontal surfaces based on neural-network techniques. *Renewable Energy*, 33(8), 1796–1803.

SOBRE O ORGANIZADOR

EDUARDO EUGENIO SPERS realizou pós-doutorado na Wageningen University (WUR), Holanda, e especialização no IGIA, França. Possui doutorado em Administração pela Universidade de São Paulo (USP). Foi Professor do Programa de Mestrado e Doutorado em Administração e do Mestrado Profissional em Comportamento do Consumidor da ESPM. Líder do tema Teoria, Epistemologia e Métodos de Pesquisa em Marketing na Associação Nacional de Pós-Graduação e Pesquisa em Administração (ANPAD). Participou de diversos projetos de consultoria e pesquisa coordenados pelo PENSA e Markestrat. É Professor Titular no Departamento de Economia, Administração e Sociologia, docente do Mestrado em Administração e Coordenador do Grupo de Extensão MarkEsalq no campus da USP/Esalq. Proferiu palestras em diversos eventos acadêmicos e profissionais, com diversos artigos publicados em periódicos nacionais e internacionais, livros e capítulos de livros sobre agronegócios, com foco no marketing e no comportamento do produtor rural e do consumidor de alimentos.

Índice Remissivo

A

Ácidos húmicos 120, 121, 123, 130
Active tourism 282, 285
Adsorbentes de bajo costo 296, 297, 298, 299, 306
Agricultura de base ecológica 261, 267
Agricultura familiar 149, 162, 236, 241, 243, 245, 248, 254, 261, 263, 266, 267, 270
Agricultura industrial 228, 229, 230
Agricultura sostenible 160, 220
Agriculturización 41, 43, 47
Agrobiodiversidade 255, 256, 257, 259
Agroecologia 144, 146, 149, 151, 159, 161, 162, 236, 237, 252, 253, 254, 260, 261, 269, 270, 341
Agrofloresta 143, 144, 145, 146, 147, 148, 149, 151
Agrotóxicos 238, 249, 250, 252, 329, 330, 331, 332, 333, 334, 335, 336, 337, 338, 339, 340, 341, 342, 343
Área de Proteção Permanente 143, 144
Aridez 152, 157
Atividade leiteira 238, 240, 241, 245, 246, 247, 248, 249, 250, 252
Avena sativa 55, 56, 57, 59

B

Baccharis spp 132, 133, 135, 140
Biocompósito 311, 312, 313, 314, 315, 316

C

Caatinga 193, 194, 195, 196, 197, 198, 199, 200, 201, 202, 203, 204, 205, 206, 207, 208, 209, 210, 211, 213, 214, 215
Callejones 55, 56, 57, 58, 59, 60, 61
Cambio climático 2, 3, 14, 15, 42, 43, 52, 53, 74, 82, 169, 229, 307
Carboximetilcelulose 318, 319, 320, 321, 322, 323, 324, 326, 327
Compactación 41, 46, 48, 50, 51
Comunicação de Riscos 329, 331, 334
Comunidades vegetales funcionales 2, 15

Conhecimento agroecológico 255, 257, 259, 269
Conservação 143, 149, 193, 197, 205, 207, 208, 209, 210, 212, 256, 260, 282, 290, 291, 292, 294
Conservación 2, 15, 16, 41, 52, 62, 157, 165, 169, 171, 175, 235
Contaminación 25, 38, 221, 223, 227, 235, 297, 298, 299, 307
Contaminación ambiental 221, 227, 299
Cultura 238, 239, 240, 241, 242, 243, 246, 247, 248, 249, 251, 252, 260, 271, 272, 273, 274, 275, 277, 278, 279, 328
Cultura da soja 238, 239, 240, 241, 242, 243, 246, 247, 249, 251, 252

D

Densidad 5, 12, 41, 46, 49, 50, 51, 52, 69, 72, 98, 121, 125, 126, 127, 128, 129, 180, 181, 183, 184, 185, 187, 188, 328
Desenvolvimento rural sustentável 254, 261, 269, 270, 271
Detección de cambios 65, 66, 67, 69, 70, 72, 78
Dinámica de la vegetación 1, 2, 4, 9, 11, 12, 13
DRX 311, 312, 313, 314

E

Ebenaceae 168, 169, 170, 177, 178
Ecológico 4, 5, 8, 11, 13, 15, 221, 222, 237, 251, 254, 269
Educação ambiental 289, 290, 291, 292, 333
Eficiencia del uso del agua 55, 56
Energías renovables 84, 85
Erosión 16, 41, 42, 43, 44, 46, 48, 49, 52, 53, 230, 235
Estabelecimento de plântulas 194, 203
Evapotranspiración 56, 57, 58, 67, 96, 116
Extensão rural 238, 241, 246, 248, 254, 260, 261, 263, 264, 265, 267, 268, 269, 270, 329, 331, 333, 338, 341

F

Fechas de siembra 180, 181, 184, 186, 187, 234, 236
Fertilización 48, 180, 181, 183, 184, 185, 188, 236
Fitoquímica 169, 170

G

Germinação de sementes 194, 202, 206, 208, 209, 210, 212, 213, 214

Gestión 42, 44, 52, 63, 84, 85, 159, 163, 233

Grano 66, 69, 172, 180, 181, 182, 183, 184, 185, 186, 187, 188, 189

H

Herbácea 56, 57, 58, 62, 63, 182, 199

Heritage 280, 281, 282, 283, 287

Horticultura 124, 184, 213, 221, 227, 328

Huerta 131, 152, 153, 154, 155, 157, 158

I

Imágenes Landsat 65, 67, 68

Imágenes multitemporales 65, 69

Indicadores de sustentabilidad 228, 229, 231, 232, 233, 234

Índices de vegetación 65, 66, 67, 68, 69, 71

Inestabilidad climática 2, 5

Infiltración 16, 41, 46, 47, 48, 49, 51, 52, 156

Insolación 96, 97, 98, 99, 115

Inteligencia computacional 95, 96

Investigación Acción Participativa 228, 229, 237

Irrigation water 24, 26, 27, 28, 29, 190

J

JBR 197, 289, 290, 291, 292, 293

L

Land change modeler 132, 136

Landsat 65, 67, 68, 73, 132, 133, 135, 142

Logística Reversa 329, 330, 331, 332, 333, 334, 336, 338, 340, 341, 342, 343

M

Manejo do solo 121, 124

Manga 311, 312, 313, 314, 315, 316, 317

Memória hídrica 194, 196, 198, 200, 201, 203, 205, 206, 207, 208, 209, 210, 211, 212, 213, 214

Mezquite 152, 153, 154, 155, 157, 158

Modelo 9, 12, 68, 84, 85, 86, 87, 88, 89, 90, 94, 95, 96, 97, 98, 99, 100, 102, 103, 104, 105, 108, 109, 110, 111, 114, 115, 116, 124, 142, 143, 145, 146, 152, 154, 157, 158, 163, 228, 230, 231, 242, 250, 255, 256, 257, 262, 267, 282, 301, 322

Montemuro 271, 272, 273, 274, 275, 276, 277, 278, 279, 280

O

Optimización 84, 101, 175, 177, 192, 299

Organo-argilominerais 311, 312, 313

P

Permeability 24, 26, 28, 35, 37, 178

Pesquisa 55, 122, 123, 124, 125, 129, 193, 196, 197, 198, 199, 240, 241, 243, 257, 261, 263, 264, 266, 267, 269, 270, 273, 274, 290, 291, 293, 294, 313, 320, 330, 335, 336, 344

“Picos de Europa” 281, 282, 283, 284, 285, 286, 287, 288

PLA 26, 29, 38, 311, 312, 313, 314, 315, 316

Plantio 143, 146, 147, 247, 255, 256, 257, 258, 260, 292, 318, 320

Polimérico, 312, 319, 321, 323, 324, 328

Política pública 160, 246

Predicción 95, 96, 97, 98, 99, 100, 101, 102, 105, 107, 108, 109, 110, 111, 112, 114, 115, 116

Produção de base ecológica 238, 249, 251, 252, 254

Protected area 132, 134, 138

R

Redes alimentarias alternativas 159, 160, 161

Relação E4/E6 121, 126, 129

Remote sensing 73, 132, 133, 135, 141

Restauração Florestal 144, 290

Riego 24, 25, 37, 38, 63, 84, 85, 86, 87, 88, 90, 91, 93, 94, 95, 101, 154, 156, 180, 181, 183, 184, 185, 188, 189, 235, 308

S

Salinization and sodification 24, 26, 27, 29

Saúde 265, 277, 319, 320, 329, 330, 331, 335, 336, 337, 338, 339, 340, 341, 342, 343

Segmentación de Series Hidrometeorológicas 74, 75, 79

Seguridad alimentaria y nutricional 160, 162, 167

Sementes 193, 194, 195, 196, 197, 198, 199, 200, 201, 202, 203, 204, 205, 206, 207, 208, 209, 210, 211, 212, 213, 214, 215, 250, 255, 256, 257, 258, 259, 260, 292, 293

Silvestre 169, 171, 172, 175

Solos temperados 120, 121, 122, 124

Solos tropicais 120, 121, 123, 125, 126, 129

Sustainable management 24, 283

Sustancia coloidal 220, 221, 222

Sustentable 16, 25, 37, 63, 76, 82, 83, 152, 153, 158, 160, 161, 162, 163, 164, 166, 168, 169, 170, 171, 176, 177, 189, 230, 231, 233, 237

T

Teatro 271, 272, 273, 274, 275, 276, 277, 278, 279, 280

Travel Cost Method 282, 284, 286, 288

V

Variabilidade 41, 42, 75, 79, 84, 89, 182, 183, 184

Z

Zapotillo 169, 171



**EDITORA
ARTEMIS**