

Ciência e Tecnologia

Para o Desenvolvimento
Ambiental, Cultural
e Socioeconômico

Xosé Somoza Medina
(organizador)

VOL II

 EDITORA
ARTEMIS
2023

Ciência e Tecnologia

Para o Desenvolvimento
Ambiental, Cultural
e Socioeconômico

Xosé Somoza Medina
(organizador)

VOL II

 EDITORA
ARTEMIS
2023



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
Organizador	Prof. Dr. Xosé Somoza Medina
Imagem da Capa	peacestock/123RF
Bibliotecário	Maurício Amormino Júnior – CRB6/2422

Conselho Editorial

Prof.^a Dr.^a Ada Esther Portero Ricol, *Universidad Tecnológica de La Habana “José Antonio Echeverría”*, Cuba
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.^a Dr.^a Ana Júlia Viamonte, Instituto Superior de Engenharia do Porto (ISEP), Portugal
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 Cirila Cervera Delgado, *Universidad de Guanajuato*, México
Prof.^a Dr.^a Cláudia Neves, Universidade Aberta de Portugal
Prof.^a Dr.^a Cláudia Padovesi Fonseca, Universidade de Brasília-DF
Prof. Dr. Cleberton Correia Santos, Universidade Federal da Grande Dourados
Prof. Dr. David García-Martul, *Universidad Rey Juan Carlos de Madrid*, Espanha
Prof.^a Dr.^a Deuzimar Costa Serra, Universidade Estadual do Maranhão
Prof.^a Dr.^a Dina Maria Martins Ferreira, Universidade Estadual do Ceará
Prof.^a Dr.^a Edith Luévano-Hipólito, *Universidad Autónoma de Nuevo León*, México
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, Brasil
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.^ª Dr.^ª Gabriela Gonçalves, Instituto Superior de Engenharia do Porto (ISEP), Portugal
Prof. Dr. Geoffroy Roger Pointer Malpass, Universidade Federal do Triângulo Mineiro, Brasil
Prof.^ª Dr.^ª Gladys Esther Leoz, *Universidad Nacional de San Luis, Argentina*
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. Dr. Håkan Karlsson, *University of Gothenburg, Suécia*
Prof.^ª Dr.^ª Iara Lúcia Tescarollo Dias, Universidade São Francisco, Brasil
Prof.^ª Dr.^ª Isabel del Rosario Chiyon Carrasco, *Universidad de Piura, Peru*
Prof.^ª Dr.^ª Isabel Yohena, *Universidad de Buenos Aires, Argentina*
Prof. Dr. Ivan Amaro, Universidade do Estado do Rio de Janeiro, Brasil
Prof. Dr. Iván Ramon Sánchez Soto, *Universidad del Bío-Bío, Chile*
Prof.^ª Dr.^ª Ivânia Maria Carneiro Vieira, Universidade Federal do Amazonas, Brasil
Prof. Me. Javier Antonio Alborno, *University of Miami and Miami Dade College, Estados Unidos*
Prof. Dr. Jesús Montero Martínez, *Universidad de Castilla - La Mancha, Espanha*
Prof. Dr. João Manuel Pereira Ramalho Serrano, Universidade de Évora, Portugal
Prof. Dr. Joaquim Júlio Almeida Júnior, UniFIMES - Centro Universitário de Mineiros, Brasil
Prof. Dr. Jorge Ernesto Bartolucci, *Universidad Nacional Autónoma de México, México*
Prof. Dr. José Cortez Godinez, Universidad Autónoma de Baja California, México
Prof. Dr. Juan Carlos Cancino Diaz, Instituto Politécnico Nacional, México
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. Juan Manuel Sánchez-Yáñez, *Universidad Michoacana de San Nicolás de Hidalgo, México*
Prof. Dr. Júlio César Ribeiro, Universidade Federal Rural do Rio de Janeiro, Brasil
Prof. Dr. Leinig Antonio Perazolli, Universidade Estadual Paulista (UNESP), Brasil
Prof.^ª Dr.^ª Livia do Carmo, Universidade Federal de Goiás, Brasil
Prof.^ª Dr.^ª Luciane Spanhol Bordignon, Universidade de Passo Fundo, Brasil
Prof. Dr. Luis Fernando González Beltrán, *Universidad Nacional Autónoma de México, México*
Prof. Dr. Luis Vicente Amador Muñoz, *Universidad Pablo de Olavide, Espanha*
Prof.^ª Dr.^ª Macarena Esteban Ibáñez, *Universidad Pablo de Olavide, Espanha*
Prof. Dr. Manuel Ramiro Rodríguez, *Universidad Santiago de Compostela, Espanha*
Prof.^ª Dr.^ª Márcia de Souza Luz Freitas, Universidade Federal de Itajubá, Brasil
Prof. Dr. Marcos Augusto de Lima Nobre, Universidade Estadual Paulista (UNESP), Brasil
Prof. Dr. Marcos Vinicius Meiado, Universidade Federal de Sergipe, Brasil
Prof.^ª Dr.^ª Mar Garrido Román, *Universidad de Granada, Espanha*
Prof.^ª Dr.^ª Margarida Márcia Fernandes Lima, Universidade Federal de Ouro Preto, Brasil
Prof.^ª Dr.^ª Maria Aparecida José de Oliveira, Universidade Federal da Bahia, Brasil
Prof.^ª Dr.^ª Maria Carmen Pastor, *Universitat Jaume I, Espanha*
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, Brasil
Prof.^ª Dr.^ª Maria Lúcia Pato, Instituto Politécnico de Viseu, Portugal



Prof.ª Dr.ª Maritza González Moreno, *Universidad Tecnológica de La Habana*, Cuba
Prof.ª Dr.ª Mauriceia Silva de Paula Vieira, Universidade Federal de Lavras, Brasil
Prof.ª Dr.ª Ninfa María Rosas-García, Centro de Biotecnología Genómica-Instituto Politécnico Nacional, México
Prof.ª Dr.ª Odara Horta Boscolo, Universidade Federal Fluminense, Brasil
Prof. Dr. Osbaldo Turpo-Gebera, *Universidad Nacional de San Agustín de Arequipa*, Peru
Prof.ª Dr.ª Patrícia Vasconcelos Almeida, Universidade Federal de Lavras, Brasil
Prof.ª Dr.ª Paula Arcoverde Cavalcanti, Universidade do Estado da Bahia, Brasil
Prof. Dr. Rodrigo Marques de Almeida Guerra, Universidade Federal do Pará, Brasil
Prof. Dr. Saulo Cerqueira de Aguiar Soares, Universidade Federal do Piauí, Brasil
Prof. Dr. Sergio Bitencourt Araújo Barros, Universidade Federal do Piauí, Brasil
Prof. Dr. Sérgio Luiz do Amaral Moretti, Universidade Federal de Uberlândia, Brasil
Prof.ª Dr.ª Silvia Inés del Valle Navarro, *Universidad Nacional de Catamarca*, Argentina
Prof.ª Dr.ª Solange Kazumi Sakata, Instituto de Pesquisas Energéticas e Nucleares. Universidade de São Paulo (USP), Brasil
Prof.ª Dr.ª Stanislava Kashtanova, *Saint Petersburg State University*, Russia
Prof.ª Dr.ª Teresa Cardoso, Universidade Aberta de Portugal
Prof.ª Dr.ª Teresa Monteiro Seixas, Universidade do Porto, Portugal
Prof. Dr. Valter Machado da Fonseca, Universidade Federal de Viçosa, Brasil
Prof.ª Dr.ª Vanessa Bordin Viera, Universidade Federal de Campina Grande, Brasil
Prof.ª Dr.ª Vera Lúcia Vasilévski dos Santos Araújo, Universidade Tecnológica Federal do Paraná, Brasil
Prof. Dr. Wilson Noé Garcés Aguilar, *Corporación Universitaria Autónoma del Cauca*, Colômbia
Prof. Dr. Xosé Somoza Medina, *Universidad de León*, Espanha

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

C569 Ciência e tecnologia para o desenvolvimento ambiental, cultural e socioeconômico II [livro eletrônico] / Organizador Xosé Somoza Medina. – Curitiba, PR: Artemis, 2023.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

Edição bilingue

ISBN 978-65-87396-76-7

DOI 10.37572/EdArt_270223767

1. Desenvolvimento sustentável. 2. Tecnologia – Aspectos ambientais. I. Somoza Medina, Xosé.

CDD 363.7

Elaborado por Maurício Amormino Júnior – CRB6/2422



EDITORA
ARTEMIS

2023

Editora Artemis

Curitiba-PR Brasil

www.editoraartemis.com.br

e-mail: publicar@editoraartemis.com.br

PRÓLOGO

Este libro presenta una colección de artículos de investigación que bajo distintos ámbitos de conocimiento realizan avances de interés en la ciencia y la tecnología. La sociedad del siglo XXI se distingue de la de épocas pretéritas por su capacidad analítica. A diferencia de lo que ocurría en otras épocas, en nuestro mundo contemporáneo tenemos demasiada información y avanzar en el conocimiento significa realizar una investigación original sobre otros antecedentes previos y analizar una gran cantidad de datos para poder extraer conclusiones que signifiquen un desarrollo, un avance entre la situación anterior y la posterior, aunque sea a pequeña escala en un contexto local y en un ámbito científico muy concreto. La suma de miles de esos pequeños avances y la interconexión mundial sostienen a la ciencia y la tecnología del siglo XXI.

Este es el objetivo de este libro, realizar avances en la ciencia y la tecnología para el desarrollo ambiental, cultural y socioeconómico, desde un posicionamiento académico, comprometido con el rigor científico y el desarrollo del ser humano.

Para ello se han compendiado veinticuatro artículos de investigación en dos apartados, ciencia y tecnología. En el primer conjunto nos encontramos con artículos que desde las ciencias ambientales o las ciencias sociales realizan propuestas de mejora de aspectos concretos sobre hidrología, regeneración de suelo agrícola, cuidado ambiental, recursos humanos, ciudades igualitarias o paisajes culturales.

En el segundo bloque, se agrupan trabajos de ingeniería química, ingeniería industrial o ingeniería forestal que relatan avances en distintas tecnologías, relacionadas con el biogás de los vertederos de residuos, los usos de nuevos materiales sintéticos, la química de determinados productos y su toxicidad, o las características bioestructurales de la madera de roble.

Xosé Somoza Medina
Universidad de León, España

SUMÁRIO

I CIENCIAS PARA EL DESARROLLO AMBIENTAL, CULTURAL Y SOCIOECONÓMICO

CAPÍTULO 1..... 1

EL RÍO NAZAS COMO SOLUCIÓN BASADA EN LA NATURALEZA PARA LA COMARCA LAGUNERA

Ana Cecilia Tobías Estrada

José Avidán Bravo Jácome

Alejandra Peña García

 https://doi.org/10.37572/EdArt_2702237671

CAPÍTULO 2..... 19

SIMULACIÓN Y PRONÓSTICO DE CAUDALES DIARIOS DEL RÍO AMAZONAS (TAMSHIYACU) USANDO MODELO HÍBRIDO WAVELET REDES NEURONALES

Lucio Vergara Saturno

Waldo Sven Lavado-Casimiro

 https://doi.org/10.37572/EdArt_2702237672

CAPÍTULO 3..... 38

BIORESTORATION OF AN AGRICULTURAL SOIL IMPACTED BY WASTE MOTOR OIL

Monserrat Torres-Olaya

Juan Luis Ignacio-De la Cruz

Gabriel Gallegos-Morales

Juan Manuel Sánchez-Yáñez

 https://doi.org/10.37572/EdArt_2702237673

CAPÍTULO 4..... 50

CARBONO ORGÁNICO SECUESTRADO EN SISTEMAS AGROFORESTALES EVALUADOS EN EL CANTÓN MEJÍA, PICHINCHA, ECUADOR

R. A. Ramos Veintimilla

C. M. Nieto Cabrera

J. R. Limongi Andrade

F. M. Romero Mancero

 https://doi.org/10.37572/EdArt_2702237674

CAPÍTULO 5..... 65

CREATIVIDAD, INGENIO Y EDUCACIÓN PARA TRANSFORMAR EN VALOR LOS RESIDUOS GENERADOS DE LA PODA DE ÁRBOLES; EL CASO DEL PROSOPIS GLANDULOSA (MEZQUITE)

José Melero-Oláguez
Argelia Melero-Hernández
Jorge Murillo-Romo
Arturo Murillo-Herrera

 https://doi.org/10.37572/EdArt_2702237675

CAPÍTULO 6..... 74

PROGRAMA DE CONSERVACIÓN Y FOMENTO DE LA CULTURA DE CUIDADO AMBIENTAL EN EL MUNICIPIO DE SAN JUAN ATZOMPA, PUEBLA, MÉXICO

Sergio Alberto Vega Cisneros
Fabiola Mendoza Morales
Rosa María Canalizo Bravo
M.A. Claudia Domínguez Olmos
M.A. Rosario Mejía Ramírez
M.A. Adalit Arias Aragón

 https://doi.org/10.37572/EdArt_2702237676

CAPÍTULO 7..... 80

EMPRENDEDORISMO 360°

Luis Alberto Ynfante

 https://doi.org/10.37572/EdArt_2702237677

CAPÍTULO 8..... 89

ELEMENTOS CLAVES PARA LA PROFESIONALIZACIÓN DEL RECURSO HUMANO EN ORGANISMOS OPERADORES DE MÉXICO

Carlos Alejandro Hernández Morales
Daniel Salas Limón

 https://doi.org/10.37572/EdArt_2702237678

CAPÍTULO 9..... 102

ANÁLISIS DEL RENDIMIENTO ESCOLAR MODALIDAD VIRTUAL Y PRESENCIAL EN LA UNIDAD DE APRENDIZAJE DE FÍSICA BÁSICA DE LA UNIVERSIDAD AUTÓNOMA DE CAMPECHE

Mayté Cadena González

María Alejandra Sarmiento Bojórquez

Juan Fernando Casanova Rosado

 https://doi.org/10.37572/EdArt_2702237679

CAPÍTULO 10..... 115

MEJORAMIENTO DE LA FUERZA DE TRABAJO UTILIZANDO SIMULACION

Jorge Tomás Gutiérrez Villegas

María Leticia Silva Ríos

Edgar Omar Gutiérrez Villegas

 https://doi.org/10.37572/EdArt_27022376710

CAPÍTULO 11..... 125

LA PERSPECTIVA DE GÉNERO EN LAS CIUDADES ESPAÑOLAS. UN ANÁLISIS EXPLORATORIO

Bárbara Atanes Delgado

Xosé Somoza Medina

 https://doi.org/10.37572/EdArt_27022376711

CAPÍTULO 12..... 149

UN SENDERO CON TERRITORIALIDAD LOCAL EN LA QUEBRADA DE EL TALA, VALLE DE CATAMARCA

Ezequiel Fonseca

Claudio Caraffini

Cristian Melián

 https://doi.org/10.37572/EdArt_27022376712

II TECNOLOGÍAS PARA PARA EL DESARROLLO AMBIENTAL, CULTURAL Y SOCIOECONÓMICO

CAPÍTULO 13..... 158

ESTUDIO DE MODELOS MATEMATICOS PARA CALCULO DEL BIOGAS PRODUCIDO EN UN VERTEDERO

Sandra Maria Martinez

Patricia María Albarracin

Luis Francisco Garcia

Santiago Ezequiel Torres

 https://doi.org/10.37572/EdArt_27022376713

CAPÍTULO 14..... 164

TECNOLOGÍA BTS-MP_{DRY} PARA LA LIMPIEZA DEL BIOGÁS. UNA FORMA EFICIENTE DE ELIMINAR COMPONENTES PELIGROSOS DEL BIOGÁS DE VERTEDEROS

Joaquín Reina Hernández

 https://doi.org/10.37572/EdArt_27022376714

CAPÍTULO 15..... 174

GEOPOLÍMEROS: EL AVE FENIX DE LOS MATERIALES DE CONSTRUCCIÓN EMERGENTES Y SU APLICACIÓN EN LA REMEDIACIÓN AMBIENTAL

Luis Felipe Rodríguez Alfaro

Edith Luévano Hipólito

Leticia Myriam Torres Martínez

 https://doi.org/10.37572/EdArt_27022376715

CAPÍTULO 16..... 185

MACROPOROUS SILICON STRUCTURES IN 700 NM AND 500 NM

Angel Rodríguez

Didac Vega

Jordi Llorca

 https://doi.org/10.37572/EdArt_27022376716

CAPÍTULO 17..... 198

PARTIAL REPLACEMENT OF SODIUM CHLORIDE BY POTASSIUM CHLORIDE IN GREEN TABLE OLIVES. LOOKING FOR A HEALTHY AND ECONOMIC ALTERNATIVE IN ARGENTINA

Mariela Beatriz Maldonado

Leonel Lisanti

Ariel Márquez

Noemi Graciela Maldonado

Pablo Enrique Martín

Daniela Adriana Barrera

 https://doi.org/10.37572/EdArt_27022376717

CAPÍTULO 18..... 207

ENSAYOS DE PUESTA A PUNTO PARA ESTUDIOS DE DIFUSIÓN DE ARSÉNICO EN *DAUCUS CAROTA*

Oscar Daniel Galvez

Mariela Beatriz Maldonado

 https://doi.org/10.37572/EdArt_27022376718

CAPÍTULO 19 **216**

TOXIC EFFECTS OF CONSTITUENTS OF THE FERN *STICHERUS QUADRIPARTITUS* AGAINST *SPODOPTERA FRUGIPERDA* AND *PLODIA INTERPUNCTELLA*

Fernando Livio Corzo

Susana Beatriz Popich

 https://doi.org/10.37572/EdArt_27022376719

CAPÍTULO 20 **228**

ANÁLISIS DE CASO EN EL CAMPO DE LA INGENIERÍA HACIENDO USO DE TÓPICOS DE LAS CIENCIAS BÁSICAS. UN ENFOQUE BASADO DISEÑO INSTRUCCIONAL

Alejandro Armando Hossian

Emanuel Maximiliano Alveal

 https://doi.org/10.37572/EdArt_27022376720

CAPÍTULO 21 **245**

SUPPLEMENTARY FAILURE MODE AND EFFECT ANALYSIS (FMEA) FOR SAFETY APPLICATION STANDARDS DIN EN ISO 13849 SAFETY FUNCTION-FMEA

Christa Düsing

David Prust

 https://doi.org/10.37572/EdArt_27022376721

CAPÍTULO 22 **264**

REACCIÓN DE ESPECIES FORESTALES DE ULTRA-RÁPIDO CRECIMIENTO A PODA TOTAL, EN ESTEPA ESPINOSA MONTANO BAJO, ECUADOR

R. A. Ramos Veintimilla

A. S. Guanaga Paredes

F. A. Sigcha

F. M. Romero Mancero

 https://doi.org/10.37572/EdArt_27022376722

CAPÍTULO 23 **279**

INFLUENCIA DE LA PARED CELULAR EN LA DENSIDAD DE LA MADERA DE ROBLE (*Quercus robur* L.)

Guillermo Riesco Muñoz

Andrés Remacha Gete

 https://doi.org/10.37572/EdArt_27022376723

CAPÍTULO 24288

EMERGENCY REMOTE TEACHING IN PROCESS SIMULATION USING DWSIM: A
CASE STUDY FROM DIQ-UMAG, CHILEAN PATAGONIA

Daniela Navarro-Pérez

Juan C. Moreno-Díaz

Pedro Simeone-Barrientos

 https://doi.org/10.37572/EdArt_27022376724

SOBRE O ORGANIZADOR.....312

ÍNDICE REMISSIVO313

CAPÍTULO 2

SIMULACIÓN Y PRONÓSTICO DE CAUDALES DIARIOS DEL RÍO AMAZONAS (TAMSHIYACU) USANDO MODELO HÍBRIDO WAVELET REDES NEURONALES¹

Data de submissão: 23/01/2023

Data de aceite: 10/02/2023

Lucio Vergara Saturno

Programa de Doctorado en Recursos
Hídricos-UNALM
Autoridad Nacional del Agua-ANA
Lima, Perú

[https://ctivitae.concytec.gob.pe/
appDirectorioCTI/VerDatosInvestigador.
do?id_investigador=255413](https://ctivitae.concytec.gob.pe/appDirectorioCTI/VerDatosInvestigador.do?id_investigador=255413)
<https://orcid.org/0000-0001-9211-8484>

Waldo Sven Lavado-Casimiro

Servicio Nacional de Meteorología e
Hidrología-SENAMHI
Lima-Perú

[https://ctivitae.concytec.gob.pe/
appDirectorioCTI/VerDatosInvestigador.
do?id_investigador=347](https://ctivitae.concytec.gob.pe/appDirectorioCTI/VerDatosInvestigador.do?id_investigador=347)
<https://orcid.org/0000-0002-0051-0743>

RESUMEN: El pronóstico de caudales a corto plazo tales como horarios o diarios es de vital importancia para la mitigación y defensa de inundaciones. La precisión de los pronósticos se ve influida tanto por la

¹ IAHR-AIIH XXVII CONGRESO LATINOAMERICANO DE HIDRÁULICA LIMA, PERÚ, 28 AL 30 DE SETIEMBRE DE 2016.

calidad de los datos históricos y el método seleccionado para pronosticar el futuro. En este estudio, un modelo híbrido wavelet red neuronal (WNN) es abordado para predecir caudales a través de una combinación de dos técnicas, la transformada wavelet y redes neuronales artificiales (ANN). Las ANN han mostrado gran habilidad en modelamiento y pronóstico de series de tiempo no estacionario y no lineal, y la transformada wavelet provee descomposición útil sobre varios niveles de resolución. Los subseñales descompuestos fueron alimentados como input a la ANN para obtener los valores de caudales previstos para varios horizontes de tiempo. Los modelos de pronóstico ANN y WNN son aplicados a datos diarios de caudales en la primera estación de aforo (Tamshiyacu) en la corriente principal de la cuenca del río Amazonas en Perú. Los desempeños relativos de estos modelos fueron medidos usando diversos criterios de habilidad de pronóstico y verificados con datos no entrenados, utilizando Matlab (R.2013a). Los resultados en términos de raíz del error cuadrático medio (RMSE) y el coeficiente de determinación (R^2) mostraron la eficacia y la mejora significativa del modelo híbrido WNN en comparación con la otra técnica de ANN estándar, y se concluye que el método aplicado es potencialmente muy útil para el pronóstico de caudales a corto plazo.

PALABRAS CLAVES: Pronóstico a corto plazo. ANN. Transformada wavelet. Híbrido. Río Amazonas.

SIMULATION AND FORECASTING OF DAILY STREAMFLOWS OF THE AMAZON RIVER (TAMSHIYACU) USING WAVELET NEURAL NETWORKS HYBRID MODEL

ABSTRACT: The short-term streamflow forecasting such as hourly or daily is of vital importance for flood mitigation and defense. The accuracy of forecasts is influenced by both the quality of past data and the method selected to forecast the future. In this study, a hybrid wavelet neural network (WNN) model was used to predict streamflow through a combination of two techniques, wavelet transform and artificial neural networks (ANN). ANNs have shown great ability in modeling and forecasting of nonstationary and nonlinear time series, and wavelet transform provides useful decomposition on several resolution levels. The decomposed subsignals were fed as input to ANN to get the forecasted streamflow values for various time horizons. Forecasting models ANN and WNN are applied to daily streamflow data in the first gauging station (Tamshiyacu) into the mainstream of the Amazon river basin in Peru. The relative performance of these models were measured using various forecast skill criteria and verified with data untrained, using Matlab (R.2013a). The results in terms of root mean square error (RMSE) and coefficient of determination (R^2) showed the effectiveness and significant improvement of the hybrid WNN model compared to the other standard technique ANN, and it is concluded that the method applied is potentially very useful for short-term streamflow forecasting.

KEYWORDS: Short-term streamflow forecasting. ANNs. Wavelet transform. Hybrid. Amazon River.

1 INTRODUCCIÓN

Recientes estudios científicos muestran que la región Amazónica ha sufrido severos eventos hidrológicos extremos, como sequías extremas y fuertes inundaciones [Espinoza et al., 2009; Lavado et al., 2012; Espinoza et al., 2011; Espinoza et al., 2012; Espinoza et al., 2013], que han traído consigo grandes pérdidas humanas y materiales en esta región. Además, han evidenciado un incremento de estos eventos, particularmente en los países andino-amazónicos (Perú, Bolivia, Ecuador y Colombia) desde inicios de los años 1990 [Espinoza et al., 2009].

Estas problemáticas, motivó que diversas instituciones de investigación y gestión del agua emprendieran acciones para mitigar los daños que pudieran ocasionar futuros eventos similares. P. ej., desde el año 2013 la Autoridad Nacional del Agua (ANA) y el Instituto Geofísico del Perú (IGP) con la colaboración de otras instituciones, está llevando a cabo el estudio denominado “Sistema de alerta cualitativo para la previsión de eventos hidrológicos extremos en la Amazonía peruana”, que permite inferir las posibles condiciones hidrológicas en los principales ríos de la Amazonía peruana; dirigido por el Dr. Jhan Carlo Espinoza V.

El presente trabajo surge de la necesidad que se presentó en dicho estudio respecto al desarrollo de modelos de pronóstico de series de tiempo hidrológicos con

la finalidad de cuantificar descargas futuras a corto plazo en los principales ríos de la Amazonía peruana, que conllevará al fortalecimiento del sistema de previsión cualitativa antes mencionada. Puesto que, Mashor (2002) indica que los riesgos hidrológicos debido al caudal (p. ej., inundaciones) pueden reducirse si se tienen efectivos sistemas de predicción de caudales a corto plazo.

Enfoques actuales de pronósticos hidrológicos se pueden clasificar en dos categorías generales: modelos basados en procesos y modelos basados en datos [Wang, 2006; Di et al., 2014]. En general, las principales diferencias entre los dos tipos de modelos son la representación de los procesos gobernantes y sus necesidades de información [Shrestha y Nestmann, 2009]. Para la predicción a tiempo real, los modelos basados en datos podrían ser favorable, ya que los modelos físicos sofisticados a menudo necesitan enormes cantidades de datos y tiempos de cálculo largos para la calibración del modelo [Chau et al., 2005]. Asimismo, los modelos basados en datos no toman en cuenta los procesos físicos hidrológicos, en su lugar identifican la relación entre las entradas y salidas matemáticamente [Di et al., 2014].

En los últimos años, las redes neuronales (ANN), como un método de inteligencia artificial, se han convertido extremadamente populares para la predicción y pronóstico en diversas áreas, incluyendo las finanzas, generación de energía, medicina, recursos hídricos y ciencias ambientales [Maier y Dandy, 2000; Abrahart et al., 2004; ASCE Task Committee, 2000 a,b]. Los modelos de ANN son estructuras matemáticas flexibles que son capaces de identificar complejas relaciones no lineales entre conjuntos de datos de entrada y salida [Wang et al., 2008; Dibike y Solomatine, 2001; ASCE Task Committee, 2000 a,b]. Sin embargo, también se informó de que los modelos de ANN no son muy satisfactorios en términos de precisión porque consideran sólo unos pocos aspectos del comportamiento de la serie temporal [Wang y Ding, 2003].

Recientes estudios muestran que los modelos híbridos Wavelet-ANN han superado significativamente a los modelos ANN tradicionales en el pronóstico de flujos de ríos [Adamowski y Sun, 2010; Krishna et al., 2011; Nourani et al., 2014]. Esta técnica se emplea mediante la combinación de dos métodos, transformada wavelet discreta (TWD) y ANN. Los datos de TWD ayudan a mejorar la capacidad de un modelo de pronóstico mediante la captura de información útil sobre varios niveles de resolución [Adamowski y Sun, 2010; Deka et al., 2012; Zhang et al., 2014]. Asimismo, han encontrado que la transformada de wavelet son muy eficaces con datos no estacionarios [Adamowski, 2008; Deka y Prahlada, 2012; Nourani et al., 2014].

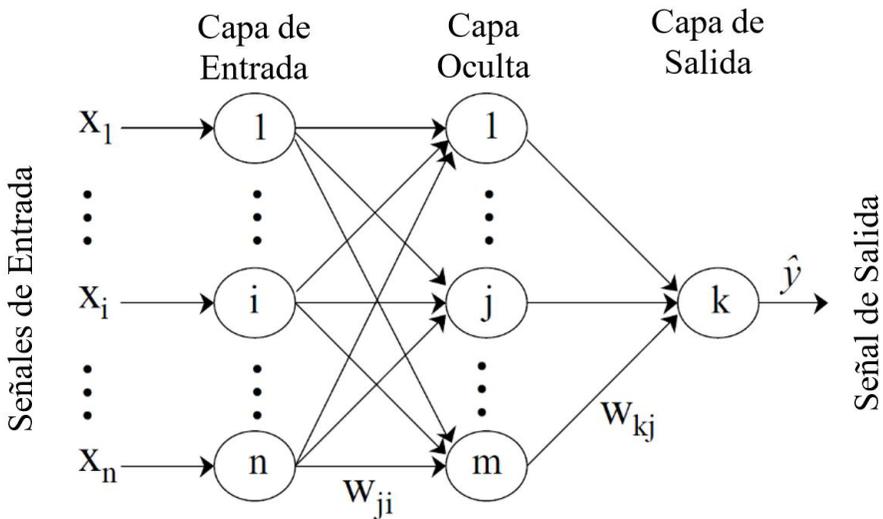
En este estudio, abordamos la eficacia de un modelo híbrido wavelet redes neuronales (WNN) para el pronóstico de series temporales de caudales del río Amazonas

(Tamshiyacu) a corto plazo y comparar su performance con los enfoques convencionales de ANN, utilizando valores previos de caudales diarias. Se trata esencialmente de una red neuronal de perceptrones multicapas con entradas de señales descompuestas a varias resoluciones utilizando la TWD.

2 REDES NEURONALES ARTIFICIALES

Una red neuronal artificial (ANN por sus siglas en inglés) es un método computacional o modelo matemático inspirado en la estructura y/o aspectos funcionales de las redes neuronales biológicas, como el cerebro [Haykin, 1999]. Las ANN consisten de elementos simples, densamente interconectados conocidas como neuronas (o nodos), que normalmente están dispuestos en capas (véase Figura 1). Una ANN recibe señales a través de las unidades de entrada y estas señales se propagan y se transforma a través de la red hacia la neurona de salida [De Vos y Rientjes, 2005].

Figura 1.- Arquitectura típica de ANN feedforward con tres capas (Kim y Valdés, 2003).



Una ANN se caracteriza por su arquitectura que representa el patrón de conexiones entre nodos, su método de determinar los pesos de conexión y la función de activación o de transferencia [ASCE Task Committee, 2000a]. La arquitectura de la ANN consiste del número de capas ocultas y el número de nodos en la capa de entrada, capas ocultas y la capa de salida (véase Figura 1). Las ANN con una capa oculta se utilizan comúnmente en modelamiento hidrológico, ya que estas redes son consideradas para proporcionar suficiente complejidad para simular con precisión las propiedades no lineales del proceso hidrológico [Kisi, 2004b; Wu et al., 2009].

El perceptrón multicapa (MLP por sus siglas en inglés) feedforward entre muchos paradigmas de ANN es de lejos, el más popular usado en modelamiento hidrológico debido a su simplicidad [Maier and Dandy, 2000], que fueron desarrollados para el pronóstico de caudales a corto plazo, que por lo general utiliza la técnica de propagación de error hacia atrás para entrenar la configuración de la red [Wu et al., 2009]. En las redes feedforward las conexiones entre los nodos fluyen en una dirección: desde una capa de entrada, a través de una o más capas ocultas, a una capa de salida [Dawson y Wilby, 2001]. La expresión explícita para un valor de salida de ANN feedforward está dado mediante la siguiente ecuación:

$$\hat{y}_k = f_o \left[\sum_{j=1}^m w_{kj} \cdot f_h \left(\sum_{i=1}^n w_{ji} x_i + w_{jo} \right) + w_{ko} \right] \quad [1]$$

donde n es el número de muestras, m es el número de neuronas ocultas, w_{ji} es un peso en la capa oculta que conecta el i -ésimo neurona en la capa de entrada y el j -ésimo neurona en la capa oculta, w_{jo} es el sesgo para el j -ésimo neurona oculta, f_h es la función de activación de la neurona oculta, w_{kj} es un peso en la capa de salida que conecta el j -ésimo neurona en la capa oculta y el k -ésimo neurona en la capa de salida, w_{ko} es el sesgo para el k -ésimo neurona de salida, y f_o es la función de activación para la neurona de salida. Los pesos son diferentes en la capa oculta y salida, y sus valores pueden cambiar durante el proceso de entrenamiento de la red [Kim y Valdés, 2003].

El propósito del entrenamiento de la red es optimizar los pesos w conectadas a capas vecinas y sesgos h de cada neurona en la capa oculta y la capa de salida, mediante el algoritmo de Levenberg-Marquardt (LM) [Wu et al., 2009]. Este algoritmo fue seleccionado ya que suele ser más rápido y más fiable que otras variantes de backpropagation [Antil y Tape, 2004].

3 ANÁLISIS WAVELET Y DESCOMPOSICIÓN

3.1 TRANSFORMADA DE WAVELET

La transformada de wavelet (TW), desarrollado durante las últimas dos décadas en la comunidad matemática, que parece ser una herramienta más eficaz que la transformada de Fourier (TF) en el estudio de series de tiempo no estacionario. La principal ventaja de la TW es su capacidad de obtener simultáneamente información en el tiempo, localización y frecuencia de una señal, mientras que el TF sólo proporcionará información de frecuencia de una señal [Adamowski y Chan, 2011]. La TW provee descomposiciones útiles de la serie de tiempo original, por lo que los datos de TW mejoran la capacidad de

un modelo de pronóstico mediante la captura de información útil sobre varios niveles de resolución que son usados como entradas en los modelos de pronóstico [Adamowski, 2008; Zhang et al., 2014]. El objetivo básico de TW es lograr una representación escala temporal completa de los fenómenos localizados y transitorios que ocurren en diferentes escalas de tiempo [Pramanik et al., 2011]. La TW se pueden dividir en dos categorías: La transformada wavelet continua (TWC) y la transformada wavelet discreta (TWD) [Pandey et al., 2010]. La TWC se define como la suma sobre todos los tiempos de la señal multiplicada por versiones desplazados y escalados de la función wavelet ψ :

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \psi\left(\frac{x-b}{a}\right) dx \quad [2]$$

donde a es un parámetro de escala; b es un parámetro de posición; y ψ corresponde al conjugado complejo. Las gráficas de los coeficientes de la TWC son precisamente la vista de la escala temporal de la señal. Sin embargo, calcular los coeficientes wavelet en todas las escalas posible es que consume mucho tiempo y genera gran cantidad de información. Por lo tanto, el uso de la TWC para la predicción no es prácticamente posible [Zhang et al., 2014].

En hidrología, las series hidrológicas observadas se expresan a menudo como series discretas, por lo que la TWD se prefiere en la mayoría de los problemas de predicción de sistemas hidrológicos, debido a su simplicidad y capacidad para calcular con menos tiempo para descomponer una serie hidrológica en un conjunto de coeficientes y subseñales bajo diferentes escalas [Sang, 2012]. Para una función wavelet madre y para una señal dada $f(t)$, una TWD se define como sigue:

$$f(t) = \sum C_{j_0,k} \phi_{j_0,k}(t) + \sum_{j>j_0} \sum \omega_{j,k} 2^{j/2} \psi(2^j t - k) \quad [3]$$

donde j es el índice de dilatación o de nivel, k es un índice de translación o de escala, $\phi_{j_0,k}$ es una función de escalado de coeficientes de escala gruesa, $c_{j_0,k}, \omega_{j,k}$ son la función de escalado de coeficientes de detalle, y todas las funciones de $\psi(2^j t - k)$ son ortonormales [Pandey et al., 2010].

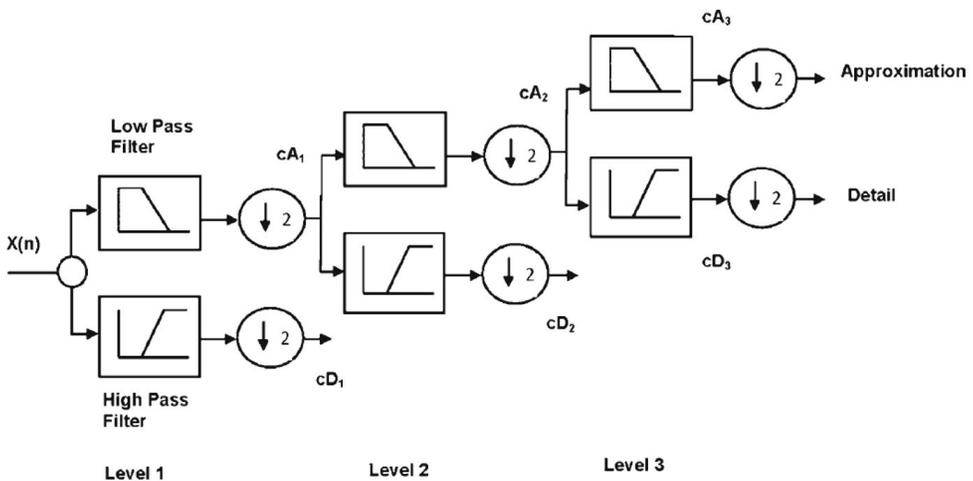
3.2 ANÁLISIS MULTIRESOLUCIÓN WAVELET

El análisis multiresolución wavelet utiliza TWD para descomponer una señal cruda (sin procesar) en una serie de señales de componentes. La TWD se describe brevemente en el ítem anterior. El algoritmo de descomposición Mallat's se emplea en este estudio.

Según la teoría de Mallat's, la serie tiempo discreto original X_t se descompone en una serie de señales de aproximación y detalle linealmente independientes [Wu et al., 2009].

En el proceso de filtrado, en su nivel más básico, la señal original X_t pasa a través de dos filtros complementarios (filtros de paso bajo y de paso alto) y emerge como dos señales: aproximaciones (A) y detalles (D). Las aproximaciones son los componentes de alta escala y de baja frecuencia de la señal. Los detalles son los componentes de baja escala y de alta frecuencia. Normalmente, el contenido de baja frecuencia de la señal (aproximación, A) es el más importante. Demuestra la identidad de la señal. El componente de alta frecuencia (detalle, D) es el matiz. También es importante observar que la señal cruda (Q) está formado por estos componentes, es decir, $Q=A_1+D_1$ o que $A_1=A_2+D_2$, y de la misma forma $Q=A_3+D_3+D_2+D_1$. El proceso de descomposición puede repetirse, con aproximaciones sucesivas siendo descompuesto en turnos, de modo que una señal se divide en muchos componentes de resolución más baja, esto se llama el árbol de descomposición wavelet, véase Figura 2 [Santos et al., 2014; Satyaji Rao et al., 2014].

Figura 2.- Diagrama de análisis multiresolución de la señal [Satyaji Rao et al., 2014].

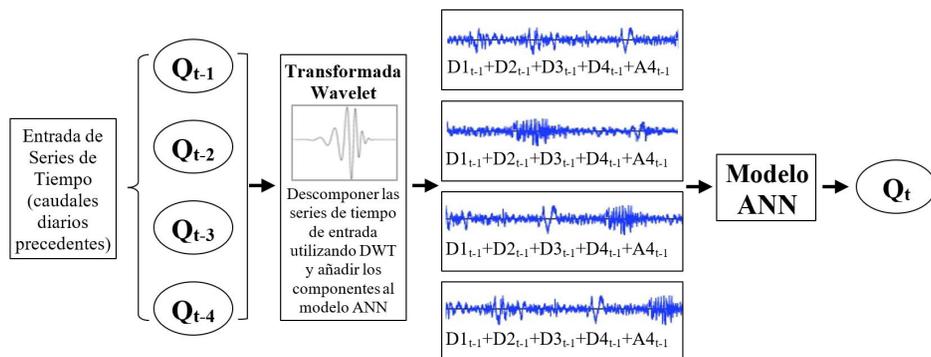


4 COMBINACIÓN DE LA TWD Y ANN

El campo de modelamiento basado en datos comprende una gran variedad de técnicas, en su mayoría procedentes de las estadísticas y la inteligencia artificial [Di et al., 2014]. La mayoría de los estudios existentes han demostrado que las ANN son capaces de superar a las técnicas estadísticas tradicionales [Maier y Dandy, 2000], asimismo, han demostrado ser buenos en la simulación de sistemas complejos, no lineales. Por otro lado, Zhang et al. (2015) a partir de resultados de simulación indicaron que el método WNN

es más preciso que la ANN y se puede utilizar eficazmente en la predicción de series temporales no lineales. Asimismo, Wang y Ding (2003) revelaron que el método WNN podría aumentar la precisión prevista y prolongar la longitud de tiempo de predicción.

Figura 3.- Esquema del modelo híbrido wavelet red neuronal (WNN) [Kisi, 2011].



En este estudio, dos técnicas de modelamiento, la TWD y los modelos ANN, se combinaron para producir un modelo híbrido WNN que integra las ventajas de ambos. En WNN, el proceso de modelamiento integrado incluye dos pasos: (1) La serie temporal de caudales, es decir, una señal original, se descompone con la TWD en subseries una aproximación (A_n) con baja frecuencia, y detalles ($D1, D2, \dots, D_n$) con alta frecuencia; y (2) Estas subseries se usaron como entrada para la red, con la serie original como objetivo (véase Figura 3). Para obtener los pesos óptimos (parámetros) de la estructura de la red, el algoritmo de LM se utiliza para entrenar a la red. El nodo de salida representa el valor original a un paso delante [Adamowski y Sun, 2010; Krishna et al., 2011; Deka et al., 2012; Wei et al., 2012; Satyaji Rao et al., 2014; Nourani et al., 2014]. Todos los análisis se realizaron utilizando el Toolbox Wavelet™ y Neural Network™ en Matlab.

5 EVALUACIÓN DE CRITERIOS DE DESEMPEÑO

Dawson *et al.* (2007) discutieron 20 medidas de desempeño generalmente utilizados en la predicción hidrológica. Para este estudio, principalmente seleccionamos cuatro medidas de desempeño para evaluar el desempeño de los diferentes modelos (ANN y WNN). Todos los modelos fueron evaluados durante la etapa de calibración y validación usando los siguientes índices estadísticos: error absoluto medio (MAE), raíz del error medio cuadrático (RMSE), error relativo absoluto medio (MARE) y coeficiente de determinación (R^2).

El RMSE prevé una buena medida de bondad de ajuste en caudales altos, mientras, medidas de MAE una perspectiva más balanceada de las bondades de ajuste en caudales

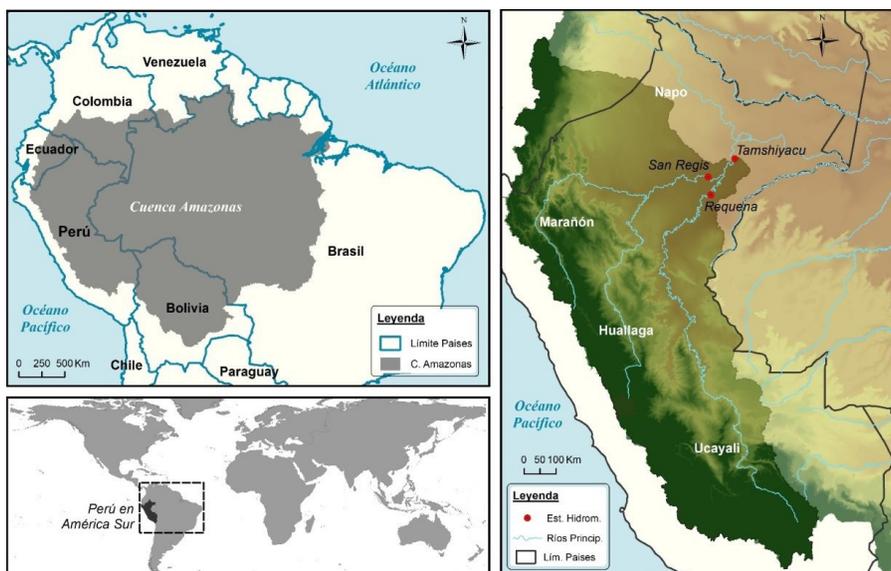
moderados. Los modelos con RMSE bajo se tratan como mejores modelos [Dadu y Deka, 2013]. R^2 es un índice del grado de relación lineal entre los datos observados y simulados, se ha utilizado ampliamente para la evaluación de modelos, a pesar de que son muy sensibles a los valores extremos altos (outliers) e insensible a diferencias aditivo y proporcionales entre las predicciones del modelo y los datos medidos [Wang et al., 2009]. P. ej., una interpretación común es que un valor de R^2 de 0,9 indica un desempeño del modelo muy satisfactorio, un valor en el rango de 0,8 a 0,9 indica un desempeño bastante bueno, y valores por debajo de 0,8 indican un ajuste insatisfactorio [Antil y Tape, 2004].

6 AREA DE ESTUDIO Y DATOS

6.1 ÁREA DE ESTUDIO

La estación hidrométrica de Tamshiyacu (Figura 4, derecha) es la primera estación de aforo en la corriente principal del río Amazonas, situado aguas abajo de la confluencia de los ríos Maraón y Ucayali cerca de la ciudad de Iquitos (a 50 km aguas arriba de la ciudad de Iquitos), drena un área de cuenca de 750 000 km² (53% en los Andes) y tiene un caudal medio anual de 32 000 m³ s⁻¹ [Espinoza et al., 2006; Espinoza et al., 2011; Guyot et al., 2007]. Además, es el principal tributario occidental de la cuenca del Amazonas, presentando la serie histórica de niveles más larga, con datos del año 1984 hasta el presente [Espinoza et al., 2006; 2011]. Asimismo, su ubicación es estratégica, lo que permite la caracterización de un período de sequías/inundaciones en la población Amazónica.

Figura 4.- Ubicación de Perú en América (izquierda inferior). Cuenca Amazonas en América del sur y países involucrados (izquierda superior). Estación hidrométrica de Tamshiyacu (derecha).



6.2 CONJUNTO DE DATOS DISPONIBLES

El conjunto de datos utilizados en este estudio consta de una serie temporal de caudales medias diarias en la estación de aforo Tamshiyacu en el río Amazonas en Perú correspondiente al periodo de 01 de setiembre de 1985 hasta 31 de agosto de 2012 (27 años con 9 862 muestras). Estos datos provienen del monitoreo desarrollado por el Servicio Nacional de Meteorología e Hidrología (SENAMHI) del Perú, como parte del observatorio ORE-HYBAM (SENAMHI-IRD-IGP-UNALM, www.ore-hybam.org). Las características estadísticas del conjunto de datos de caudales diarios se dan en la Tabla 1. El caudal promedio diario fue de 29 610 m³/s con un caudal máximo de 55 420 m³/s en 19 de abril de 2012 y un caudal mínimo de 8 327 m³/s en 5 de setiembre de 2010.

Tabla 1.- Características estadísticas de los caudales diarios del río Amazonas.

Índice	Tamshiyacu [m ³ /s]	Descripción
Min.	8 327	Mínimo
1st Qu.	20 660	1er Cuartil
Median	29 130	Mediana
Mean	29 610	Media
3rd Qu.	38 380	3er Cuartil
Max.	55 420	Máximo
IQR	17 720	Rango Intercuartil
sd	10 771.02	Desviación estándar
cv	0.3638	Coficiente de variación
Skewness	0.1185	Asimetría
Kurtosis	-0.9822	Kurtosis
n	10 398	Número de muestras

7 DESARROLLO DE LOS MODELOS

La determinación de la arquitectura en el desarrollo de los modelos es muy importante, para ello, se requiere de variables de entrada. En este estudio, el conjunto de datos de caudales diarios del río Amazonas (Tamshiyacu) que fue la única entrada utilizada. Por ende, valores de caudales antecedentes a menudo se utilizan como entrada, ya que estos son indirectamente indicativos para las condiciones hidrológicas.

Balayneh y Adamowski (2012) utilizaron el 80% de los datos para entrenar los modelos, mientras que el 20% restante de los datos dividieron en dos subconjuntos de prueba y validación con cada conjunto que comprende el 10% de los datos. Para todos los modelos formulados, en este estudio, se utilizaron 78% de los datos para entrenar los modelos, mientras que el 22% restante de los datos se utilizaron para la etapa de prueba.

Para poner a prueba los modelos ANN y WNN, los datos de entrada a la red se lograron extendiéndose hacia atrás desde el tiempo t , obteniendo series de tiempo $\{Q_{(t)}, Q_{(t-1)}, \dots, y Q_{(t-6)}\}$, hasta seis pasos de tiempo anteriores. Se formularon las siguientes combinaciones: i) $Q_{(t-1)}$, ii) $Q_{(t-1)}, Q_{(t-2)}$, iii) $Q_{(t-1)}, Q_{(t-2)}, Q_{(t-3)}$, iv) $Q_{(t-1)}, Q_{(t-2)}, Q_{(t-3)}, Q_{(t-4)}$, v) $Q_{(t-1)}, Q_{(t-2)}, Q_{(t-3)}, Q_{(t-4)}, Q_{(t-5)}$ y vi) $Q_{(t-1)}, Q_{(t-2)}, Q_{(t-3)}, Q_{(t-4)}, Q_{(t-5)}, Q_{(t-6)}$. Donde $Q_{(t)}$ es el valor de descarga del día actual y $Q_{(t-1)}, \dots$ y $Q_{(t-6)}$ son valor de caudales pasados de un día hasta los 6 días respectivamente.

En la etapa de pronóstico, a partir de las combinaciones formuladas, ahora queremos estimar Q en algún tiempo futuro $Q_{(t+s)} = f(Q_{(t)}, Q_{(t-1)}, \dots)$, donde s se llama el horizonte de pronóstico. P. ej., para predecir sólo una muestra de tiempo en el futuro, $s=1$. Este es un problema de función de aproximación [Akintola et al., 2011]. En este estudio los modelos han sido desarrollados para diferentes horizontes de pronóstico ($s=1, 3, 6, 9, 12, 15, 18, 21$ y 24 días). Los escenarios de entrada y salida son los mismos para ambos modelos.

7.1 MODELOS DE RED NEURONAL ARTIFICIAL (ANN)

En la primera etapa, se desarrollaron modelos ANN utilizando la arquitectura MLP feedforward, sin entradas descompuestos mediante wavelet, es decir, sin procesamiento previo de datos para predecir los datos caudales. Para determinar la arquitectura del modelo ANN, el número óptimo de neuronas en la capa de entrada se determinó mediante prueba y error. Los caudales fueron rezagados para generar varias neuronas en la capa de entrada y el número de neuronas fue elegido como el apropiado, aquellos que proporcionaron valores RMSE más bajos y significativos, tanto en la etapa de entrenamiento y validación. Hubo entre 1-6 entradas para cada modelo ANN.

Tradicionalmente, el número de nodos ocultos para los modelos de ANN se selecciona a través de un método de prueba y error. Sin embargo, un estudio realizado por Balayneh y Adamowski, (2012) indican que el mejor desempeño de una red neural se produce cuando el número de nodos ocultos es igual a $\log(N)$, donde N es el número de muestras de entrenamiento. Asimismo, indican que el número óptimo de neuronas ocultas es $2n+1$, donde n es el número de nodos de entrada. En este estudio, estos dos métodos ayudaron tomar referencia un rango de selección para el número óptimo de nodos ocultos, asimismo, se tomó en cuenta valores cercanos. Cada MLP fue entrenada con 1-18 nodos ocultas en la capa oculta.

Todos los modelos de ANN se han desarrollado utilizando el Toolbox Neural Network de Matlab (R.2013a). La función de transferencia tangente hiperbólica sigmoide (tansig) fue la función de activación de la capa oculta, mientras que la función de activación de la capa de salida fue una función lineal (purelin). Asimismo, fueron entrenados usando

el algoritmo de propagación hacia atrás LM. El objetivo principal fue minimizar el error en la capa de salida mediante la búsqueda de un conjunto de fuerzas de conexión que causan la ANN para producir resultados que son igual o más cerca de los objetivos.

7.2 MODELOS HÍBRIDO WAVELET RED NEURONAL (WNN)

En la segunda etapa, los modelos WNN fueron similares a los modelos de ANN utilizados en la primera etapa. Sin embargo, en lugar de utilizar los datos primarios de caudales en la capa de entrada, los modelos WNN utilizaron datos de caudales que se había descompuesto en altas y bajas frecuencias utilizando el algoritmo transformada wavelet. En este estudio, para descomponer la serie original se elige la función Wavelet Daubechies de orden 2 (db2), una de las familias de wavelets más ampliamente utilizados y orden 2 seleccionado por su mejor desempeño.

El número total de neuronas de entrada para los modelos híbrido WNN se determinó en función al mismo número de neuronas de entrada determinadas para los modelos ANN que exhibía el valor más bajo de RMSE y al número de niveles de descomposición (4 niveles mínimos de descomposición " $L = \text{ent}(\log N)$, siendo N número de muestras de la serie temporal, Nourani et al., (2014)"), para poder comparar las ventajas de las dos técnicas de modelamiento.

Los modelos híbridos WNN fueron entrenados con los datos repartidos exactamente de la misma forma y manera que los modelos tradicionales de ANN, con la excepción de que las entradas se hicieron a partir de subseñales después de que se haya selecciona la descomposición de wavelets. El proceso de selección del número óptimo de neuronas en la capa oculta fue similar al proceso utilizado para los modelos de ANN. Hubo entre 3-20 entradas para cada modelo WNN. Todos los análisis wavelet se realizaron con el Toolbox Wavelet en Matlab (R.2013a).

8 RESULTADOS Y DISCUSIONES

De un total de 9 862 (27 años) datos diarios de caudales del río Amazonas fueron particionados en dos partes, los primeros subconjuntos de 7 670 datos (21 años) representando el 78.8% se utilizaron para el entrenamiento de la red y los restantes subconjunto de 2 192 datos (6 años) que representa el 22.2% se utilizaron para la validación de pronóstico de los modelos.

En la primera etapa, un modelo ANN perceptrón multicapa feedforward de propagación hacia atrás sin procesamiento previo de datos fue desarrollado para predecir el caudal diario. Una estructura de red de tres capas (p, m, n) se eligió para el

presente estudio, en el que p es el número de neuronas en la capa de entrada, m son las neuronas en la capa oculta y n es el número de neuronas (una sola neurona para todas las formulaciones) en la capa de salida. P. ej., el modelo ANN4 (negrita en la Tabla 2) tiene como estructura (4-17-1), que indica 4 neuronas en la capa de entrada, 17 neuronas en la capa oculta y una sola neurona en la capa de salida.

Cada MLP fue entrenado utilizando el esquema de propagación hacia atrás con el algoritmo de entrenamiento LM, asimismo, utilizando la función de activación sigmoideal (tansig) y lineal (purelin) en la capa oculta y la capa de salida respectivamente para optimizar los parámetros. Se identificó el número óptimo de las neuronas en la capa oculta usando un procedimiento de prueba y error, encontrándose el número de neuronas ocultas de 1 a 18 en función al número de neurona en la capa de entrada. El número de neuronas ocultas se selecciona en base al RMSE más bajo.

Tabla 2.- Resultados del desempeño de los modelos ANN y WNN con diferentes estructuras.

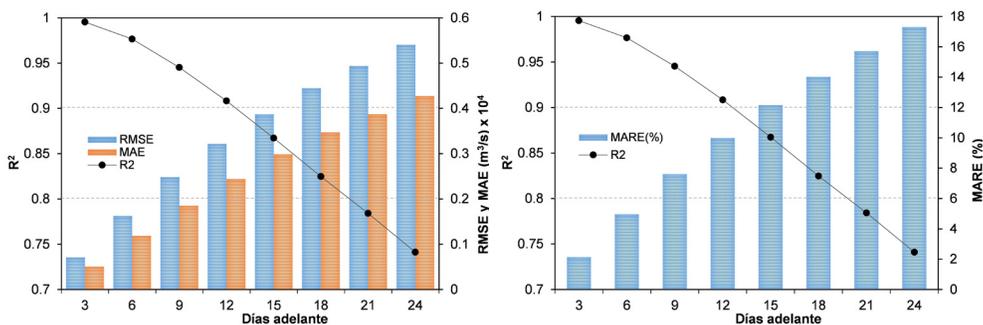
Modelo	Tipo Wavelet	Nivel	Estructura ANN	Calibración			Validación		
				RMSE	MAE	R ²	RMSE	MAE	R ²
ANN1	---	---	1-1-1	452.4876	338.5650	0.99819	433.2804	330.6612	0.99861
ANN2	---	---	2-8-1	191.1247	133.2611	0.99968	178.9603	126.9110	0.99976
ANN3	---	---	3-9-1	177.7321	122.8412	0.99972	158.4033	114.1050	0.99981
ANN4	---	---	4-17-1	177.6208	122.7203	0.99972	157.1787	113.1957	0.99982
ANN5	---	---	5-14-1	177.4952	122.3886	0.99972	157.9258	113.7594	0.99982
ANN6	---	---	6-18-1	175.9491	121.8620	0.99973	157.3352	113.0965	0.99982
WNN1	db2	2	3-17-1	417.5706	314.9734	0.99846	404.3648	310.8980	0.99879
WNN2	db2	3	4-9-1	413.6861	311.9660	0.99849	402.3197	306.4643	0.99881
WNN3	db2	4	5-31-1	399.5092	303.7769	0.99859	400.8023	308.1361	0.99881
WNN4	db2	2	6-23-1	105.5777	69.0321	0.99990	102.2373	66.8341	0.99992
WNN5	db2	3	8-27-1	89.8504	59.9276	0.99993	89.5953	59.0330	0.99994
WNN6	db2	4	10-22-1	85.0158	56.5026	0.99994	83.6554	55.7255	0.99995
WNN7	db2	2	9-26-1	87.7928	56.9649	0.99993	82.7690	54.1139	0.99995
WNN8	db2	3	12-25-1	77.6622	50.9402	0.99995	74.8982	49.6111	0.99996
WNN9	db2	4	15-35-1	67.9331	45.8668	0.99996	70.4617	47.5738	0.99996
WNN10	db2	2	12-31-1	50.0689	35.0960	0.99998	56.0083	36.9509	0.99998
WNN11	db2	3	16-24-1	48.7334	33.6675	0.99998	52.1359	35.2722	0.99998
WNN12	db2	4	20-40-1	44.0735	30.9987	0.99998	51.6737	34.9041	0.99998

En este estudio, seis modelos de ANN (ANN1, ..., hasta ANN6 en la Tabla 2) han sido desarrollados con diferentes escenarios de entrada a la red indicadas en la sección de desarrollo de los modelos. Por otro lado, también estructurados para diferentes horizontes de pronóstico ($s=1, 3, 6$, hasta 24 días). Sin embargo, los resultados correspondientes a un

plazo de anticipación ($s=1$) durante el periodo de entrenamiento y validación se muestran en la Tabla 2.

El análisis de los resultados de la Tabla 2, se observa claramente que, en la fase de validación, el modelo ANN4 (negrita en la Tabla 2) con estructura (4-17-1) obtiene el mejor desempeño con valores de RMSE y R^2 de 157.18 y 0.99 respectivamente. Asimismo, se observa que el resto de los modelos con mayor número de entradas no mejoran estos resultados.

Figura 5.- Desempeño del modelo ANN4 (4-17-1) en la etapa de entrenamiento en RMSE, MAE, MARE y R^2 para varios horizontes de pronóstico.

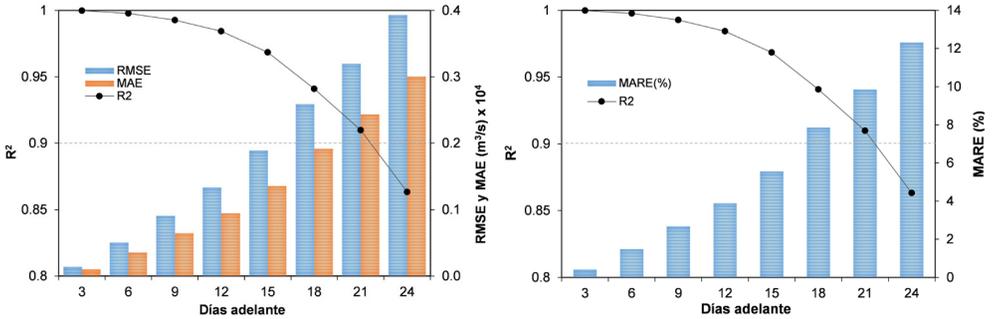


En esta etapa, también se evaluaron los resultados del modelo ANN4 (4-17-1) con los criterios de desempeño RMSE, MAE, MARE (%) y R^2 para varios horizontes de pronóstico mostrados en la Figura 5 para visualizar las variaciones de error. Por tanto, de la Figura 5, según interpretaciones de Antil y Tape (2004), los pronósticos para los 21 y 24 días con valores de R^2 de 0.78 y 0.74 respectivamente, indicarían desempeño de los modelos con ajuste insatisfactorio.

En la segunda etapa, para el desarrollo de los modelos híbridos WNN, los datos de la serie original de caudales se descompusieron a sus componentes de Aproximación y Detalles (subseries) en distintos niveles (2, 3 y 4) utilizando la DWT de la función wavelet Daubechies 2 (db2). Estas subseries se usaron como entradas para la red diseñada, con la serie original como objetivo (target).

En este estudio, se combinaron distintas entradas (i, ii, iii y iv) y niveles de descomposición para formular doce modelos híbridos WNN (WNN1, ..., hasta WNN12 en la Tabla 2) para diferentes horizontes de pronóstico ($s=1, 3, 6, 9$, hasta 24 días). Sin embargo, el desempeño de estos modelos en términos de pruebas estadísticas (RMSE, MAE y R^2) correspondientes a un plazo de anticipación ($s=1$) en la fase de entrenamiento y validación se da en la Tabla 2.

Figura 6.- Desempeño del modelo híbrido WNN12 (20-40-1) en la etapa de entrenamiento en RMSE, MAE, MARE y R^2 para varios horizontes de pronóstico.



Los resultados del modelo WNN12 (negrita en la Tabla 2) con estructura (20-40-1), muestra claramente su mejor desempeño en la fase de calibración y validación con valores de RMSE de 44.07 y 51.67 respectivamente. Asimismo, se evaluaron los resultados del modelo WNN12 con las pruebas estadísticas RMSE, MAE, MARE y R^2 para varios horizontes de pronóstico que se muestran en la Figura 6 para representar las variaciones de error. De esta Figura 6, de acuerdo con Antil y Tape (2004), el pronóstico para el día 24 con valor de R^2 de 0.86, indicaría desempeño bastante bueno.

8.1 COMPARACIÓN DE LOS DOS MODELOS FORMULADOS

La evaluación de los desempeños de estos dos grupos de modelos de pronóstico ANN y WNN correspondientes a un plazo de anticipación ($s=1$) en la fase de entrenamiento y validación en términos de pruebas estadísticas generales (RMSE, MAE y R^2) se da en la Tabla 2.

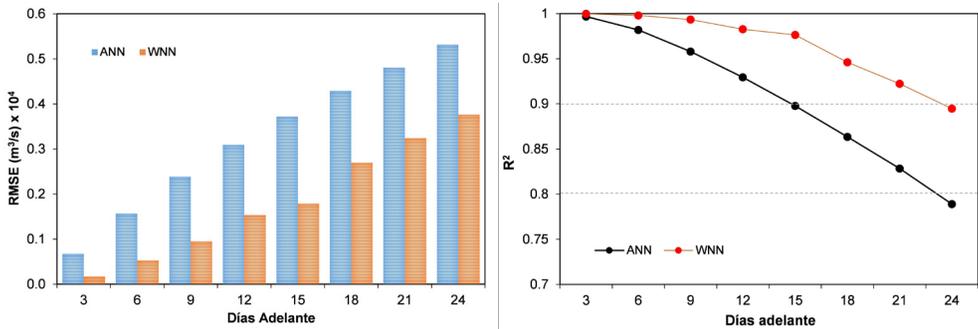
La Figura 7 revela que para todos los horizontes de pronóstico el modelo WNN12 es mucho mejor en comparación con el modelo ANN4 en términos de RMSE y R^2 durante el periodo de validación. P. ej., el RMSE (3 760.29 m^3/s) es mucho menor para el modelo híbrido WNN12 en comparación con ANN4 (5 317.52 m^3/s), asimismo, el R^2 (0.89) es mucho mejor para el modelo WNN comparado con ANN (0.79) para el horizonte de pronóstico de 24 días (véase Figura 7).

Los resultados corroboraron que el modelo WNN12 con 20 neuronas de entradas a la red (es decir, se utilizó el cuarto escenario de entrada y el nivel 4 de descomposición con wavelet “db2”), tuvo el mejor desempeño para simular la serie de caudal. Además, el análisis comparativo en términos de R^2 en la etapa de validación mostró que mientras ANN4 podría cumplir satisfactoriamente en pronosticar con precisión hasta los 21 días de horizonte pronóstico, el modelo híbrido WNN12 mejoró significativamente mostrando

un desempeño mucho mejor y prolongando el horizonte de pronóstico hasta los 24 días calificado como satisfactorio (véase Figura 7).

A partir de la Figura 7, también se observó que los valores de los estadísticos varían según el horizonte de pronóstico con RMSE (169.96 m³/s a 3760.29 m³/s) y el coeficiente R² (0.99979-0.89478) para el modelo híbrido WNN; y RMSE (673.85 m³/s a 5317.52 m³/s) y el coeficiente R² (0.99665-0.78902) para el modelo ANN, durante el período de validación. Se puede confirmar que el modelo WNN superó al modelo ANN reduciendo el error RMSE en un 30%, mientras que el coeficiente R² se incrementó por encima de 13% para el horizonte de pronóstico más lejano (24 días). Asimismo, el error RMSE se incrementó a 75% y el coeficiente R² disminuyó a 0.3% para el horizonte de pronóstico de 3 días.

Figura 7.- Comparación del desempeño del modelo ANN4 (4-17-1) y el modelo híbrido WNN12 (20-40-1) en la etapa de validación en RMSE y R² para varios horizontes de pronóstico.



9 RESUMEN Y CONCLUSIONES

Centrado en el pronóstico de caudales a corto plazo usando únicamente datos de caudales diarios como variable de entrada se desarrolló un modelo híbrido WNN mediante la combinación de dos métodos, esto es, la TWD y las ANN. La TWD se utilizó para la descomposición de los datos de caudales no estacionarias en series estacionarias. Estos descompuestos alimentaron como entradas a la ANN para pronosticar la serie original. También, el modelo ANN se desarrolló y se compararon con el modelo WNN. Los análisis comparativos revelaron que el modelo WNN exhibe un mejor desempeño en modelamiento de datos de series temporales de caudales diarias.

Además, abordamos la eficacia del modelo híbrido WNN desarrollado utilizando wavelets Daubechies de orden 2 (db2) como wavelets madre para pronosticar series de caudales sobre varios horizontes de tiempo 1, 3, 6, ..., hasta 24 días en la estación de aforo Tamshiyacu situada en el río Amazonas en Perú. Finalmente se determinó que, para todos los casos de horizontes de pronóstico, los modelos WNN proporcionan resultados más

precisos en comparación a los ANN solos. Esto se debe principalmente a la capacidad de la TWD para proporcionar descomposiciones útiles de la serie de tiempo en múltiples niveles de aproximación y detalle.

Las ANN son modelos de pronóstico muy útiles para sistemas hidrológicos donde se requiere realizar pronósticos a corto plazo. La facilidad de recalibración y adaptación del modelo hace que sea posible aplicar los modelos a medida que se dispongan de nuevos eventos y así mejorar con el tiempo la precisión de los pronósticos de los mismos. Sin embargo, no son muy satisfactorios en términos de precisión. Los resultados finales indican que los modelos ANN son superados significativamente por los modelos híbridos WNN como un método nuevo y prometedor de pronóstico de caudales a corto plazo que sería útil para los sistemas de pronóstico de eventos futuros en los ríos de la Amazonía peruana, donde la disponibilidad de datos es limitada.

10 AGRADECIMIENTO

Los autores agradecen a los responsables del Convenio de Cooperación Interinstitucional entre la Autoridad Nacional del Agua-ANA y el Instituto Geofísico del Perú-IGP, por proporcionar las facilidades necesarias para llevar a cabo este estudio. Asimismo, agradecer de manera especial al Dr. Waldo Lavado, investigador científico de SENAMHI, por su orientación, paciencia y conocimientos profundos brindados en su elaboración.

REFERENCIAS

- Abrahart** R.J., Kneale P.E., See L., (2004). “*Neural Networks in Hydrology*”, A.A. Balkema, Rotterdam.
- Adamowski** J., (2008). “Development of a short-term river flood forecasting method for snowmelt driven floods based on wavelet and cross-wavelet analysis”. *J. Hydrol.* 353, 247–266.
- Adamowski** J., Sun K., (2010). “Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds”. *J. Hydrol.* 390, 85–91.
- Adamowski** J. and Chan H. F., (2011). “A wavelet neural network conjunction model for groundwater level forecasting”, *Journal of Hydrology* 407, 28-40.
- Akintola** K.G., Alese B.K. and Thompson A.F., (2011). “Time series forecasting with neural network: a case study of stock prices of intercontinental bank Nigeria”, *IJRRAS* 9(3), 467- 472.
- Anctil** F., Tape D.G., (2004). “An exploration of artificial neural network rainfall-runoff forecasting combined with wavelet decomposition”. *J Environ Eng Sci* 3:121-128.
- Belayneh** A. and Adamowski J., (2012). “Standard Precipitation Index Drought Forecasting Using Neural Networks, Wavelet Neural Networks, and Support Vector Regression”, *App. Comp. Int. & Soft Comp.* 794061, pp. 13.

- ASCE** Task Committee, (2000a). "Artificial Neural Networks in Hydrology-I: Preliminary Concepts", *Journal of Hydrologic Engineering*, Vol. 5, No. 2, pp. 115-123.
- ASCE** Task Committee, (2000b). "Artificial Neural Networks in Hydrology-II: Hydrologic Applications", *Journal of Hydrologic Engineering*, Vol. 5, No. 2, pp. 124- 137.
- Chau** K.W., Wu C.L. and Li Y.S., (2005). "Comparison of several flood forecasting models in Yangtze River", *Journal of Hydrologic Engineering*, ASCE, Vol. 10, No. 6, 2005, pp. 485-491.
- Dadu** K. S. and Deka P. C., (2013). "Multistep lead time forecasting of hydrologic time series using Daubechies Wavelet-Neural network hybrid model", *International Journal of Scientific & Engineering Research*, Volume 4, Issue 10, ISSN 2229-5518.
- Dawson** C. W. and Wilby R. L., (2001). "Hydrological modelling using artificial neural networks", *Progress in Physical Geography* 25, 1 pp. 80-108.
- Dawson** C.W., Abrahart R.J. and See L.M., (2007). "HydroTest: A web-based toolbox of evaluation metrics for the standardised assessment of hydrological forecasts", *Env. Mod. & Software* 22, 1034-1052.
- De Vos** N.J., and Rientjes T.H.M., (2005). "Constraints of artificial neural networks for rainfall-runoff modeling: Trade-offs in hydrological state representation and model evaluation", *Hydrol. & Earth System Sciences*, 9:111-126.
- Deka** P. C., Haque L. and Banhatti A., (2012). "Discrete Wavelet-Ann Approach in Time Series Flow Forecasting-A Case Study of Brahmaputra River", *Int. J. of Earth Sc. and Engineering*, 5(4):673-685.
- Deka** P. C. and Prahlada R., (2012). "Discrete wavelet neural network approach in significant wave height forecasting for multistep lead time", *Ocean Engineering* 43: 32-42.
- Di** C., Yang X., and Wang X. (2014). "A four-stage hybrid model for hydrological time series forecasting". *PLOS ONE*, vol.9, no.8, Article ID e104663.
- Dibike** Y. B. and Solomatine D. P., (2001). "River Flow Forecasting Using Artificial Neural Networks", *Journal of Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 26(1), 1-8.
- Espinoza** J.C., Ronchail J., Frappart F., Lavado W., Santini W., Guyot J. L. (2013). "The major floods in the Amazonas River and tributaries (Western Amazon basin) during the 1970- 2012 period: A focus on the 2012 flood". *Journal of Hydrometeorology*.
- Haykin** S., (1999). "Neural Networks: A Comprehensive Foundation", 2 edn. New Jersey: Prentice Hall.
- Kim** T.-W. and Valdés J. B., (2003). "Nonlinear Model for Drought Forecasting Based on a Conjunction of Wavelet Transforms and Neural Networks", *J. Hydrol. Eng.*, 8:319-328.
- Kisi** O., (2004b). "Multi-layer perceptrons with Levenberg-Marquardt optimization algorithm for suspended sediment concentration prediction and estimation". *Hydrol. Sci. J.* 49(6), 1025-1040.
- Krishna** B., Satyaji Rao Y. R. and Nayak P. C. (2011). "Time Series Modeling of River Flow Using Wavelet Neural Networks", *Journal of Water Resource and Protection*, 3: 50-59.
- Lavado** W., Labat D., Ronchail J., Espinoza J. C., Guyot J. L. (2012). "Trends in rainfall and temperature in the Peruvian Amazon-Andes basin over the last 40 years (1965-2007)". Accepted in *Hydrological Processes*.

- Maier** H.R. and Dandy G.C., (2000). "Neural networks for the prediction and forecasting of water resources variables: A review of modelling issues and applications". *Environ. Modell. Softw.*, 15, 101-124.
- Mashor** M. Y., (2002). "On-line short-term streamflow forecasting using neural networks", *Friend 2002 regional hydrology: bridging the gap between research and practice*, IAHS publication 274: 8.
- Nourani** V., Hosseini Baghanam A., Adamowski J., and Kisi O. (2014). "Applications of hybrid wavelet–Artificial Intelligence models in hydrology: A review". *Journal of Hydrology* 514, 358-377.
- Pandey** A. S., Singh D., and Sinha S. K., (2010). "Intelligent hybrid wavelet models for short-term load forecasting", *IEEE Trans. on power syst.*, vol. 25, pp. 1266-1273.
- Pramanik** N., Panda R. K., and Singh A., (2011). "Daily river flow forecasting using wavelet ANN hybrid models", *Journal of Hydroinformatics*, vol. 13, no. 1, pp. 49–63.
- Sang** Y. F., (2012). "A practical guide to discrete wavelet decomposition of hydrologic time series", *Water Resources Management*, vol. 26, no. 11, pp. 3345–3365.
- Santos** C.A.G., Freire P.K.M.M., Silva G.B.L., Silva R.M., (2014). "Discrete wavelet transform coupled with ANN for daily discharge forecasting into Três Marias reservoir", *Int. Assoc. of Hydr. Sc.* 364, Bologna, Italy, pp. 100-105.
- Satyaji Rao** Y. R., Krishna B. and Venkatesh B., (2014). "Wavelet Based Neural Networks for Daily Stream Flow Forecasting", *Intern. J. of Em. Tech. and Adv. Eng.*, Vol. 4, Issue 1, ISSN 2250-2459.
- Shrestha** R.R. and Nestmann F., (2009). "Physically based and data-driven models and propagation of input uncertainties in river flood prediction". *J. Hydrol. Eng.*, 14, 1309–1319.
- Wang** W., (2006). "Stochasticity, Nonlinearity and Forecasting of Streamflow Processes", IOS Press: Amsterdam, The Netherlands.
- Wang** D. and Ding J., (2003). "Wavelet Network Model and Its Application to the Prediction of Hydrology", *Nature and Science*, Vol. 1, No. 1, pp. 67-71.
- Wang** W.C., Chau K.W., Cheng C.T. and Qiu L., (2009). "A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series", *Journal of Hydrology* 374, 294-306.
- Wu** C.L., Chau K.W., Li Y.S., (2009). "Methods to improve neural network performance in daily flows prediction". *Journal of Hydrology* 372, 80-93.
- Zhang** F., Dai H., Tang D., (2014). "A Conjunction Method of Wavelet Transform-Particle Swarm Optimization-Support Vector Machine for Streamflow Forecasting", *J. App. Math.*, 910196:1-910196:10.

SOBRE O ORGANIZADOR

Xosé Somoza Medina (1969, Ourense, España) Licenciado con Grado y premio extraordinario en Geografía e Historia por la Universidad de Santiago de Compostela (1994). Doctor en Geografía e Historia por la misma universidad (2001) y premio extraordinario de doctorado por su Tesis “Desarrollo urbano en Ourense 1895-2000”. Profesor Titular en la Universidad de León, donde imparte clases desde 1997. En la Universidad de León fue Director del Departamento de Geografía entre 2004 y 2008 y Director Académico de la Escuela de Turismo entre 2005 y 2008. Entre 2008 y 2009 ejerció como Director del Centro de Innovación y Servicios de la Xunta de Galicia en Ferrol. Entre 2007 y 2009 fue vocal del comité “Monitoring cities of tomorrow” de la Unión Geográfica Internacional. En 2012 fue Director General de Rehabilitación Urbana del Ayuntamiento de Ourense y ha sido vocal del Consejo Rector del Instituto Ourenseño de Desarrollo Local entre 2011 y 2015. Ha participado en diversos proyectos y contratos de investigación, en algunos de ellos como investigador principal, con temática relacionada con la planificación urbana, la ordenación del territorio, las nuevas tecnologías de la información geográfica, el turismo o las cuestiones demográficas. Autor de más de 100 publicaciones relacionadas con sus líneas de investigación preferentes: urbanismo, turismo, gobernanza, desarrollo, demografía, globalización y ordenación del territorio. Sus contribuciones científicas más importantes se refieren a la geografía urbana de las ciudades medias, la crisis del medio rural y sus posibilidades de desarrollo, la evolución del turismo cultural como generador de transformaciones territoriales y más recientemente las posibilidades de reindustrialización de Europa ante una nueva etapa posglobalización. Ha participado como docente en masters y cursos de especialización universitaria en Brasil, Bolivia, Colombia, Paraguay y Venezuela y como docente invitado en la convocatoria Erasmus en universidades de Bulgaria (Sofía), Rumanía (Bucarest) y Portugal (Porto, Guimarães, Coimbra, Aveiro y Lisboa). Ha sido evaluador de proyectos de investigación en la Agencia Estatal de Investigación de España y en la Organización de Estados Iberoamericanos (OEI). Como experto europeo en Geografía ha participado en reuniones de la Comisión Europea en Italia y Bélgica. Impulsor y primer coordinador del proyecto europeo URBACT, “come Ourense”, dentro del Programa de la Unión Europea “Sostenibilidad alimentaria en comunidades urbanas” (2012-2014). Dentro de la experiencia en organización de actividades de I+D+i se pueden destacar la organización de diferentes reuniones científicas desarrolladas dentro de la Asociación de Geógrafos Españoles (en 2002, 2004, 2012 y 2018).

ÍNDICE REMISSIVO

A

Abastecimiento energético 158

Agricultura 1, 2, 3, 4, 6, 9, 16, 52, 226, 276

Agua 1, 2, 3, 4, 5, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 35, 66, 72, 83, 89, 90, 91, 92, 94, 95, 97, 99, 100, 101, 152, 153, 154, 164, 165, 166, 167, 168, 170, 175, 179, 180, 208, 209, 281, 282, 283

ANN 19, 20, 21, 22, 23, 25, 26, 29, 30, 31, 33, 34, 35, 37

Arqueología 149, 151, 156, 157

Arsénico 207, 208, 209, 210, 213, 214, 215

B

Bioenergía 158, 164

Biogás 84, 158, 160, 161, 162, 163, 164, 165, 166, 167, 168, 169, 170, 171, 172, 173

Biomasa 50, 53, 54, 55, 56, 57, 58, 59, 63, 64, 83, 84, 158, 266, 269, 271, 277, 278

C

Cauce 1, 5, 6, 7, 11, 15, 16, 17

Caudal mínimo 1, 10, 28

Cementos alternativos 174

Ciudad igualitaria 125, 126, 127, 144

Coahuila 1, 2, 3, 5, 7, 14, 18, 38

Comarca Lagunera 1, 2, 3, 4, 6, 15, 16, 17, 18

Conservación 2, 10, 12, 13, 14, 15, 17, 64, 74, 75, 77, 78, 90, 91, 92, 232, 234, 235

COVID-19 86, 102, 103, 113, 114, 288, 289, 290, 291, 308, 309, 311

Cuenca 1, 4, 5, 6, 7, 8, 11, 12, 13, 15, 16, 17, 19, 27, 154

Cultura ambiental 65, 74, 75, 78

D

Daucus carota 207, 208, 209, 213, 215

Dendroenergía 265

Densidad anhidra 279, 283, 284, 285

Densidad básica 279, 283, 284, 285

Densidad de la pared celular 279, 281, 282, 283, 284, 285, 286

Derechos 1, 2, 7, 9, 11, 12, 13, 14, 15, 16, 17, 90, 128, 130

Desarrollo cognitivo 228, 243
Desarrollo de competencias 89, 95
Desarrollo local 80
Difusión 77, 86, 207, 209, 213, 214
DIN EN ISO 13849 245, 262
Diseño de productos 65
Diterpenoids 216, 218, 221, 222, 223, 224, 225, 226, 227
Durango 1, 2, 3, 4, 5, 6, 7, 10, 296, 311
DWSIM 288, 289, 290, 292, 294, 295, 296, 297, 298, 299, 300, 301, 302, 303, 304, 305, 306, 307, 308, 309, 310

E

Economía 4, 64, 66, 69, 73, 80, 82, 91, 151, 158, 170, 174, 176, 177, 178, 179, 181, 276
Economía circular 66, 69, 73, 158, 174, 176, 177, 178, 179, 181
Ecosistema 1, 2, 4, 9, 10, 12, 16, 80, 81
Educación 15, 18, 65, 67, 80, 83, 85, 87, 88, 90, 93, 97, 101, 102, 103, 104, 107, 108, 113, 114, 124, 125, 135, 137, 145, 289, 309, 310, 311
E-learning 102, 103, 107, 113, 114
Electrochemical etching 185, 186, 196, 197
Emprendedorismo 80, 81, 82, 83, 85, 86, 88
Endophytic bacteria 39
Energía 21, 72, 80, 81, 84, 85, 88, 158, 159, 160, 162, 165, 166, 168, 169, 172, 173, 174, 175, 179, 180, 228, 232, 233, 234, 235, 238, 240, 266, 278
Energías renovables 67, 80, 81, 83, 85, 88, 159, 160
Espacio 50, 53, 86, 103, 104, 108, 137, 140, 141, 142, 143, 147, 149, 150, 151, 152, 154, 155, 156, 237
España 18, 87, 88, 112, 125, 127, 128, 131, 135, 136, 139, 140, 144, 146, 147, 156, 164, 173, 243, 279

F

Failure Mode and Effects Analysis 245, 262
Feminismo en la ciudad 125
FMEA 245, 246, 249, 250, 253, 254, 255, 257, 259, 260, 261, 262, 263
Fuerza de trabajo 115, 120
Functional foods 199

G

Gas sensors 185, 186, 189

Geopolímeros 174, 176, 177, 178, 179, 180, 181

Gestión 1, 2, 5, 7, 8, 9, 11, 13, 14, 15, 16, 17, 20, 66, 74, 89, 90, 91, 92, 93, 94, 95, 99, 100, 101, 108, 114, 125, 136, 145, 159, 178, 311

Gestión educativa 89

Grado de terneza 207, 209, 211, 212

H

Híbrido 19, 21, 26, 30, 33, 34, 264, 267, 270, 271, 278

Historia 18, 125, 126, 147, 149, 151, 155, 156, 157

Hydrocarbons 39, 43, 45, 48

I

Instrucción 228, 229, 230, 231, 233, 237, 243

L

Laguna 1, 3, 4, 7, 18, 48, 73

Lepidoptera 216, 217, 225, 226, 227

Lethal and sublethal effects 216, 225, 227

Líneas de producción 115, 118, 121, 122, 123

M

Macroporous silicon 185, 186, 187, 188, 189, 190, 192, 196, 197

Materiales inteligentes 174, 181

Mathematical modeling 199, 201, 202

Medio ambiente 1, 2, 4, 11, 12, 13, 14, 16, 17, 64, 73, 78, 79, 81, 85, 88, 90, 132, 133, 134, 159, 163, 174, 181

Métodos de trabajo 115, 118, 121, 122, 123

Mezquite 65, 66, 67, 68, 69, 73

Mid Infrared 185, 190, 197

Mineralization 39, 40, 43, 47, 208

Modelo matemático 22, 228, 231, 233, 234, 236, 237, 238, 239, 240, 241

Modelos de simulación 115, 116, 124

Municipio 4, 6, 66, 74, 75, 76, 77, 135, 138, 158, 160, 161

O

Olives 198, 199, 200, 201, 202, 203, 205, 206

P

Perspectiva de género 125, 126, 127, 130, 131, 132, 134, 136, 138, 143, 144, 145, 146, 147

Plants 38, 39, 41, 47, 216, 217, 227, 265, 277, 292, 300

Poda 65, 66, 67, 68, 264, 265, 267, 268, 269, 270, 271, 272, 273, 274, 275

Porosidad 180, 279, 281, 283, 284, 285, 286

Potassium chloride 199, 200, 201, 205

Presa 1, 3, 4, 5, 6, 7, 10, 18

Process simulation 288, 290, 291, 292, 293, 299, 300, 301, 302, 306, 308

Profesionalización en el sector hídrico 89

Programa 10, 19, 54, 63, 66, 74, 75, 76, 77, 78, 79, 89, 91, 92, 95, 97, 98, 99, 103, 116, 137, 140, 161, 268, 276, 283

Pronóstico a corto plazo 19

Propiedad física 279

Purificación 164, 169

R

Recepa 264, 265, 269, 275

Remediación ambiental 174

Remote emergency teaching 288

Rendimiento escolar 102, 104, 105, 106, 107, 108, 111, 112, 113, 114

Residuos sólidos 65, 158, 159, 160, 163

Residuos sólidos urbanos 158, 159, 160, 163

Riego 1, 3, 4, 5, 7, 13

Río 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 15, 16, 17, 18, 19, 21, 27, 28, 30, 34, 150, 152, 218, 226

Río Amazonas 19, 21, 27, 28, 30, 34

S

Safety Function-FMEA 245

Secuestro de carbono 51, 52, 59

Sendero 149, 150, 151, 153, 154, 155

Servicio ambiental 51, 52, 60, 61

Siloxanos 164, 165, 166, 167, 168, 169, 170, 171, 172, 173

Silvicultura 265
Sistema agroforestal 51, 61, 62, 64
Soil 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48, 51
Sticherus quadripartitus 216, 217, 218

T

Tecnologías 4, 82, 107, 140, 158, 159, 164, 166, 167, 173, 180, 312
Teorías prescriptivas 228
Tiempo de cocción 207, 209, 211, 212, 214
Tierra 1, 51, 56, 57, 58, 59, 60, 61, 64, 66, 154, 156
Transformación 65, 137, 138, 149, 152, 158, 281, 309
Transformada wavelet 19, 21, 24, 30

U

Urbanismo no sexista 125

V

Vertederos 158, 160, 164, 165, 167, 171, 173

Y

YouTube channel 288, 290, 299, 300, 302, 304, 306, 310