

DEPARTAMENTO DE INGENIERÍA RURAL Y AGROALIMENTARIA



UNIVERSIDAD
POLITECNICA
DE VALENCIA

*Aplicación de redes neuronales artificiales para
predicción de variables en ingeniería del riego:
evapotranspiración de referencia y pérdidas
de carga localizadas en emisores integrados*

TESIS DOCTORAL

presentada por:

D. Pau MARTÍ PEREZ

dirigida por:

Dr. D. Álvaro ROYUELA TOMÁS

Valencia, febrero de 2009

a Carola, Ximo i Guille

***Nada me retuvo. Me liberé y fui.
Hacia placeres que estaban
tanto en la realidad como en mi ser,
a través de la noche iluminada.
Y bebí un vino fuerte, como
sólo los audaces beben el placer.***

K. KAVAFIS, Poesías Completas

índice de contenidos

ÍNDICE DE CONTENIDOS.....	I
AGRADECIMIENTO.....	V
RESUM.....	VII
RESUMEN.....	IX
ABSTRACT.....	XI
ÍNDICE DE FIGURAS.....	XIII
ÍNDICE DE TABLAS.....	XVII
LISTA DE VARIABLES.....	XXVII
LISTA DE ACRÓNIMOS.....	XXXI
PUBLICACIONES Y PONENCIAS EXTRAÍDAS DE LA TESIS.....	XXXIII
CAPÍTULO 1.....	1
1.1. MOTIVACIÓN.....	5
1.2. REDES NEURONALES.....	8
1.2.1. <i>Introducción</i>	8
1.2.2. <i>Fundamentos biológicos de las redes neuronales</i>	9
1.2.3. <i>Definición y propiedades</i>	11
1.2.4. <i>Evolución histórica de las redes neuronales artificiales</i>	13
1.2.5. <i>Aplicaciones</i>	15
1.3. INTRODUCCIÓN A LOS PROBLEMAS ABORDADOS.....	17
1.3.1. <i>Estudio de pérdidas de carga localizadas en emisores integrados</i>	17
1.3.2. <i>Estudio de la evapotranspiración de referencia</i>	23
1.4. OBJETIVOS.....	28
1.4.1. <i>Objetivos generales</i>	28
1.4.2. <i>Objetivos particulares</i>	29
1.4.2.1. <i>Estudio de pérdidas de carga singulares</i>	29
1.4.2.2. <i>Estudio de la evapotranspiración de referencia</i>	29
1.5. ESTRUCTURA DEL CONTENIDO.....	30
CAPÍTULO 2.....	31
2.1. INTRODUCCIÓN.....	35
2.2. MATERIALES Y MÉTODOS.....	35
2.2.1. <i>Desarrollo experimental</i>	35
2.2.2. <i>Variables del modelo</i>	38
2.2.3. <i>Gestión de datos experimentales</i>	41
2.2.4. <i>Propiedades de las redes neuronales utilizadas e implementación en Matlab</i>	44
2.2.4.1. <i>Propiedades de la ANN</i>	44
2.2.4.1.1. <i>Modelo neuronal</i>	44
2.2.4.1.2. <i>Algoritmo de entrenamiento</i>	45
2.2.4.1.3. <i>Criterio de parada</i>	46
2.2.4.2. <i>Implementación de las redes</i>	47
2.2.4.2.1. <i>Arquitecturas analizadas. Número de repeticiones</i>	47
2.2.4.2.2. <i>Parámetros de entrenamiento</i>	49
2.2.5. <i>Indicadores de calidad del comportamiento de las redes</i>	50
2.3. RESULTADOS Y DISCUSIÓN.....	53
2.3.1. <i>Selección de las variables del modelo</i>	53
2.3.1.1. <i>h_j como variable de salida</i>	54
2.3.1.2. <i>α como variable de salida</i>	55
2.3.1.3. <i>Comparativa general</i>	55

2.3.2. Composición del subgrupo de verificación.....	58
2.3.3. Propuesta de modelo ANN.....	61
2.4. CONCLUSIONES.....	66
2.5. LÍNEAS DE FUTURO	67
CAPÍTULO 3.....	69
3.1. INTRODUCCIÓN.....	73
3.2. MATERIALES Y MÉTODOS.....	73
3.2.1. Obtención de datos climáticos.....	73
3.2.2. Gestión de datos climáticos	74
3.2.3. Obtención de targets y caracterización de estaciones.....	75
3.2.4. Propiedades de las redes neuronales utilizadas e implementación en Matlab	79
3.2.4.1. Propiedades de la ANN.....	79
3.2.4.2. Implementación de las redes	80
3.2.4.2.1. Neural Networks Toolbox.....	80
3.2.4.2.2. Matlab Editor	81
3.2.5. Indicadores de calidad del comportamiento de las redes.....	83
3.3. RESULTADOS Y DISCUSIÓN	84
3.3.1. Cálculos realizados con el Neural Networks Toolbox.....	84
3.3.2. Cálculos realizados con el Matlab Editor	90
3.4. CONCLUSIONES.....	93
CAPÍTULO 4.....	95
4.1. INTRODUCCIÓN.....	99
4.2. MATERIALES Y MÉTODOS.....	99
4.2.1. Obtención de datos climáticos.....	100
4.2.2. Gestión de datos climáticos	100
4.2.3. Obtención de targets y caracterización de estaciones.....	101
4.2.4. Gestión de inputs y modelos considerados.....	103
4.2.5. Propiedades de las redes neuronales utilizadas.....	111
4.2.6. Implementación en Matlab.....	112
4.3. RESULTADOS Y DISCUSIÓN	116
4.3.1. Selección del rango máximo de IC. Selección del modelo y de la alternativa de test óptimos	116
4.3.2. Análisis del modelo óptimo	123
4.4. CONCLUSIONES.....	133
4.5. TRABAJO FUTURO	134
BIBLIOGRAFÍA.....	137
ANEJO A.....	149
A.1. CARACTERIZACIÓN DE UNA RED NEURONAL	153
A.1.1. Nodos o neuronas.....	153
A.1.2. Combinación de señales de entrada a un nodo. Post synaptic potenTial.....	154
A.1.3. Función de activación	155
A.1.4. Patrón de conectividad.....	156
A.1.5. Regla de propagación de las señales a través de la red	156
A.1.6. Regla de entrenamiento	157
A.2. TOPOLOGÍA DE LAS REDES NEURONALES	157
A.3. EL PERCEPTRON FRENTE AL PERCEPTRON MULTICAPA O MULTINIVEL.....	158
A.4. EL PROCESO DE APRENDIZAJE	159
A.4.1. Tipología	159
A.4.2. Error backpropagation learning algorithm.....	161
A.4.2.1. Fundamentos del método.....	161
A.4.2.2. Implementación del EBLA	163
A.4.3. Criterios de parada.	164
A.4.4. Inicialización de pesos.....	164
A.5. ALGORITMOS DE ENTRENAMIENTO AVANZADOS.....	165

A.5.1. Técnica del gradiente conjugado (CGD).....	165
A.5.2. Método Quasi-Newton (QN).....	165
A.5.3. Algoritmo de Levenberg-Marquardt (LM)	166
A.6. MANEJO DEL SISTEMA DE DATOS. CAPACIDAD DE GENERALIZACIÓN DE LA RED	167
ANEJO B.....	169
B.1. SELECCIÓN DE LA ARQUITECTURA ÓPTIMA PARA DIFERENTES COMBINACIONES INPUT-OUTPUT. REPETICIÓN ÓPTIMA.....	173
B.1.1. h_l como output.....	173
B.1.2. α como output.....	175
B.2. SELECCIÓN DE LA ARQUITECTURA ÓPTIMA PARA DIFERENTES COMBINACIONES DE VALIDACIÓN-TEST. REPETICIÓN ÓPTIMA.....	178
B.3. ERRORES ASOCIADOS A LOS PROCESOS ‘LEAVE ONE OUT’	185
B.3.1. Rendimientos desglosados por emisor de test para las combinaciones de verificación NBE, NBH, ABE, BCDE y GBHI. Repetición óptima.....	185
B.3.2. predicciones finales asociadas a las combinaciones de verificación NBH, ABE, BCDE y GBHI. Repetición y arquitectura óptimas.....	188
B.3.3. Errores asociados a las fases de entrenamiento, validación-cruzada y test de cada etapa de los procesos ‘leave one out’. Repetición óptima	192
ANEJO C.....	253
C.1. CÁLCULOS REALIZADOS CON EL <i>NEURAL NETWORKS TOOLBOX</i> DE <i>MATLAB</i>	257
C.1.1. Modelo ANN de 4 inputs	257
C.1.1.1. Indicadores de rendimiento del modelo.	257
C.1.1.2. Predicción del modelo sobre el set de test.	259
C.1.2. Modelo ANN de 7 inputs	261
C.1.2.1. Indicadores de rendimiento del modelo	261
C.1.2.2. Predicción del modelo sobre el set de test	263
C.2. CÁLCULOS REALIZADOS CON <i>MATLAB EDITOR</i>	265
C.2.1. Modelo ANN de 4 inputs	265
C.2.1.1. Selección de arquitectura óptima	265
C.2.1.2. Predicción del modelo ANN de 4 inputs para los sets de test.....	266
C.2.2. Modelo ANN de 7 inputs	268
C.2.2.1. Selección de arquitectura óptima	268
C.2.2.2. Predicción del modelo sobre el set de test	270
ANEJO D.....	273
D.1. ANÁLISIS DE LA COMBINACIÓN DE RANGOS MÁXIMOS DE IC	277
D.2. ERRORES RELATIVOS ABSOLUTOS PROMEDIOS DE TODOS LOS MODELOS, ALTERNATIVAS DE TEST Y COMBINACIONES DE RANGOS DE IC CONSIDERADOS	281
D.2.1. Caso 0	281
D.2.2. Caso 1	282
D.2.3. Caso 2	283
D.2.4. Caso 3	284
D.2.5. Caso 4	285
D.2.6. Caso 5	286
D.3. SELECCIÓN DE ARQUITECTURA ÓPTIMA DE LOS MODELOS DE PREDICCIÓN DE R_s Y HR Y DEL MODELO ANN DE 4 INPUTS	287
D.3.1. Modelo para predicción de R_s en Castalla	287
D.3.2. Modelo para predicción de HR en Castalla.....	287
D.3.3. Modelo para predicción de R_s en Pinoso.....	288
D.3.4. Modelo para predicción de HR en Pinoso.....	288
D.3.5. Modelo de 4 inputs para predicción de ET_o en Altea	289
D.3.6. Modelo de 4 inputs para predicción de ET_o en Onda.....	289
D.3.7. Modelo de 4 inputs para predicción de ET_o en Benavites.....	290
D.4. ÍNDICES DE CALIDAD DEL MODELO ÓPTIMO	290
D.5. ÍNDICES DE CALIDAD DE LOS MODELOS PRELIMINARES DE R_s Y HR CORRESPONDIENTES AL MODELO ÓPTIMO	292

agradecimiento

Antes que nada, deseo dejar constancia desde estas líneas de mi gratitud sincera a todas aquellas personas e instituciones que han contribuido directa o indirectamente, pero siempre de modo decisivo, a la elaboración del trabajo que ahora presento. A todas ellas llevo en mi recuerdo aun sin nominarlas. Debo, no obstante, hacer unas excepciones con determinadas personas porque han tenido una participación muy directa en la gestación de esta tesis.

Al profesor Dr. D. **Álvaro Royuela**, director de la tesis, le transmito mi admiración y agradecimiento, tanto en el ámbito científico y profesional, como en el más personal e íntimo. Durante este tiempo compartido, he podido constatar la diligencia y el interés con que ha ejercido su función de dirigir la investigación aportando ideas, sugiriendo cambios y debatiendo resultados, pero también respetando siempre mis iniciativas, dándome completa autonomía y libertad, prueba de la confianza depositada en mi persona, sin dejar nunca de motivarme a mejorar los contenidos, brindarme su apoyo y animarme a proseguir el trabajo hasta lograr los objetivos fijados.

A D. **Elies Fuster**, también amigo personal, le expreso mi reconocimiento más profundo por su inestimable cooperación y ayuda, ya que es el verdadero responsable de que haya podido afrontar este trabajo de investigación. Por una parte, me introdujo en la disciplina de las *redes neuronales*, y, por otra, me ha prestado una ayuda imprescindible durante todo el proceso para hacer frente a cuestiones teóricas y prácticas inherentes a la aplicación de dichas redes, especialmente al guiarme en el uso y explotación del programa *Matlab*. Y todo ello con su permanente buen humor y su excelente predisposición a ayudar sin condiciones.

A los profesores Dr. D. **Guillermo Palau**, Dr. D. **Juan Manzano**, Dr. D. **Pablo González** y a D. **Luis Sanchis** deseo agradecerles las opiniones vertidas, las sugerencias planteadas y los comentarios críticos formulados, así como la cálida acogida que me han dispensado siempre que les he pedido ayuda y la cortesía con que me han atendido.

Al equipo directivo del **Centro Valenciano de Estudios del Riego** le doy las gracias por haber decidido en su momento apoyar esta iniciativa financiando la beca que me ha permitido poder llevar a término este proyecto.

A **Carola i Ximo** els vull transmetre la meua profunda estima, per obrir-me els ulls i mostrar-me que *sempre tot està per fer i tot és possible*.

A todos les expreso mi gratitud por su impagable apoyo humano e intelectual.

resum

En aquesta tesi, es presenta la aplicació de xarxes neuronals artificials (ANNs) per model·lar dues variables de gran importància en la enginyeria del reg: la evapotranspiració de referència i les pèrdues de càrrega singulars provocades pels emisor integrats. D'una banda, s'ha proposat un model ANN per la predicció de les pèrdues de pressió ocasionades per la inserció d'emissors integrats als lateral de reg localitzat, cosa que no s'ha fet encara amb la ajuda de ANNs. D'altra banda, s'ha analitzat la validesa d'un model ANN existent de 4 inputs per la predicció d' ET_0 en distints contextes continentals de la Comunitat Valenciana i s'ha plantejat un nou model ANN de 6 inputs per millorar el rendiment del anterior.

Per dur a terme els estudis esmentats, s'ha recurrit a l'ús de perceptrons multinivell (MLP) sotmesos a l'algoritme Levenberg-Marquardt. En els tres casos, es varen analitzar xarxes amb múltiples configuracions i es va repetir el procés d'entrenament de cada xarxa un nombre variable de vegades per compensar l'efecte derivat de la assignació inicial aleatòria dels pesos en aquest procés. De la mateixa manera, als tres problemes estudiats es portaren a terme distintes estratègies en la assignació de les dades disponibles als conjunts d'entrenament, validació creuada i test.

A diferència dels models estadístics existents, el model ANN que es proposa per la predicció de pèrdues de càrrega localitzades posseix indicadors de rendiment referits a un set de test independent. Aquest fet ha permés avaluar el potencial real de generalització del model. Per diferents combinacions de validació creuada, amb dades d'almenys tres emissors, es varen obtenir valors mitjans de *performance index* per sobre de 0.85. En quant als models de predicció d' ET_0 , el rendiment del model existent de 4 inputs depèn del grau d'oscil·lació tèrmica del contexte continental on s'utilitza y la seua validesa afora de la seu d'entrenament és molt limitada. El nou model proposat introdueix fonamentalment dues novetats amb l'objectiu de millorar el rendiment del model dins i fora de la seu. Aquestes novetats consisteixen a considerar la humitat relativa i a utilitzar dades climàtiques d'estacions auxiliars secundaries amb índex de continentalitat similars a les estacions de test. D'aquesta manera, es poden obtenir prediccions més exactes que amb el model anterior.

resumen

En esta tesis, se presenta la aplicación de redes neuronales artificiales (ANNs) para modelar dos variables de gran importancia en la ingeniería del riego: la evapotranspiración de referencia y las pérdidas de carga localizadas provocadas por los emisores integrados. Por una parte, se ha propuesto un modelo ANN para la predicción de las pérdidas de presión ocasionadas por la inserción de emisores integrados en los laterales de riego localizado, lo que nunca se ha llevado a cabo mediante redes neuronales. Por otro lado, se ha analizado la validez de un modelo ANN de 4 inputs existente para predicción de ET_0 en distintos contextos continentales de la Comunidad Valenciana y se ha planteado un nuevo modelo ANN de 6 inputs para mejorar el rendimiento del anterior.

Para llevar a cabo dichos estudios, se ha recurrido al uso de perceptrones multinivel (MLP) sometidos al algoritmo Levenberg Marquardt. En los tres casos, se analizaron redes con múltiples configuraciones y se repitió el proceso de entrenamiento de cada red un número variable de veces para compensar el efecto derivado de la asignación inicial aleatoria de pesos en dicho proceso. Asimismo, en los tres problemas abordados se llevaron a cabo distintas estrategias en la asignación de los datos disponibles a los conjuntos de entrenamiento, validación cruzada y test.

A diferencia de los modelos estadísticos existentes, el modelo ANN propuesto para predicción de pérdidas de carga localizadas posee indicadores de rendimiento referidos a un set de test independiente, lo que ha permitido evaluar su potencial real de generalización. Para diferentes combinaciones de validación cruzada, con datos al menos de tres emisores, se obtuvieron valores medios del *performance index* por encima de 0.85. En cuanto a los modelos de predicción de ET_0 , el rendimiento del modelo existente de 4 inputs depende del grado de oscilación térmica del contexto continental en que se utilice y su validez fuera de la sede de entrenamiento es muy limitada. El nuevo modelo que se propone introduce fundamentalmente dos novedades con el objetivo de mejorar el rendimiento del modelo dentro y fuera de la sede. Dichas novedades consisten en considerar la humedad relativa y en utilizar datos climáticos de estaciones auxiliares secundarias con índices de continentalidad semejantes a las estaciones de test. De esta manera, se logran predicciones más exactas que con el modelo anterior.

abstract

This thesis presents the application of artificial neural networks (ANNs) for the estimation of two relevant variables of irrigation engineering: reference evapotranspiration and integrated emitter local losses. On the one hand, one ANN model has been proposed for prediction of pressure losses due to emitter insertions in lateral lines. No previous research has mapped the capability of ANNs to estimate local pressure losses in microirrigation laterals. On the other hand, the applicability of a 4-input ANN model for ET_o prediction has been studied in different continental contexts of the Valencia region. Furthermore, a new ANN model for ET_o prediction has been proposed to improve the performance quality of the predictions.

For these purposes, multilayer feedforward networks with backpropagation, commonly known as multilayer perceptrons, were used under the supervision of the Levenberg-Marquardt algorithm. In all cases, several ANN configurations were proposed and tested. Moreover, the process was repeated several times to mind the effect derived from the random assignment of the synaptic weights when the training algorithm is initialized. On the other hand, different strategies were followed to define the matrices for training, cross-validating and testing.

In comparison to traditional regression models, the performance quality of the proposed ANN model for integrated emitter local loss prediction is referred to an independent test set. This fact allows to evaluate the real generalization potential of the model. For different cross-validation combinations, with data sets from at least three emitters, *performance indexes* over 0.85 were obtained. In relationship to ET_o prediction models, the performance of the 4-input ANN model depends on the thermic oscillation range of the location where the model is created and the validity of the model outside the training location is limited. The new ANN model introduces in general two novelties to improve the performance quality in the training location and outside. These ones are the consideration of relative humidity and the importation of climatic data from secondary ancillary weather stations which are similar from a continental point of view to the test location. This way, more accurate ET_o predictions can be obtained.

índice de figuras

CAPÍTULO 1

Figura 1.1. Esquema general de una neurona biológica (Isasi-Viñuela y Galván-León, 2004)	9
Figura 1.2. Esquema de transmisión de información entre neuronas (Delgado, 2007)	10
Figura 1.3. Esquema de una red neuronal artificial feed-forward con conectividad total	11
Figura 1.4. Esquema de funcionamiento de un proceso de aprendizaje supervisado	12
Figura 1.5. Esquema de un lateral con un emisor no integrado sobre línea y un lateral con un emisor integrado en línea (Juana et al., 2002a)	17
Figura 1.6. Esquema del proceso de pérdida de agua desde los estomas (Allen et al., 1998)	24

CAPÍTULO 2

Figura 2.1. Esquema del montaje utilizado para la toma de medidas experimentales	36
Figura 2.2. Coeficientes de resistencia α de los emisores para cada condición experimental	40
Figura 2.3. Esquema de procesado de las señales entre neuronas	45
Figura 2.4. Esquema resumen de los procesos implementados en <i>Matlab</i> para el estudio de h_l	51
Figura 2.5. Esquema de funcionamiento del programa implementado para generar el modelo ANN final	52
Figura 2.6. Modelo ANN de 2 inputs vs modelo de regresión (Provenzano et al., 2005)	57
Figura 2.7. Modelo ANN de 4 inputs vs modelo de regresión (Provenzano et al., 2005)	57
Figura 2.8. Predicción de h_l en emisores con rangos de α altos, obtenidos con trío de verificación NBE	65
Figura 2.9. Predicción de h_l en emisores con rangos de α bajos, obtenidos con trío de verificación NBE	65

CAPÍTULO 3

Figura 3.1. Situación geográfica de las estaciones estudiadas	74
Figura 3.2. Pasos generales seguidos en la implementación del programa con <i>Matlab Editor</i>	83
Figura 3.3. ET_o PM vs ET_o ANN 4 inputs testados en Altea y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	89
Figura 3.4. ET_o PM vs ET_o ANN 7 inputs testados en Altea y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	89
Figura 3.5. Error cuadrático vs n^o de neuronas para los conjuntos de entrenamiento, validación cruzada y test. Altea	90

CAPÍTULO 4

Figura 4.1. Situación geográfica de las estaciones climáticas utilizadas en el estudio	101
Figura 4.2. Esquema de la generación del modelo para predicción de ET_o particularizado para la alternativa 3. Paso 1: creación del modelo preliminar de R_s	106
Figura 4.3. Esquema de la generación del modelo para predicción de ET_o particularizado para la alternativa 3. Paso 2: creación del modelo preliminar de HR	107
Figura 4.4. Esquema de la generación del modelo para predicción de ET_o particularizado para la alternativa 3. Paso 3: creación del modelo de ET_o	107
Figura 4.5. Esquema del proceso de simulación del modelo ANN para predicción de ET_o en una estación de test con una única estación auxiliar	108
Figura 4.6. Correspondencia entre sedes para selección de modelos preliminares	111
Figura 4.7. Proceso de selección de la sede óptima para cada categoría de estación	115
Figura 4.8. Esquema de los procesos implementados en <i>Matlab</i> para generar el modelo ANN de 6 inputs 1/2	117

Figura 4.9. Esquema de los procesos implementados en <i>Matlab</i> para generar el modelo ANN de 6 inputs 2/2	119
Figura 4.10. Número de neuronas vs AARE para los sets de entrenamiento, verificación y test en Altea	125
Figura 4.11. Número de neuronas vs AARE para los sets de entrenamiento, verificación y test en Denia	126
Figura 4.12. Máxima variación del MSE vs número de neuronas consideradas	127
Figura 4.13. Código de estación de test vs AARE para modelos ANN de 4 y 6 inputs y ecuación de Hargreaves. Estaciones costeras	128
Figura 4.14. Código de estación de test vs AARE para modelos ANN de 4 y 6 inputs y ecuación de Hargreaves. Estaciones intermedias	128
Figura 4.15. Código de estación de test vs AARE para modelos ANN de 4 y 6 inputs y ecuación de Hargreaves. Estaciones interiores	129
Figura 4.16. ET_o PM vs ET_o ANN en Borriana (estación 1-8, IC=0.479)	131
Figura 4.17. ET_o PM vs ET_o ANN en Carcaixent (estación 2-13, IC=4.303)	132
Figura 4.18. ET_o PM vs ET_o ANN en Requena-Cerrito (estación 3-14, IC=14.925)	132
 ANEJO A	
Figura A.1. Correspondencia entre modelos biológico y artificial (Delgado, 2007)	156
Figura A.2. Ejemplo de entrenamiento con early stopping (Fiszelew y García, 2008)	168
Figura A.3. Ejemplo de sobreajuste de puntos (Castillo et al., 1999)	168
 ANEJO B	
Figura B.1. Predicción de h_i en emisores con rangos de α altos, obtenidos con trío de verificación NBH	188
Figura B.2. Predicción de h_i en emisores con rangos de α bajos, obtenidos con trío de verificación NBH	189
Figura B.3. Predicción de h_i en emisores con rangos de α altos, obtenidos con trío de verificación ABE	189
Figura B.4. Predicción de h_i en emisores con rangos de α bajos, obtenidos con trío de verificación ABE	190
Figura B.5. Predicción de h_i en emisores con rangos de α altos, obtenidos con trío de verificación BCDE	190
Figura B.6. Predicción de h_i en emisores con rangos de α bajos, obtenidos con trío de verificación BCDE	191
Figura B.7. Predicción de h_i en emisores con rangos de α altos, obtenidos con trío de verificación GBHI	191
Figura B.8. Predicción de h_i en emisores con rangos de α bajos, obtenidos con trío de verificación GBHI	192
 ANEJO C	
Figura C.1. ET_o PM vs ET_o ANN 4 inputs testados en Benavites y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	259
Figura C.2. ET_o PM vs ET_o ANN 4 inputs testados en Campo Arcís y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	259
Figura C.3. ET_o PM vs ET_o ANN 4 inputs testados en Castalla y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	260
Figura C.4. ET_o PM vs ET_o ANN 7 inputs testados en Benavites y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	263
Figura C.5. ET_o PM vs ET_o ANN 7 inputs testados en Campo Arcís y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	263
Figura C.6. ET_o PM vs ET_o ANN 7 inputs testados en Castalla y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	264
Figura C.7. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Benavites	265
Figura C.8. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Campo Arcís	265
Figura C.9. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Castalla	266

Figura C.10. ET_o PM vs ET_o ANN 4 inputs testados en Altea y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	266
Figura C.11. ET_o PM vs ET_o ANN 4 inputs testados en Benavites y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	267
Figura C.12. ET_o PM vs ET_o ANN 4 inputs testados en Campo Arcís y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	267
Figura C.13. ET_o PM vs ET_o ANN 4 inputs testados en Castalla y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	268
Figura C.14. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Altea	268
Figura C.15. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Benavites	269
Figura C.16. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Campo Arcís	269
Figura C.17. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Castalla	270
Figura C.18. ET_o PM vs ET_o ANN 7 inputs testados en Altea y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	270
Figura C.19. ET_o PM vs ET_o ANN 7 inputs testados en Benavites y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	271
Figura C.20. ET_o PM vs ET_o ANN 7 inputs testados en campo Arcís y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	271
Figura C.21. ET_o PM vs ET_o ANN 7 inputs testados en Castalla y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)	272

ANEJO D

Figura D.1. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo R_s en Castalla	287
Figura D.2. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo HR en Castalla	287
Figura D.3. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo R_s en Pinoso	288
Figura D.4. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo HR en Pinoso	288
Figura D.5. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo ANN de 4 inputs en Altea	289
Figura D.6. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo ANN de 4 inputs en Onda	289
Figura D.7. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo ANN de 4 inputs en Benavites	290

índice de tablas

CAPÍTULO 2

Tabla 2.1. Caracterización de los emisores ensayados	39
Tabla 2.2. Combinaciones de inputs consideradas	41
Tabla 2.3. Fase de tanteo de estrategias de entrenamiento y test	43
Tabla 2.4. Arquitecturas estudiadas para cada combinación de variables input	48
Tabla 2.5. Parámetros elegidos para el proceso de entrenamiento	49
Tabla 2.6. Indicadores de rendimiento de los modelos óptimos obtenidos con el entrenamiento 1	54
Tabla 2.7. Indicadores de rendimiento de los modelos óptimos obtenidos	56
Tabla 2.8. Índices de rendimiento de arquitecturas óptimas obtenidos bajo los entrenamientos 2-22	59
Tabla 2.9. Indicadores de rendimiento medios de cada proceso 'leave one out'	62

CAPÍTULO 3

Tabla 3.1. Datos geográficos de las estaciones climáticas	73
Tabla 3.2. Variables consideradas en los modelos ANN estudiados	75
Tabla 3.3. Arquitecturas de 4 inputs analizadas con <i>Neural Network Toolbox</i>	81
Tabla 3.4. Arquitecturas analizadas con <i>Matlab Editor</i>	81
Tabla 3.5. Caracterización de arquitecturas óptimas. MSE en (mm/día) ²	85
Tabla 3.6. Indicadores estadísticos de la predicción obtenida mediante el modelo de Hargreaves para el año 2007. Índice de continentalidad propuesto calculado para 2007 en las estaciones estudiadas	87
Tabla 3.7. Índices de rendimiento de las arquitecturas óptimas de 4 y 7 inputs para los sets de test, obtenidos con el <i>Matlab Editor</i> . MSE en (mm/día) ²	91

CAPÍTULO 4

Tabla 4.1. Caracterización de las estaciones climáticas de estudio	102
Tabla 4.2. Resumen de variables consideradas en los distintos modelos para predicción de radiación solar, humedad relativa y evapotranspiración de referencia	104
Tabla 4.3. Alternativas de test consideradas	110
Tabla 4.4. Selección de máximos rangos admisibles de IC para cálculo de inputs medios exógenos	116
Tabla 4.5. Valores medios de estaciones auxiliares por tipo de estación de test	118
Tabla 4.6. Resultados óptimos medios por categoría de estación de test y rango IC para caso 0	120
Tabla 4.7. Resultados óptimos medios por categoría de estación de test y rango IC para caso 1	120
Tabla 4.8. Resultados óptimos medios por categoría de estación de test y rango IC para caso 2	121
Tabla 4.9. Resultados óptimos medios por categoría de estación de test y rango IC para caso 3	121
Tabla 4.10. Resultados óptimos medios por categoría de estación de test y rango IC para caso 4	122
Tabla 4.11. Resultados óptimos medios por categoría de estación de test y rango IC para caso 5	122
Tabla 4.12. Índices medios de rendimiento del caso 3 con la combinación 3 de rango IC	124

ANEJO B

Tabla B.1. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e y D_t y el output h_l	173
Tabla B.2. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t y L_e y el output h_l	173
Tabla B.3. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y Re_t y el output h_l	173
Tabla B.4. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y Q_t y el output h_l	174
Tabla B.5. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , S_e y Q_t y el output h_l	174
Tabla B.6. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y S_e y output h_l	174
Tabla B.7. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e , S_e y Q_t y el output h_l	175
Tabla B.8. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e , S_e y Re_t y el output h_l	175
Tabla B.9. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e y D_t y el output α	175
Tabla B.10. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t y L_e y el output α	176
Tabla B.11. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y Re_t y el output α	176
Tabla B.12. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y Q_t y el output α	176
Tabla B.13. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , S_e y Q_t y el output α	177
Tabla B.14. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y S_e y el output α	177
Tabla B.15. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e , S_e y Q_t y el output α	177
Tabla B.16. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e , S_e y Re_t y el output α	178
Tabla B.17. Errores de entrenamiento y test de una red con el entrenamiento 2	178
Tabla B.18. Errores de entrenamiento y test de una red con el entrenamiento 3	178
Tabla B.19. Errores de entrenamiento y test de una red con el entrenamiento 4	179
Tabla B.20. Errores de entrenamiento y test de una red con el entrenamiento 5	179
Tabla B.21. Errores de entrenamiento y test de una red con el entrenamiento 6	179
Tabla B.22. Errores de entrenamiento y test de una red con el entrenamiento 7	180
Tabla B.23. Errores de entrenamiento y test de una red con el entrenamiento 8	180
Tabla B.24. Errores de entrenamiento y test de una red con el entrenamiento 9	180
Tabla B.25. Errores de entrenamiento y test de una red con el entrenamiento 10	181
Tabla B.26. Errores de entrenamiento y test de una red con el entrenamiento 11	181
Tabla B.27. Errores de entrenamiento y test de una red con el entrenamiento 12	181
Tabla B.28. Errores de entrenamiento y test de una red con el entrenamiento 13	182
Tabla B.29. Errores de entrenamiento y test de una red con el entrenamiento 14	182
Tabla B.30. Errores de entrenamiento y test de una red con el entrenamiento 15	182

Tabla B.31. Errores de entrenamiento y test de una red con el entrenamiento 16	183
Tabla B.32. Errores de entrenamiento y test para de una red con el entrenamiento 17	183
Tabla B.33. Errores de entrenamiento y test de una red con el entrenamiento 18	183
Tabla B.34. Errores de entrenamiento y test de una red con el entrenamiento 19	184
Tabla B.35. Errores de entrenamiento y test para de una red con el entrenamiento 20	184
Tabla B.36. Errores de entrenamiento y test de una red con el entrenamiento 21	184
Tabla B.37. Errores de entrenamiento y test de una red con el entrenamiento 22	185
Tabla B.38. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación NBH	185
Tabla B.39. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación ABE	186
Tabla B.40. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación NBE	186
Tabla B.41. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación BCDE	187
Tabla B.42. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación GBHI	188
Tabla B.43. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con A	192
Tabla B.44. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con C	193
Tabla B.45. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con D	193
Tabla B.46. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con F	194
Tabla B.47. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con G	194
Tabla B.48. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con H	195
Tabla B.49. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con I	195
Tabla B.50. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con L	196
Tabla B.51. Errores de entrenamiento y test para de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con M	196
Tabla B.52. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con O	197
Tabla B.53. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con P	197
Tabla B.54. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con Q	198
Tabla B.55. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con A	198
Tabla B.56. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con C	199
Tabla B.57. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con D	199

Tabla B.58. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con F	200
Tabla B.59. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con G	200
Tabla B.60. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con H	201
Tabla B.61. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con I	201
Tabla B.62. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con L	202
Tabla B.63. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con M	202
Tabla B.64. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con O	203
Tabla B.65. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con P	203
Tabla B.66. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con A	204
Tabla B.67. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con C	204
Tabla B.68. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con D	205
Tabla B.69. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con E	205
Tabla B.70. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con F	206
Tabla B.71. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con G	206
Tabla B.72. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con I	207
Tabla B.73. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con L	207
Tabla B.74. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con M	208
Tabla B.75. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con O	208
Tabla B.76. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con P	209
Tabla B.77. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBH y test con Q	209
Tabla B.78. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con A	210
Tabla B.79. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con C	210
Tabla B.80. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con D	211
Tabla B.81. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con E	211
Tabla B.82. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con F	212

Tabla B.83. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con G	212
Tabla B.84. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con I	213
Tabla B.85. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con L	213
Tabla B.86. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con M	214
Tabla B.87. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con O	214
Tabla B.88. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con P	215
Tabla B.89. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con C	215
Tabla B.90. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con D	216
Tabla B.91. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con F	216
Tabla B.92. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con G	217
Tabla B.93. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con H	217
Tabla B.94. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con I	218
Tabla B.95. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con L	218
Tabla B.96. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con M	219
Tabla B.97. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con N	219
Tabla B.98. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con O	220
Tabla B.99. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con P	220
Tabla B.100. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con Q	221
Tabla B.101. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con C	221
Tabla B.102. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con D	222
Tabla B.103. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con F	222
Tabla B.104. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con G	223
Tabla B.105. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con H	223
Tabla B.106. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con I	224
Tabla B.107. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con L	224

Tabla B.108. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con M	225
Tabla B.109. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con N	225
Tabla B.110. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con O	226
Tabla B.111. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con P	226
Tabla B.112. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con A	227
Tabla B.113. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con F	227
Tabla B.114. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con G	228
Tabla B.115. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con H	228
Tabla B.116. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con I	229
Tabla B.117. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con L	229
Tabla B.118. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con M	230
Tabla B.119. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con N	230
Tabla B.120. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con O	231
Tabla B. 121. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con P	231
Tabla B.122. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con Q	232
Tabla B.123. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con A	232
Tabla B.124. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con F	233
Tabla B.125. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con H	233
Tabla B.126. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con I	234
Tabla B.127. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con L	234
Tabla B.128. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con M	235
Tabla B.129. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con N	235
Tabla B.130. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con O	236
Tabla B.131. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con P	236
Tabla B.132. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con Q	237

Tabla B.133. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con A	237
Tabla B.134. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con F	238
Tabla B.135. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con H	238
Tabla B.136. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con I	239
Tabla B.137. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con L	239
Tabla B.138. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con M	240
Tabla B.139. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con N	240
Tabla B.140. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con O	241
Tabla B.141. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con P	241
Tabla B.142. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con A	242
Tabla B.143. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con C	242
Tabla B.144. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con D	243
Tabla B.145. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con E	243
Tabla B.146. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con F	244
Tabla B.147. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con L	244
Tabla B.148. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con M	245
Tabla B.149. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con N	245
Tabla B.150. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con O	246
Tabla B.151. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con P	246
Tabla B.152. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con Q	247
Tabla B.153. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con A	247
Tabla B.154. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con C	248
Tabla B.155. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con D	248
Tabla B.156. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con E	249
Tabla B.157. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con F	249

Tabla B.158. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con L	250
Tabla B.159. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con M	250
Tabla B.160. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con N	251
Tabla B.161. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con O	251
Tabla B.162. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con P	252

ANEJO C

Tabla C.1. Errores cuadráticos medios obtenidos con el modelo ANN de 4 inputs en las fases de entrenamiento y test	257
Tabla C.2. <i>Performance index</i> obtenidos con el modelo ANN de 4 inputs en las fases de entrenamiento y test	258
Tabla C.3. Errores cuadráticos medios obtenidos con el modelo ANN de 7 inputs en las fases de entrenamiento y test	261
Tabla C.4. <i>Performance index</i> obtenidos con el modelo ANN de 7 inputs en las fases de entrenamiento y test	262

ANEJO D

Tabla D.1. Estaciones exógenas auxiliares por estación costera de test	277
Tabla D.2. Estaciones exógenas auxiliares por estación intermedia de test 1/2	278
Tabla D.3. Estaciones exógenas auxiliares por estación intermedia de test 2/2	279
Tabla D.4. Estaciones exógenas auxiliares por estación interior de test 1/2	279
Tabla D.5. Estaciones exógenas auxiliares por estación interior de test 2/2	280
Tabla D.6. Indicadores del modelo 0 con la combinación 1 de rangos de IC	281
Tabla D.7. Indicadores del modelo 0 con la combinación 2 de rangos de IC	281
Tabla D.8. Indicadores del modelo 0 con la combinación 3 de rangos de IC	281
Tabla D.9. Indicadores del modelo 1 con la combinación 1 de rangos de IC	282
Tabla D.10. Indicadores del modelo 1 con la combinación 2 de rangos de IC	282
Tabla D.11. Indicadores del modelo 1 con la combinación 3 de rangos de IC	282
Tabla D.12. Indicadores del modelo 2 con la combinación 1 de rangos de IC	283
Tabla D.13. Indicadores del modelo 2 con la combinación 2 de rangos de IC	283
Tabla D.14. Indicadores del modelo 2 con la combinación 3 de rangos de IC	283
Tabla D.15. Indicadores del modelo 3 con la combinación 1 de rangos de IC	284
Tabla D.16. Indicadores del modelo 3 con la combinación 2 de rangos de IC	284
Tabla D.17. Indicadores del modelo 3 con combinación 3 de rangos de IC	284
Tabla D.18. Indicadores del modelo 4 con la combinación 1 de rangos de IC	285
Tabla D.19. Indicadores del modelo 4 con la combinación 2 de rangos de IC	285
Tabla D.20. Indicadores del modelo 4 con la combinación 3 de rangos de IC	285
Tabla D.21. Indicadores del modelo 5 con la combinación 1 de rangos de IC	286
Tabla D.22. Indicadores del modelo 5 con la combinación 2 de rangos de IC	286
Tabla D.23. Indicadores del modelo 5 con la combinación 3 de rangos de IC	286

Tabla D.24. Índices de calidad del modelo óptimo y de los modelos ANN de 4 inputs y Hargreaves en estaciones de test costeras	290
Tabla D.25. Índices de calidad del modelo óptimo y de los modelos ANN de 4 inputs y Hargreaves en estaciones de test intermedias	291
Tabla D.26. Índices de calidad del modelo óptimo y de los modelos ANN de 4 inputs y Hargreaves en estaciones de test interiores	291
Tabla D.27. Desglose de los índices de calidad de los modelos R_s y HR en estaciones costeras. Sede de entrenamiento: Castalla	292
Tabla D.28. Desglose de los índices de calidad de los modelos R_s y HR en estaciones intermedias. Sede de entrenamiento: Pinoso	292
Tabla D.29. Desglose de los índices de calidad de los modelos R_s y HR en estaciones interiores. Sede de entrenamiento: Pinoso	293

lista de variables

- a** : operador para determinación ET_o
 a_s : constante de regresión para determinación de R_s
 $AARE$: error relativo absoluto promedio
 b : operador para determinación ET_o
 b_k : bias o umbral
 b_s : constante de regresión para determinación de R_s
 C : *performance index*
 c : operador para determinación ET_o
 C_c : coeficiente de contracción
 C_f : coeficiente fórmula f
 CV_m : coeficiente de variación de fabricación
 d : coeficiente de ajuste de Willmott
 d_m : mínima distancia al mar
 d_r : distancia inversa relativa tierra-sol
 D_e : diámetro interior del emisor
 D_t : diámetro interior de la tubería
 e : nº de repeticiones de cada proceso de entrenamiento
 e_a : presión de vapour real
 e_s : presión de vapor de saturación para un periodo dado
 $e_s - e_a$: déficit de presión de vapor del aire
 e^o : presión de vapor de saturación para una temperatura dada
 ET : evapotranspiración
 ET_c : evapotranspiración del cultivo
 ET_o : evapotranspiración de referencia
 ET_o^H : evapotranspiración de referencia calculada con la ecuación de Hargreaves
 ET_o^{PM} : evapotranspiración de referencia calculada con la ecuación de Penman-Monteith
 f : factor de fricción
 g : aceleración de la gravedad
 g : gradiente
 G : flujo de calor del suelo
 G_{sc} : constante solar
 H : matriz messiana o hessiano
 h_l : pérdidas de carga localizadas debidas a la inserción del emisor
 $h_l(\alpha)$: pérdidas de carga localizadas calculadas a partir del coeficiente de resistencia
 h_r : pérdidas de carga por rozamiento
 ΔH_s : pérdidas de carga por rozamiento en la separación entre emisores
 HR : humedad relativa
 I : matriz identidad
 IC : índice de continentalidad
 j : gradiente de pérdidas de carga
 J : día del año
 J : matriz jacobiana o jacobiano
 k, K : coeficiente de resistencia

k_c : coeficiente de cultivo
 l : valor de entrada de la función tansig
 L : longitud de la tubería
 L_e : longitud del emisor
 MSE : error cuadrático medio
 n : nº de neuronas ocultas
 n_d : número de días considerado
 n_e : número de emisores
 N : número de horas diarias de sol teóricas
 N : número de horas diarias de sol medidas
 P : presión atmosférica
 $PI-P5$: puntos de medida de presión
 q_n : caudal nominal del emisor
 Q_t : caudal circulante por la tubería
 Q_m : caudal medio emitido por los goteros
 Q_{mLQ} : caudal medio del cuarto más bajo
 r : coeficiente de correlación
 R_a : radiación extraterrestre
 Re : número de Reynolds
 Re_t : número de Reynolds de la tubería
 R_n : radiación solar neta
 R_{nl} : radiación solar neta de onda larga
 R_{ns} : radiación solar neta de onda corta
 R_s : radiación solar
 R_{so} : radiación solar de onda corta con cielo raso
 r_{te} : relación entre la sección de la tubería con el emisor y sin éste
 S : sección de la conexión del emisor
 S : sección de la tubería sin emisor
 S_e : distancia entre emisores
 T : temperatura media diaria
 t_j : valor radiación solar de onda corta con cielo raso deseado
 T_{max} : temperatura máxima diaria
 T_{min} : temperatura mínima diaria
 UE : uniformidad de emisión
 u_2 : velocidad del viento medida a dos metros de altura
 V : velocidad media en la tubería
 v_k : combinación lineal de señales
 w_{kj} : peso sináptico de la neurona k
 w_s : ángulo solar del ocaso
 x : nº de inputs
 x_i x_j x_k : señal input
 y_e : vector esperado
 y_k : valor de salida de la neurona
 y_m : vector estimado
 α : coeficiente de resistencia
 β : albedo

Δ : pendiente de la curva que relaciona presión de vapor de saturación y temperatura
 δ : declinación solar
 δ_j : error de cada nodo de salida
 γ : constante psicrométrica
 η : tasa de aprendizaje
 φ : función sigmoïdal tangente hiperbólica
 ϕ : *momentum*
 μ : constante que gobierna el tamaño de cada paso hacia el mínimo
initial μ : valor inicial asignado para μ en la fórmula de Levenberg-Marquardt
maximum μ : valor de μ por encima del cual el algoritmo LM se detiene
 μ decrease factor: factor reductor de μ en cada paso del algoritmo LM
 μ increase factor: factor incrementador de μ en cada paso del algoritmo LM
 π : número Pi
 σ : constante de Stefan-Boltzmann
 σ_e : desviación estándar esperada
 σ_j : valor calculado
 σ_m : desviación estándar estimada
 τ : latitud
 θ : contenido de agua en el suelo
 ν : viscosidad cinemática del agua

lista de acrónimos

- AARE***: Average Absolute Relative Error
- AI***: Average Index
- ANN***: Artificial Neural Network (plural ANNs)
- ASAE***: American Society of Agricultural Engineers
- ASCE***: American Society of Civil Engineers
- BFGS***: Broydon Fletcher Goldfab Sahnno
- CFD***: Computational Fluid Dynamics
- CGD***: Conjugate Gradient Descent
- CVER***: Centro Valenciano de Estudios del Riego
- DN***: Diámetro Nominal
- DPV***: Déficit de Presión de Vapor
- EBLA***: Error Back Propagation Learning Algorithm
- EBPN***: Error Back Propagation Network
- ET***: Evapotranspiración
- FAO***: Food and Agriculture Organization of the United Nations
- GUI***: Graphical User Interface
- IEEE***: Institute of Electrical and Electronics Engineers
- IVIA***: Instituto Valenciano de Investigaciones Agrarias
- LM***: Levenberg Marquardt
- MAE***: Mean Absolute Error
- MIT***: Massachusetts Institute of Technology
- MLP***: Multi Layer Perceptron
- MSE***: Mean Squared Error
- PM***: Penman Monteith
- PM-FAO***: Penman Monteith-FAO
- PSP***: Post Synaptic Potential
- QN***: Quasi Newton
- RBF***: Radial Basis Function
- SIG***: Sistemas de Información Geográfica
- UE***: Uniformidad de Emisión

publicaciones y ponencias extraídas de la tesis

Se desea citar las contribuciones en forma de ponencias y artículos a que ha dado lugar la tesis. Por otra parte, aun sin estar aceptadas las publicaciones, se recibió una invitación para actuar como revisor externo en el *Journal of Irrigation and Drainage Engineering*, concretamente para evaluar la calidad del *paper* “Infilling daily evapotranspiration data using artificial neural networks”.

CONGRESOS

Ponencias presentadas en congresos extraídas de la tesis

nombre del congreso	título de la ponencia	lugar y fecha
<i>2nd International Conference on Sustainable Irrigation: Management, Technologies and Policies</i>	“Applicability of a 4-inputs ANN model for ET_0 prediction in coastal and inland locations.”	Alicante, junio 2008
<i>8th international conference on Hybrid Intelligent Systems</i>	“Improvement of temperature-based ANN models for ET_0 prediction in coastal locations by means of preliminary models and exogenous data.”	Barcelona, septiembre 2008 *

* paper sometido a la revisión de tres referees externos

ARTÍCULOS EN REVISTAS

Artículos enviados a revistas

nombre de la revista	título del texto	estado
<i>Journal of Irrigation and Drainage Engineering</i>	“Discussion of ‘Estimating Evapotranspiration Using Artificial Neural Networks and Minimum Climatological Data’.”	aceptado
<i>Journal of Irrigation and Drainage Engineering</i>	“Integrated emitter local loss prediction using artificial neural networks.”	en proceso de revisión
<i>Journal of Irrigation and Drainage Engineering</i>	“Generalization of ET_0 ANN models through data supplanting.”	en proceso de revisión

capítulo 1

introducción y objetivos

1.1. MOTIVACIÓN	5
1.2. REDES NEURONALES	8
1.2.1. INTRODUCCIÓN	8
1.2.2. FUNDAMENTOS BIOLÓGICOS DE LAS REDES NEURONALES	9
1.2.3. DEFINICIÓN Y PROPIEDADES	11
1.2.4. EVOLUCIÓN HISTÓRICA DE LAS REDES NEURONALES ARTIFICIALES	13
1.2.5. APLICACIONES	15
1.3. INTRODUCCIÓN A LOS PROBLEMAS ABORDADOS.....	17
1.3.1. ESTUDIO DE PÉRDIDAS DE CARGA LOCALIZADAS EN EMISORES INTEGRADOS	17
1.3.2. ESTUDIO DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA.....	23
1.4. OBJETIVOS	28
1.4.1. OBJETIVOS GENERALES.....	28
1.4.2. OBJETIVOS PARTICULARES.....	29
1.4.2.1. <i>Estudio de pérdidas de carga singulares.....</i>	<i>29</i>
1.4.2.2. <i>Estudio de la evapotranspiración de referencia.....</i>	<i>29</i>
1.5. ESTRUCTURA DEL CONTENIDO	30

1.1. Motivación

Durante la realización de los cursos de doctorado tuve conocimiento, por primera vez, de la existencia de las redes neuronales a través de un compañero del departamento de física aplicada, que ya las aplicaba con éxito en el campo de la acústica. En un principio, ni se me pasó por la cabeza la posibilidad de que yo pudiera acabar aplicando aquella caja negra misteriosa a problemas de nuestra especialidad. Sin embargo, una primera toma de contacto con la bibliografía existente, desveló que ya habían sido utilizadas con éxito para modelar evapotranspiración de referencia, ET_0 (Kumar et al., 2002; Sudheer et al., 2003). No obstante, los casos de aplicación de redes neuronales a fenómenos del ámbito agrícola eran exiguos y, más aún, en el contexto de la ingeniería del riego.

A pesar de ello y gracias a la inestimable ayuda de este colega, pude iniciar mi andadura en esta disciplina tan amplia y compleja, que exigía, por otra parte, la utilización de un software adecuado para su aplicación a problemas concretos. Este hecho, junto con la buena predisposición que mostró el profesor Giuseppe Provenzano, de la Universidad de Palermo, para establecer una colaboración con nuestro departamento poniendo a nuestra disposición sus datos experimentales sobre pérdidas de carga localizadas en emisores integrados, originaron la puesta en marcha de la presente investigación en torno a la aplicación de redes neuronales para estimar dichas pérdidas.

Dicho estudio se planteó como una toma de contacto con las redes neuronales, así como con los rudimentos básicos que permiten aplicar redes neuronales a un problema concreto mediante un software, *Matlab* en nuestro caso. Así, lejos de estar en condiciones de programar las funciones específicas de este programa correspondientes a redes neuronales, se comenzaron a manejar distintos conceptos teóricos mediante el *graphical user interface* (GUI) que ofrece este programa, el *Neural Networks Toolbox*. El mayor inconveniente y, al mismo tiempo, el mayor estímulo de esta etapa fue la ausencia de precedentes en este campo. Así pues, resultó un periodo enriquecedor de aprendizaje.

El interés por el estudio de la ET_0 se remonta a 2005, cuando se inició una labor de dos años de duración en el seno del Centro Valenciano de Estudios del Riego (CVER).

Durante este tiempo, se llevaron a cabo sendos estudios sobre las necesidades hídricas de los cultivos en las comarcas del Alto y Medio Vinalopó, en el marco de dos contratos de investigación firmados con la Confederación Hidrográfica del Júcar, Aguas del Júcar y la Junta Central de Usuarios del Vinalopó, l'Alacantí y la Marina. La tarea de cálculo de las necesidades de riego teóricas según las directrices del manual 56 de la FAO (Allen et al., 1998) puso pronto de manifiesto dos aspectos limitantes de dicha metodología: la necesidad de disponer de gran cantidad de variables climáticas, así como la restricción de la aplicabilidad de las predicciones obtenidas sólo para el microclima del que se extraían dichas medidas. Este hecho supeditaba la calidad de las predicciones, entre otras cosas, a la disponibilidad de una buena red de estaciones meteorológicas en la zona de estudio, capaces de suministrar todas las variables que demandaba la aplicación de la ecuación de Penman-Monteith, así como un buen mantenimiento de las mismas.

El final de dichos estudios coincidió con la aparición de un trabajo (Zanetti et al., 2007) donde se analizaba la aplicación de redes neuronales para aproximar valores de evapotranspiración de referencia de Penman Monteith a partir sólo de medidas de las temperaturas máxima y mínima y de estimaciones de radiación extraterrestre y número de horas diarias de luz (calculadas independientemente en función del día del año y la latitud de la estación de test). Pese a las limitaciones de los resultados, éste fue el detonante que suscitó el interés por el estudio de ET_o con redes neuronales, dada la originalidad y potencialidad de dicha aplicación. De esta manera, una vez finalizado el estudio de las pérdidas de cargas, con resultados muy satisfactorios, se optó por cambiar el ámbito de aplicación de las redes neuronales seguido hasta el momento.

En primer lugar, se adoptó una línea continuista y se estudió la validez del modelo de predicción de ET_o (Zanetti et al., 2007) en la zona de la Comunidad Valenciana con el objetivo de analizar detalladamente la idea propuesta, así como las propiedades de las redes utilizadas por los autores de esta investigación. Sin embargo, lejos de servir sólo de contacto con este nuevo campo de aplicación, los resultados obtenidos permitieron realizar nuevas aportaciones al problema inicial del modelo de 4 inputs propuesto. Al igual que en la primera fase de estudio del problema de las pérdidas de carga localizadas, se continuó aplicando el *Neural Network Toolbox*.

Finalmente, una vez adquirida cierta base teórica sobre redes neuronales, en concreto sobre el perceptron multinivel, y, habida cuenta de las limitaciones que presentaba el *Neural Networks Toolbox*, se decidió dar un paso más y se intentó crear un programa específico para estudiar un problema en concreto. Esto supuso aprender a programar en *Matlab*. Adquirida cierta solvencia en esta disciplina, se pretendió introducir mejoras en el modelo estudiado de ET_0 y proponer un nuevo modelo que fuera fiel a la filosofía inicial: utilizar como punto de partida pocas variables climáticas. A posteriori, en 2008, se llevó a cabo un recálculo de los apartados que habían sido estudiados mediante el *Toolbox*. Para ello, se utilizó el editor de programas, aumentando el número de casos contemplados anteriormente.

Conviene poner énfasis en los resultados del proceso de perfeccionamiento que se ha producido en la técnica de aplicación de dichas redes neuronales en los dos fenómenos estudiados. Así, mientras los dos primeros problemas fueron abordados mediante la ayuda de un *toolbox* implementado en el propio programa (*Neural Networks Toolbox*), el nuevo modelo de evapotranspiración no hubiera sido viable sin el conocimiento del lenguaje de programación de *Matlab*, especialmente en lo que se refiere a las funciones matemáticas específicas vinculadas a las redes neuronales y a la selección de estaciones auxiliares y modelos preliminares. Cuando aumentó la complejidad del problema a tratar, al iniciar el estudio del nuevo modelo de ET_0 , se hizo patente que al demandar éste un trabajo extra en cuanto a casuística en la definición del conjunto de matrices a analizar, por la necesidad de considerar distintas estrategias de entrenamiento, era necesario adaptar la herramienta *Matlab* al problema en cuestión. Por otra parte, este cambio en el enfoque de la aplicación de la técnica, permitió profundizar en el conocimiento de los aspectos constitutivos de la arquitectura de una red neuronal y de los algoritmos de entrenamiento que intervienen, así como automatizar y optimizar la evaluación de más parámetros internos de la red.

Con todo este trabajo, se ha pretendido poner de manifiesto el gran potencial que atesoran las redes neuronales para ayudar a resolver problemas que se plantean en el ámbito de la ingeniería del riego y dejar constancia de que nos encontramos ante una herramienta muy versátil y, prácticamente, por descubrir en este campo.

1.2. Redes neuronales

1.2.1. INTRODUCCIÓN

En los últimos años, la computación paralela y las redes neuronales han despertado un gran interés en los campos de la computación y la inteligencia artificial. Anteriormente, los métodos y las herramientas de computación estándar usados para procesar información se caracterizaban, en general, por representar explícitamente el conocimiento mediante reglas, redes semánticas y modelos probabilísticos, entre otros; por centrar la atención en las causas que intervenían en el problema y en sus relaciones; y por procesar la información secuencialmente. Sin embargo, apareció un gran número de problemas complejos donde no era conveniente una representación explícita del conocimiento y no se disponía de un procedimiento de razonamiento lógico para resolverlo. Así, las redes neuronales artificiales fueron introducidas como estructuras de computación alternativas, creadas con el propósito de reproducir las funciones del cerebro humano. De esta manera, apareció una nueva estructura computacional, compuesta de un ingente número de pequeños elementos procesadores interconectados trabajando en paralelo. Este nuevo paradigma permitía realizar muchas operaciones simultáneamente, en contraposición al proceso en serie tradicional en el que los cálculos se llevaban a cabo de manera secuencial.

En su inicio, los investigadores toparon con la escasez de tecnología apropiada y con la ruptura con otras áreas de la inteligencia artificial, lo que frenó su progreso. Sin embargo, el vertiginoso aumento de recursos computacionales y el desarrollo de técnicas eficientes de computación paralela han renovado el interés por este ámbito. En la actualidad, las redes neuronales han demostrado su valía para resolver problemas complejos que parecían intratables y difíciles de formular, como el reconocimiento de patrones (Ripley, 1996; Bishop, 1997), el reconocimiento de imágenes y del habla (Allen, 1995; Skrzypek y Karplus, 1992), la predicción y el pronóstico de series temporales (Azoff, 1994; Myers, 1992), el control de procesos (Miller et al., 1995) y el procesamiento de señales (Cichocki et al., 1993), entre otros.

A ello cabe añadir que, aunque una red neuronal no persigue como objetivo la reproducción de procesos biológicos, sino más bien la capacitación para resolver tareas

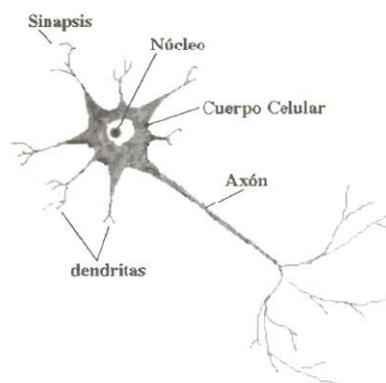
concretas con resultados similares a los procesos inteligentes humanos, el fundamento sí es el sistema nervioso humano, enormemente simplificado. De hecho, fueron los avances en neurología y los modelos de funcionamiento del cerebro humano los que finalmente han inspirado el diseño de estas estructuras computacionales.

Así pues, se puede concluir que los modelos computacionales conocidos como redes neuronales están inspirados en las características neurofisiológicas humanas y, por tanto, están formados por un gran número de procesadores, o neuronas, dispuestos en varias capas e interconectados entre sí mediante conexiones a las que se asigna un factor de ponderación o peso. Estos procesadores realizan cálculos simples basados en la información que reciben de los procesadores vecinos. Las redes neuronales no siguen reglas programadas rígidamente, como hacen los computadores digitales más convencionales, sino que utilizan un proceso de aprendizaje por analogía, donde los pesos de las conexiones son ajustados automáticamente para reproducir un conjunto de patrones representativo del problema a aprender.

1.2.2. FUNDAMENTOS BIOLÓGICOS DE LAS REDES NEURONALES

El elemento estructural y funcional esencial en el sistema de comunicación neuronal es la **neurona**. La información se envía entre las distintas neuronas a través de prolongaciones, formando redes, en las cuales se elabora y almacena. La figura 1.1 muestra un esquema de la constitución de una neurona.

Figura 1.1. Esquema general de una neurona biológica (Isasi-Viñuela y Galván-León, 2004)

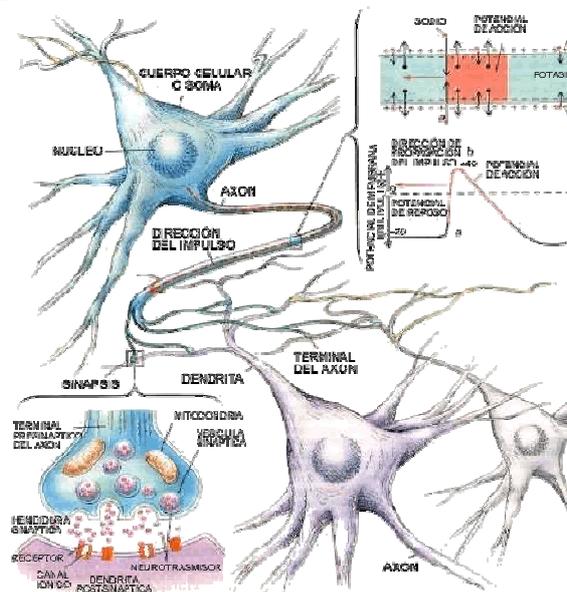


Una parte de las neuronas está en conexión con receptores, a través de los cuales llegan comunicaciones procedentes del exterior o del interior del organismo. Una de las prolongaciones de la neurona es la encargada de la conducción de impulsos, el **axón**.

Éste se encarga de propagar una serie de impulsos y, a cierta distancia de su origen, se ramifica y forma los botones terminales, que se ponen en contacto con otras neuronas o con células efectoras, pero sin llegar a fusionarse. La zona de contacto recibe el nombre de **sinapsis**. La neurona cuenta además con un gran número de ramificaciones de entrada, las **dendritas**, que propagan la señal al interior de la neurona.

Las sinapsis recogen información electro-química procedente de las células vecinas a las que la célula en cuestión está conectada; esta información llega al **núcleo**, donde es procesada hasta generar una respuesta que es propagada por el axón. Más tarde, esta señal se ramifica y llega a las dendritas de otras células a través de las sinapsis. Las sinapsis son espacios líquidos donde existen determinadas concentraciones de iones. Estos iones confieren al espacio intersináptico ciertas propiedades de conductividad que activan o inhiben el paso del impulso eléctrico. De esta manera, las sinapsis se convierten en potenciadores o inhibidores de la señal procedente de los axones. La figura 1.2 muestra un esquema del proceso de transmisión de impulsos entre neuronas.

Figura 1.2. Esquema de transmisión de información entre neuronas (Delgado, 2007)



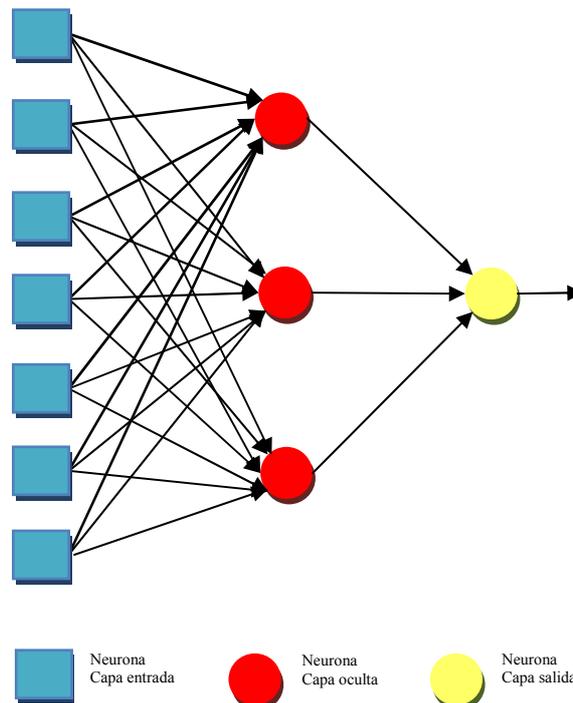
Se calcula que en el cerebro existen alrededor de 100.000 millones de neuronas, lo cual forma una red de tamaño muy grande. Cada neurona puede tener de 5.600 a 60.000 conexiones dendríticas, y llega a procesar en entrada y salida miles de sinapsis. Con ello, en el cerebro se producen trillones de sinapsis; y es esta conectividad la que lo dota de una excepcional capacidad de procesamiento. Un dispositivo de estas características

es imposible de reproducir con la tecnología actual y ello constituye una de las grandes limitaciones que tienen los sistemas artificiales actuales.

1.2.3. DEFINICIÓN Y PROPIEDADES

Haykin (1999) define las redes neuronales artificiales como *procesadores distribuidos en paralelo compuestos por unidades de proceso elementales masivamente interconectadas entre sí, con capacidad para almacenar conocimiento de tipo experimental*. Estas redes se asemejan al cerebro humano en dos aspectos: por una parte, el conocimiento se adquiere del entorno a través de un proceso de aprendizaje; y, por otra, éste se traduce en la fuerza, o los pesos, de las conexiones entre neuronas. La figura 1.3 muestra el esquema de una red neuronal artificial con alimentación hacia adelante, conectividad total y tres capas: una de entrada, con 7 neuronas; una capa oculta, con 3 neuronas; y una capa de salida, con 1 neurona.

Figura 1.3. Esquema de una red neuronal artificial feed-forward con conectividad total



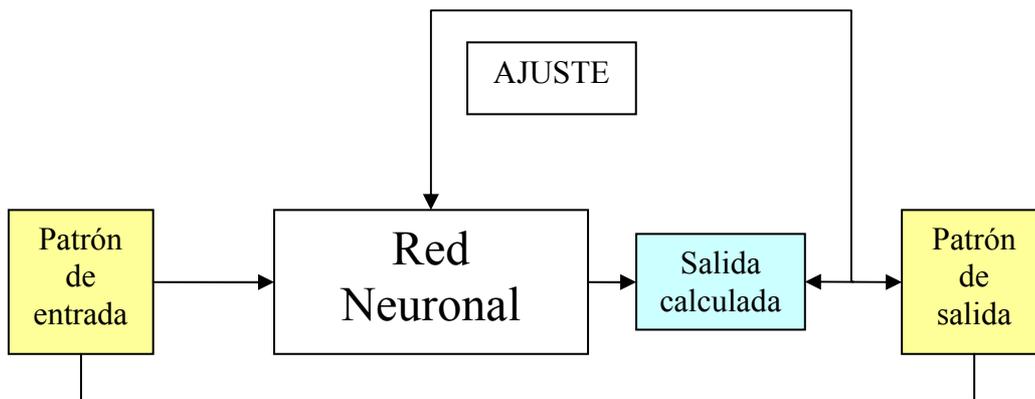
El concepto de aprendizaje implica la siguiente secuencia de acciones (Haykin, 1999):

- la red neuronal es estimulada por un entorno;
- la red neuronal sufre cambios en su parámetros libres como consecuencia de dicha estimulación;

- la red neuronal responde al entorno de manera nueva debido a los cambios sufridos en su estructura interna.

De esta manera, una vez ha sido elegida la arquitectura de red para un problema particular, los pesos de las conexiones se ajustan para codificar la información contenida en un conjunto de datos de entrenamiento o aprendizaje. La figura 1.4 esquematiza el funcionamiento de un proceso de aprendizaje supervisado.

Figura 1.4. Esquema de funcionamiento de un proceso de aprendizaje supervisado



Según Isasi-Viñuela y Galván-León (2004), desde la perspectiva de los ejemplos, el conjunto de aprendizaje debe poseer las siguientes características: ser **significativo**, es decir, debe haber un número suficiente de ejemplos; y ser **representativo**, pues es importante que todas las regiones significativas del espacio de estados estén suficientemente representadas en el conjunto de aprendizaje. Por otra parte, se define el **algoritmo de entrenamiento** como el conjunto de reglas claramente definidas para solucionar un problema de aprendizaje.

Según García-Bartual (2005), entre las propiedades más importantes de las redes neuronales, se encuentran las siguientes:

- *No linealidad.* Tienen capacidad para simular y predecir procesos no lineales.
- *Generalización.* Poseen capacidad de aprendizaje y, de ahí, también de autoorganizarse y generalizar, es decir, de hallar resultados satisfactorios para inputs no tenidos en cuenta en la fase de entrenamiento (aprendizaje).

- *Adaptabilidad.* Pueden adaptar los pesos sinápticos ante cambios en el entorno, permitiendo la representación de procesos y sistemas dinámicos muy complejos. Son apropiadas para funcionamiento en tiempo real.
- *Tolerancia a fallos.* Son capaces de aprender a reconocer patrones con ruido, distorsionados o incompletos, ya que pueden redistribuir la operación sobre su estructura en paralelo.
- *Fácil inserción dentro de la tecnología existente.* Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas.
- *Confiabilidad.* Permiten valorar el grado de confianza en la respuesta dada.

1.2.4. EVOLUCIÓN HISTÓRICA DE LAS REDES NEURONALES ARTIFICIALES

El primer intento de conceptualizar el funcionamiento del cerebro humano, basándose en una red de células interconectadas, tiene lugar en 1943 (McCulloch y Pitts, 1943). Por primera vez, se pretendió explicar el funcionamiento del sistema nervioso a partir de un conjunto de elementos primitivos de cálculo, abstracciones de las propiedades y operación de las neuronas fisiológicas y sus conexiones. La neurona artificial que propusieron fue un sistema binario que sólo admitía los estados todo o nada. Constituye un primer modelo conexionista que consigue, con elementos simples de cálculo, acomodados parcialmente en paralelo, operaciones de gran calibre.

En 1949, se propone que estas redes podían aprender. Este hecho estaba relacionado con la conductividad de la sinapsis. Así, la repetida activación de una neurona por otra, a través de una sinapsis determinada, aumenta su conductividad y la hace más propensa a ser activada sucesivamente, induciendo a la formación de un circuito de neuronas estrechamente conectadas entre sí (Hebb, 1949).

Poco después, en 1951, Minsky y Edmonds montan la primera máquina de redes neuronales (García-Bartual, 2005), una red de 40 neuronas artificiales que imitaban el cerebro de una rata. Los autores expusieron que, si se realizaba este proyecto a gran escala, con miles o millones de neuronas más, y con diferentes sensores y tipos de retroalimentación, la máquina podría ser capaz de razonar.

En 1957, Rosenblatt da a conocer el **Perceptron**, que fue objeto de distintas versiones y ampliaciones en los años sucesivos (1957-1962). Éste se compone de tres tipos de unidades: sensores, unidades de asociación y unidades de respuesta. Los estímulos externos activan algunas de las unidades-sensor, que a su vez activan, con diferente intensidad y desfase temporal, a las unidades de asociación. Dichas activaciones pueden ser activadoras o inhibidoras. La unidad asociativa actúa como una función de umbral, de tal modo que si las activaciones ponderadas que le llegan superan dicho umbral, ésta se activa, enviando un pulso hacia la unidad de respuesta. El perceptron es la red más antigua, capaz de generalizar después de haber aprendido una serie de patrones.

Dos años más tarde, se utiliza por primera vez una red neuronal para resolver un problema real: la aplicación de filtros adaptativos para eliminar ecos en las líneas telefónicas. Esta red recibió el nombre de **Adaline** (Widrow y Hoff, 1960).

Poco después, sale a la luz un estudio (Minsky y Papert, 1969) sobre el Perceptron en el que se afirma que el desarrollo de perceptrones multinivel es estéril, lo que bloquea todas las investigaciones sobre perceptrones, situación que se prolongaría hasta la década de los 80.

La aparición de una nueva técnica de aprendizaje, denominada **retropropagación del error**, rompió ese bloqueo y revitalizó definitivamente y hasta nuestros días el ámbito de investigación de las redes neuronales. Este algoritmo abrió las puertas al empleo práctico de las redes neuronales en un sinnúmero de campos. Normalmente, se refiere como **EBPN (error back propagation network)** y **EBLA (error back propagation learning algorithm)** (Rumelhart et al., 1986). Las redes neuronales más empleadas en la práctica son las llamadas redes multicapa de alimentación hacia delante entrenadas con el algoritmo de retropropagación del error (EBLA), también referidas como perceptrones multinivel (**multilayer perceptron MLP**). En 1989, se demuestra teóricamente que una red de este tipo, con una capa oculta con el suficiente número de nodos y entrenada con el EBLA, puede aproximar cualquier función continua con cualquier grado de precisión (Funahashi, 1989).

1.2.5. APLICACIONES

Hay muchos tipos diferentes de redes neuronales, cada uno de los cuales tiene una aplicación particular apropiada. El crecimiento del número de aplicaciones es exponencial y, atendiendo a la bibliografía existente, han sido empleadas en ámbitos tan diversos como los que siguen.

Finanzas y Negocios. Predicción de índices. Detección de fraudes y falsificaciones. Riesgo de créditos. Predicción de rentabilidad de acciones. Interpretación de firmas. Marketing. Venta cruzada. Campanas de venta.

Alimentación. Perfilamiento de clientes en función de la compra. Análisis de olor y aroma. Control de calidad. Desarrollo de productos.

Medicina. Ayuda al diagnóstico. Análisis de imágenes. Desarrollo de medicamentos. Analizadores de habla. Predicción de reacciones adversas a medicamentos. Causalidad de los ataques epilépticos.

Transportes. Optimización de rutas. Optimización en la distribución de recursos. Optimización de plazas y horarios de vuelos. Explotación de bases de datos.

Energía. Predicción del consumo eléctrico. Distribución de recursos hidráulicos para la producción eléctrica. Predicción de consumo de gas ciudad.

Militares. Clasificación de las señales de radar. Armas inteligentes. Reconocimiento y seguimiento en el tiro al blanco.

Manufacturación. Control de robots. Control de calidad. Control de procesos. Inspección de calidad.

Biología. Obtención de modelos de retina. Mejorar aprendizaje sobre el cerebro y otros sistemas.

Ciencia. Análisis de datos y clasificación. Análisis de tendencias y patrones.

La mayoría de las aplicaciones consisten en realizar un reconocimiento de patrones (buscar un patrón en una serie de ejemplos, clasificar patrones, completar una señal a partir de valores principales o reconstruir el patrón correcto partiendo de uno distorsionado). En muchos de los ejemplos, se tiene que trabajar con datos sensoriales y de percepción; y en otros, se realiza un filtrado o mapeo de señales de entrada.

Las redes neuronales han sido aplicadas a diferentes campos de la ingeniería hidráulica y medioambiental desde 1990. Sus aplicaciones son muy numerosas en la actualidad y abarcan, fundamentalmente, los siguientes campos.

- Predicción de caudales y aportaciones (Morshed y Kalaurachi, 1998; Thirumalaian y Deo, 1998; Valença y Ludemir, 1998; Campolo et al., 1999; Imrie et al., 2000; Cigizoglu, 2003; Kişi, 2004; Moradkhani et al., 2004; Sudheer y Jain, 2004; Cigizoglu, 2005).
- Generación de series sintéticas de aportaciones (Jia y Culver, 2006).
- Predicción de lluvias (French et al., 1992; Toth et al., 2000; Ganguly y Bras, 2003; Olsson et al., 2004).
- Estimación de precipitación a partir de imágenes de satélite (Islam y Kothari, 2000).
- Aplicaciones SIG (Pijanowski et al., 2002).
- Aplicaciones en tiempo real. Niveles y caudales en situación de crecida (Chau, 2006).
- Modelación lluvia-escorrentía (Minnes y Hall, 1996; Shamseldin, 1997; Furundzic, 1998; Jayawardena y Fernando, 1998; Sajikumar y Thandaveswara, 1999; Elshorbagy et al., 2000; Turner et al., 2001; Dolling y Varas, 2002; Hsu et al., 2002; Pan y Wang, 2004; Sanches-Fernandes, 2004; Wu et al., 2005; Chen y Adams, 2006; Jain y Srinivasulu, 2006; Raghuwanshi et al., 2006).
- Embalses (Jain et al., 1999; Coulibaly et al., 2001; Cancelliere et al., 2002; Coulibaly et al., 2005).
- Hidrología subterránea (Coulibaly et al., 2001; Balkhair, 2002; Hong et al., 2002; Rajanayaka et al., 2002; García y Shigidi, 2006; Lin y Chen, 2006).
- Control de procesos en depuradoras. (Valentin et al., 1999; Woinaroschy y Vidrighin, 1999; Choi y Park, 2001; Gamal y Smith, 2002; Studzinski, 2002).
- Calidad de aguas superficiales (Conrads y Roehl, 1999; Iriondo y Mota, 2004; Bowden et al., 2005).
- Transporte de sedimentos en ríos (Ciğizoğlu, 2002; Nagy et al., 2002; Tayfur, 2002; Cigizoglu, 2004; Kişi, 2005; Sahoo et al., 2006).
- Aspectos biológicos (Olden y Jackson, 2001; Dedecker et al., 2002; Paisley et al., 2003).
- Diseño de canales (Price et al., 1998).

- Contaminación atmosférica (Bermúdez-Cela et al., 2002; Cecchetti et al., 2004).
- Revisión/estado del arte (Flood y Kartam, 1994a; Flood y Kartam, 1994b; Zhang et al., 1998; ASCE Task Committee., 2000a, 2000b; Flood, 2006).
- Cambio climático y sequía (Kim y Valdés, 2003; Knutti et al., 2003; Elgaali y García, 2004).
- Drenaje (Shukla et al., 1996; Yang et al., 1996; Bhattacharya, 1999; Patel et al., 2002; Singh et al., 2002a, 2002b).

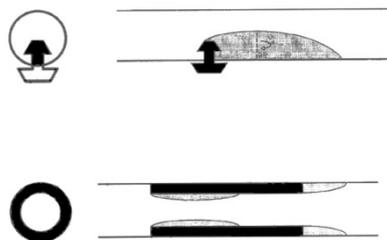
En el anejo A, se abordan los aspectos constitutivos y funcionales básicos de un perceptron multinivel, el tipo de red neuronal utilizado en este trabajo.

1.3. Introducción a los problemas abordados

1.3.1. ESTUDIO DE PÉRDIDAS DE CARGA LOCALIZADAS EN EMISORES INTEGRADOS

Los sistemas de riego localizado depositan el agua directamente en la zona radicular de árboles y cultivos a través de los emisores, haciendo posible un aumento de la eficiencia en el uso del agua en áreas caracterizadas por la escasez de recursos hídricos. Los emisores son dispositivos que controlan la salida del agua, desde las tuberías laterales, en puntos discretos o continuos (Rodrigo et al., 1997). Los emisores pueden clasificarse de diversas maneras. Si se atiende a si forman parte de la tubería o no pueden clasificarse en integrados o no integrados, respectivamente. La figura 1.5 muestra las secciones transversales y longitudinales de un lateral con un emisor no integrado sobre línea (o pinchado), parte superior, y un lateral con un emisor integrado en línea, parte inferior, así como las contracciones de flujo a que dan lugar.

Figura 1.5. Esquema de un lateral con un emisor no integrado sobre línea y un lateral con un emisor integrado en línea (Juana et al., 2002a)



El diseño del sistema es decisivo para maximizar su rentabilidad y aprovechamiento, en tanto que debe permitir maximizar la uniformidad de emisión (UE) del mismo (Provenzano y Pumo, 2004), entendiendo la UE como un indicador que cuantifica las diferencias de volumen de agua que llega a las distintas plantas. La metodología propuesta por Karmelli y Keller (1975), recogida posteriormente, entre otros, por Juana et al. (2004), Provenzano y Pumo (2004) o Bralts et al. (2003), se utiliza para cuantificar la UE, donde resulta que:

$$UE = \frac{Q_{mLQ}}{Q_m} \quad (1.1)$$

$$UE = 100 \left[1 - 1.27 \frac{CV_m}{\sqrt{n}} \right] \left(\frac{Q_{min}}{Q_m} \right) \quad (1.2)$$

donde n es el número de emisores, Q_m es el caudal medio emitido por los goteros (l/h), Q_{mLQ} es el caudal medio del cuarto más bajo (l/h), Q_{min} es el caudal mínimo emitido por los goteros (l/h) y CV_m es el coeficiente de variación de fabricación (-).

El análisis de la uniformidad de emisión y su influencia en las condiciones de diseño y dimensionado, al igual que el de nuevas tecnologías de diseño, dimensionado y modelación del funcionamiento de los sistemas de riego a presión han sido ampliamente investigados, donde destacan los resultados de Howell y Hiller (1974), Bralts et al. (1981a, 1981b y 1982), Bralts y Kesner (1983), Barragan y Wu (2005) y Barragan et al. (2006).

Los factores que influyen en la uniformidad de emisión pueden desglosarse en dos categorías generales: aquellos que provocan variaciones en las descargas de los emisores a causa de variaciones de presión y los que producen variaciones de caudal en un emisor para una presión dada. En el primer grupo se encuentran los desniveles y las pérdidas de carga en la línea, mientras que el segundo engloba la variabilidad inherente al proceso de fabricación de los emisores, las obturaciones y los efectos derivados de los cambios de temperatura. Asimismo, las pérdidas de carga se dividen entre pérdidas continuas, debidas al rozamiento, y pérdidas localizadas, debidas, en general, a la variación del vector velocidad, y, en el caso de un emisor en particular, a la contracción y posterior expansión del flujo al atravesar la sección obstruida por el mismo. Las pérdidas continuas han sido estudiadas de manera teórica (Barenblatt y Monin, 1979;

Schlichting, 1979; Von Bernuth, 1990) y de manera práctica (Watters y Keller, 1978; Schlichting, 1979; Von Bernuth y Wilson, 1989). Sin embargo, las pérdidas localizadas son menos conocidas, aunque se hayan realizado estudios sobre el comportamiento de diferentes tipos de emisores, sin llegar a generalizar los resultados en una ecuación universal para cualquier tipología (Howell y Hiller, 1974; Howell y Barinas, 1980; Al Amoud, 1995).

La evaluación de las pérdidas de energía y, con ella, el diseño de instalaciones de riego localizado, se suele llevar a cabo considerando la hipótesis de pérdidas localizadas nulas. Y ello pese a los numerosos estudios que revelan que éstas pueden llegar a suponer un porcentaje significativo de las pérdidas totales cuando el número de emisores es elevado. (Howell y Hiller, 1974; Howell y Barinas, 1980; Jeppson, 1982; Bagarello y Pumo, 1992; Al Amoud, 1995; Bagarello et al., 1997; Vallesquino y Luque-Escamilla, 2001; Juana et al., 2002a; Provenzano et al., 2003; Provenzano y Pumo, 2004)

Durante los últimos años se ha extendido el uso de laterales con emisores integrados gracias a su capacidad para ser adaptados a diferentes marcos de plantación y por su facilidad de montaje e instalación. La oferta de laterales con emisores integrados se caracteriza por abarcar diferentes modelos de emisor, estar soldados a tuberías de polietileno de pequeños diámetros con separaciones entre 20 y 150 cm. Por ello, esta variabilidad justifica la necesidad de marcar un procedimiento general para evaluar estas pérdidas localizadas, con el objetivo de incluirlas en el diseño de la instalación.

Algunos autores han desarrollado estudios más amplios con el objetivo de proponer fórmulas generales para estimar la caída de presión provocada por diferentes tipos de emisores a lo largo del lateral en función de parámetros como la sección obstruida, el caudal nominal del emisor, el número de Reynolds o el número de emisores en el lateral. Una de las primeras propuestas fue a cargo de Watters y Keller (1978), con la obtención de unas curvas que representaban las pérdidas singulares provocadas por emisores sobre línea en función del tamaño de la conexión y del diámetro interior de la tubería, comprendidos entre 10 y 20 mm.

Arviza (1992) obtuvo sendas ecuaciones para emisores pinchados y en línea extrapolando la pérdida de presión local producida por un emisor sometido a diferentes números de Reynolds a todo el lateral. Por otra parte, Bagarello et al. (1997) y Provenzano y Pumo (2004) propusieron dos expresiones nuevas para estimar las pérdidas localizadas en emisores sobre línea e integrados, respectivamente. Para ello, se midieron las pérdidas en un lateral con cincuenta emisores sellados, con lo que se despreció la influencia del servicio en línea, y se determinó el valor del coeficiente α como el factor de proporcionalidad entre las pérdidas localizadas y la altura cinética, que varía para cada tramo del lateral. Este procedimiento dificulta la determinación de las pérdidas sin la ayuda de un ordenador. Un año después, Provenzano et al. (2005) propusieron una nueva expresión para predecir pérdidas de carga en emisores integrados, considerando, además de los de 2004, los datos correspondientes a cinco nuevos modelos no coaxiales.

Juana et al. (2002a, 2002b) llevan a cabo un estudio teórico del problema validado experimentalmente, donde se recoge el caudal de todos los emisores con distribución mixta, aunque la consideración del coeficiente de resistencia α plantea el mismo inconveniente que el enfoque anterior. Además, ambos estudios consideran que los coeficientes de resistencia, α y k respectivamente, son constantes para cualquier número de Reynolds, pese a detectar una relación entre ambas variables.

Palau-Salvador et al. (2006) proponen una expresión para evaluar directamente las pérdidas localizadas (sin coeficientes de resistencia) en emisores pinchados, obtenida sin sellar los mismos. Asimismo, generan un modelo basado en CFD para predecir las mismas y llegar a una mejor comprensión de la turbulencia originada por la inserción de los emisores. Provenzano et al. (2007) desarrollaron un procedimiento basado en CFD (*Computational Fluid Dynamics*) para valorar las pérdidas de presión en laterales con emisores en línea coextrusionados.

El mismo año, Demir et al. (2007) crearon dos modelos de predicción de pérdidas de carga por rozamiento y localizadas en emisores de riego localizado. Estos modelos, válidos para emisores integrados, fueron planteados con ayuda del teorema Pi de Buckingham, que permitió reducir en tres el número de variables que influían en la

determinación de las pérdidas localizadas. De esta manera, las ecuaciones existentes se muestran a continuación de manera resumida.

1. Arviza (1992)

- emisores sobre línea

$$h_l = 8.229 \cdot 10^{-6} n_e^{2.502} q_n^{2.133} \left(\frac{S}{S} \right)^{2.490} \quad \text{para DN 16 mm} \quad (1.3)$$

$$h_l = 5.074 \cdot 10^{-6} n_e^{2.852} q_n^{1.665} \left(\frac{S}{S} \right)^{3.192} \quad \text{para DN 12 mm y } \frac{S}{S} > 0.367 \quad (1.4)$$

$$h_l = 0.427 \cdot 10^{-3} n_e^{2.845} q_n^{1.498} \left(\frac{S}{S} \right)^{7.317} \quad \text{para DN 12 mm y } \frac{S}{S} < 0.367 \quad (1.5)$$

- emisores en línea

$$h_l = 3.344 \cdot 10^{-7} n_e^{3.45} q_n^{2.546} \left(\frac{D_e}{D_t} \right)^{-3.413} \left(\frac{L_e}{D_t} \right)^{0.765} \left(\frac{1}{D_t} \right)^{1.546} \quad \text{para DN 16 mm} \quad (1.6)$$

2. Bagarello et al. (1997)

- emisores sobre línea

$$\alpha = 1.68 \left(\frac{\left(\frac{S}{S} \right)^2}{\left(1 - \left(\frac{S}{S} \right) \right)^2} \right)^{0.645} \quad (1.7)$$

3. Juana et al. (2002b)

$$K = \left(\frac{1}{C_c r_{te}} - 1 \right)^2 \quad (1.8)$$

- emisores sobre línea

$$C_c = 0.907 - 0.523(1 - r_{te}) + 0.659(1 - r_{te})^2 - 0.321(1 - r_{te})^3 \quad (1.9)$$

- emisores en línea

$$C_c = 0.887 - 0.704(1 - r_{te}) + 0.847(1 - r_{te})^2 - 0.464(1 - r_{te})^3 \quad (1.10)$$

- emisores integrados

$$C_c = 0.844 - 0.468(1 - r_{te}) + 0.161(1 - r_{te})^2 - 0.036(1 - r_{te})^3 \quad (1.11)$$

4. Provenzano y Pumo (2004)

- emisores integrados

$$\alpha = 0.056 \left[\left(\frac{D_t}{D_e} \right)^{17.825} - 1 \right] \quad (1.12)$$

5. Provenzano et al. (2005)

- emisores integrados

$$\alpha = 0.116 \left[\left(\frac{D_t}{D_e} \right)^{13.87} - 1 \right] \quad (1.13)$$

6. Palau-Salvador et al. (2006)

- emisores sobre línea

$$h_l = 7.63781 \cdot 10^{-6} n_e^{2.49535} q_n^{2.55437} \left(\frac{s}{S} \right)^{2.8445} \quad (1.14)$$

7. Demir et al. (2007)

- emisores integrados en línea

$$\frac{\Delta H_s}{S_e} = 28.116 \left(\frac{V D_t}{v} \right)^{-0.771} \left(\frac{V^2}{g D_t} \right)^{1.248} \left(\frac{S_e}{D_t} \right)^{-0.258} \left(\frac{D_e}{D_t} \right)^{-3.008} \left(\frac{L_e}{D_e} \right)^{0.066} \quad (1.15)$$

- emisores integrados sobre línea

$$\frac{\Delta H_s}{S_e} = 4.629 \cdot 10^{-7} \left(\frac{V D_t}{v} \right)^{1.673} \left(\frac{V^2}{g D_t} \right)^{0.058} \left(\frac{S_e}{D_t} \right)^{-0.365} \left(\frac{s}{S} \right)^{1.153} \quad (1.16)$$

donde h_l son pérdidas de carga localizadas en m; ΔH_s es la pérdida de carga por fricción en la separación entre emisores en m; n_e es el número de emisores en el lateral; q_n es el caudal nominal del emisor en l/h; (s/S) es la relación entre la sección de conexión del emisor y la de la tubería; L_e es la longitud del emisor en mm (en las ecuaciones 1.15 y

1.16 en m); D_e es el diámetro interior del emisor en mm (en las ecuaciones 1.15 y 1.16 en m); D_t es el diámetro interior de la tubería en mm (en las ecuaciones 1.15 y 1.16 en m); α y K son los coeficientes de resistencia que multiplican al término cinético para obtener h_l ; C_c es el coeficiente de contracción; r_{te} es la relación entre la sección de la tubería con el emisor y sin éste; g es la aceleración de la gravedad en ms^{-2} ; S_e es la separación entre emisores en m; V es la velocidad media en ms^{-1} ; y ν es la viscosidad cinemática del agua en m^2s^{-1} .

Siguiendo en esta línea, el problema que se aborda es la modelación de pérdidas de carga localizadas provocadas por emisores integrados mediante redes neuronales. De acuerdo con lo explicado en esta sección, se trata de contribuir a crear estimaciones mejores y más generalizables de dichas pérdidas e, indirectamente, posibilitar un mejor diseño de subunidades, que permita alcanzar uniformidades de riego más elevadas, en la medida en que este tipo de pérdidas puedan ser relevantes en una instalación determinada. Nuevamente, se pretende plantear la posibilidad de introducir una herramienta novedosa, cuyas ventajas aún no han sido aprovechadas en este ámbito. Esta falta de antecedentes, ha obligado a trazar estrategias procedimentales que deberán ser corroboradas o corregidas en estudios venideros.

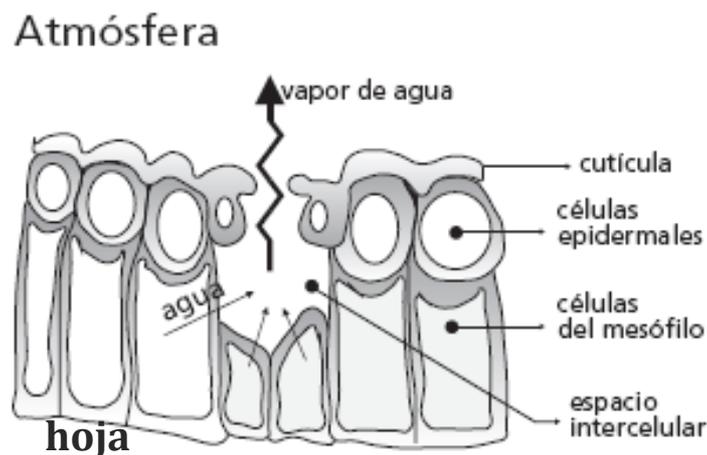
1.3.2. ESTUDIO DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA

El agua se está convirtiendo en un bien escaso y caro en muchas zonas civilizadas. El aumento de la competencia por el agua entre zonas urbanas y rurales es considerable y se estima que aproximadamente la mitad de la población mundial depende de productos agrarios regados (Lima et al., 1999). Las necesidades hídricas de los cultivos son la cantidad de agua que hay que suministrarles para mantener un nivel máximo de evapotranspiración, ET; y se pueden determinar como la diferencia entre la ET y el agua que aporta la lluvia o que puede ser extraída del suelo por el cultivo. Así, la ET es determinante en la fase de diseño agronómico de un sistema de riego. Para Pizarro (1987), esta etapa es decisiva, pues los errores que se cometan aquí no podrán ser corregidos en la fase posterior, o diseño hidráulico, y puede poner en peligro el objetivo de conseguir una gestión adecuada del agua de riego. Unos hábitos generalizados de diseño y manejo inadecuados pueden exponer a la agricultura de regadío a un serio peligro de colapso. Sousa et al. (2002) sugieren que un sistema de regadío está bien

diseñado y manejado cuando tiene lugar una aplicación de agua racional, con unas dosis y frecuencias suficientes que aseguren el desarrollo completo del cultivo. Por todo ello, la cuantificación de la evapotranspiración es muy importante porque permite la optimización del uso del agua de riego en regiones áridas y semiáridas, donde la escasez de agua es un problema y es de gran relevancia para estudios agrarios, hidrológicos y climáticos, pues constituye uno de los mayores componentes del ciclo hidrológico (Sobrino et al., 2005).

La evaporación es el proceso en el que el agua líquida se convierte en vapor de agua y desaparece de la superficie evaporativa (Allen et al., 1998). La transpiración es el flujo de vapor de agua a través de los estomas de las plantas a la atmósfera, figura 1.6, (Villalobos et al, 2002)

Figura 1.6. Esquema del proceso de pérdida de agua desde los estomas (Allen et al., 1998)



La combinación de estos dos procesos separados a través de los cuales el agua se pierde, por una parte, desde la superficie del suelo por evaporación y, por otra parte, desde el cultivo por transpiración, se conoce como evapotranspiración (Allen et al. 1998). La evapotranspiración es un fenómeno complejo y no lineal que depende de la interacción de varios factores climáticos (radiación solar, velocidad del viento, humedad del aire y temperatura) así como del tipo y del estado de crecimiento del cultivo (Kumar et al., 2002).

Por otra parte, la evapotranspiración de referencia (ET_0) se define como la evapotranspiración de una pradera de gramíneas en cobertura total con una altura entre 8 y 15 cm y un buen suministro de agua y nutrientes. El concepto de evapotranspiración

de referencia fue introducido para estudiar la demanda evaporativa de un cultivo tipo independientemente del tipo de suelo. Los únicos factores que afectan a la ET_o son climáticos y, consecuentemente, puede considerarse un factor climático. De esta manera, va asociada a un momento del año y una localización concretos. Por ello, es necesario introducir algún elemento que relacione este parámetro climático con la demanda evaporativa específica de cada cultivo. El coeficiente de cultivo k_c es el factor que relaciona la evapotranspiración de un cultivo con la de referencia (Doorenbos y Pruitt, 1977). Estas diferencias se deben, entre otros, a los efectos propios del cultivo sobre la evapotranspiración, como pueden ser el área foliar, la altura, el porcentaje de suelo cubierto, etc. La evapotranspiración del cultivo (ET_c), en ausencia de déficit hídrico, se calcula habitualmente como el producto

$$ET_c = k_c \cdot ET_o \quad (1.17)$$

La evapotranspiración se puede medir directamente o estimar indirectamente a partir de datos climáticos. La evapotranspiración no es fácil de medir experimentalmente. Un sistema habitual para determinar la ET_c es la realización de un balance de agua del suelo, mediante un lisímetro, por ejemplo.

Los lisímetros de pesada son grandes contenedores abiertos por su parte superior que engloban un volumen de suelo cuyo peso puede ser medido con precisión y permiten realizar un balance de agua. No siempre es posible medir la evapotranspiración con un lisímetro porque es un método caro que consume mucho tiempo y exige experimentos planeados cuidadosamente (Villalobos et al., 2002). Por esta razón, los métodos indirectos pueden ser preferibles debido a su inmediatez. Estos métodos varían desde relaciones empíricas hasta métodos complejos basados en procesos físicos. La selección del método para estimar la evapotranspiración depende de varios factores. Uno de ellos es la disponibilidad de datos climáticos (Pereira et al., 2002). Así, las ecuaciones existentes para cálculo de ET_o pueden ser clasificadas en cuatro grupos generales en función de los datos requeridos:

- *Temperatura*. Thornthwaite (1948). Blaney-Criddle (1950). Hargreaves (Hargreaves y Samani, 1985).
- *Radiación*. FAO-radiación.
- *Temperatura y radiación*. Jensen-Haise (1963). Priestley-Taylor (1972).

- *Temperatura, radiación, humedad relativa y velocidad del viento.* Son las ecuaciones de combinación derivadas de la de Penman (1948) con la de Penman-FAO (Doorenbos y Pruitt, 1977) y la de FAO-Penman-Monteith (Allen et al., 1998)

En literatura reciente, se hallan recogidas un gran número de ecuaciones para predecir la ET_0 (Dehghanisanij et al., 2004; Pereira y Pruitt, 2004; Alexandris et al., 2005; Gavilán et al., 2006) y, en la práctica, la elección o el descarte de un método dependen fundamentalmente de la disponibilidad o no de los datos que éste exige. Por otra parte, varios autores plantearon la necesidad de establecer un método estándar preciso para estimar la evapotranspiración de referencia (Chiew et al., 1995; Allen, 1996; Martínez-Cob y Tejero-Juste, 2004).

La fiabilidad de la ecuación de Penman-Monteith (PM) para estimar ET_0 ha sido estudiada por muchos científicos (McNaughton y Jarvis, 1984; Allen, 1986; Allen et al., 1989, De Souza y Yoder, 1994; Chiew et al., 1995). Jensen et al. (1990) estudiaron las prestaciones de 20 métodos diferentes frente a medidas de lisímetro en 11 estaciones situadas en diferentes contextos climáticos del planeta. La ecuación de PM resultó ser el mejor método en todas las situaciones climáticas contempladas. Otros estudios han demostrado la superioridad de la ecuación de PM frente a otros métodos cuando se comparaban con medidas de lisímetro, especialmente para medidas diarias (Chiew et al., 1995; García et al., 2004; López-Urrea et al., 2006; Cai et al., 2007). Así, la FAO (Food and Agricultural Organization of the United Nations) asumió la definición de Smith et al. (1997) y adoptó la ecuación de PM-FAO como la ecuación estándar para estimar ET_0 (Allen et al., 1998; Naoum y Tsanis, 2003).

Sin embargo, el número de estaciones donde las medidas climáticas disponibles son fiables y permiten la aplicación de la ecuación PM-FAO es limitado. Este hecho justifica el desarrollo de métodos suficientemente exactos para determinar ET_0 a partir de pocas variables climáticas, que puedan ser medidas fácilmente y con fiabilidad, como la temperatura.

En los últimos años, se han aplicado redes neuronales (ANN) para predecir la ET_0 en distintas circunstancias, con muy buenos resultados en general. Kumar et al. (2002) usaron un perceptron multinivel (MLP) con un algoritmo de entrenamiento de

retropropagación del error estándar y con momento, respectivamente, para estimar ET_o . Para ello, consideraron valores de lisímetro como targets y aplicaron diferentes arquitecturas. Así, encontraron, entre otras cosas, que las ANN permitían obtener mejores predicciones de ET_o que el modelo de Penman-Monteith.

Sudheer et al. (2003) aplicaron redes RBF (Radial Basis Function) para modelar valores de lisímetro en el cultivo de arroz a partir de distintas combinaciones de inputs. Sus resultados sugerían la posibilidad de calcular valores de ET_c a partir de datos de temperatura, aunque los autores puntualizaban que era preciso analizar otros cultivos y periodos vegetativos. En la misma línea, Trajkovic et al. (2003) utilizaron redes RBF para estimar ET_o obtenida con la ecuación FAO-56 PM a partir de datos de temperatura. Asimismo, comparó las predicciones obtenidas con las de Thornwaite, Hargreaves y ecuaciones simplificadas de PM y concluyó que las redes RBF ofrecían, en general, mejores estimaciones de ET_o .

Kişİ (2006) realizó un análisis comparativo de predicciones obtenidas mediante redes MLP y los modelos empíricos de Penman y Hargreaves y comprobó que las ANN ofrecían estimaciones mucho más exactas. Un año más tarde, Zanetti et al. (2007) plantean la importancia de desarrollar herramientas de predicción efectivas para aquellos casos en que sólo hay pocas variables climáticas disponibles, habida cuenta de que la existencia de estaciones con datos fiables para la aplicación de la ecuación FAO-56 PM es limitada. Para ello, usan un perceptron multinivel con retropropagación del error para predecir ET_o , calculada con la ecuación FAO-56 PM, a partir de temperaturas máxima y mínima, radiación extraterrestre y horas diarias de sol. A pesar de los resultados satisfactorios obtenidos cuando el modelo se testaba con datos de la estación que había sido utilizada en la fase de entrenamiento, el modelo presentaba un potencial bajo para predecir los valores de ET_o fuera de la estación de entrenamiento. Unos meses más tarde, Kişİ y Öztürk (2007) aprovecharon por primera vez la capacidad de vinculación de las técnicas de lógica difusa en la modelación de ET_o , con resultados incluso mejores a los obtenidos con redes neuronales.

Poco más tarde, Rahimi (2008) lleva a cabo un estudio análogo al de Zanetti et al. (2007) en doce estaciones climáticas ubicadas en un entorno semiárido y obtiene buenas predicciones, aunque no analiza la capacidad de generalización del modelo fuera de la

sede empleada en la fase de entrenamiento. Este hecho lastra la calidad de los resultados, pues restringe la utilidad del modelo y lo sitúa, básicamente, como sustituto de la ecuación FAO-56 PM cuando ésta no puede aplicarse por falta de datos, a causa de averías en el sistema de medición, por ejemplo. Finalmente, Kumar et al. (2008) comparan los rendimientos de los mejores métodos de estimación de ET_0 según la ASCE (American Society of Civil Engineers) con los que proporcionan sus respectivos homólogos ANN, aplicando un perceptron multinivel con retropropagación estándar del error y con momento, respectivamente, con distintas tasas de aprendizaje. En todos los casos los modelos neuronales ofrecen mejores resultados que los métodos convencionales.

En esta línea, se ha analizado la aplicabilidad y capacidad de generalización de una red neuronal de 4 inputs (Zanetti et al., 2007) en dos contextos continentales (estaciones costeras e interiores) de la Comunidad Valenciana y, por otra parte, se ha desarrollado y testado un nuevo modelo de 6 inputs que pretende aprovechar la generación preliminar de variables climáticas no disponibles, así como la suplantación de datos en las estaciones de test con datos procedentes de estaciones con índices de continentalidad similares.

1.4. Objetivos

1.4.1. OBJETIVOS GENERALES

Con la presente tesis se persigue abordar la creación de nuevos modelos basados en redes neuronales artificiales, para la predicción y el estudio de variables en distintos ámbitos de la ingeniería del riego, así como poner de manifiesto el enorme potencial atesorado por dichas herramientas. Asimismo, se pretende mejorar los modelos ya existentes, tanto los basados en técnicas estadísticas tradicionales (pérdidas de carga localizadas), como los que ya han sido formulados con la ayuda de redes neuronales (evapotranspiración de referencia).

Los dos problemas escogidos para nuestro estudio han sido: 1) la predicción de pérdidas localizadas en emisores integrados, y 2) la predicción de evapotranspiración de referencia ET_0 a partir de un número limitado de variables climáticas. Dicha elección se

justifica, de una lado, por la influencia determinante de las pérdidas singulares ocasionadas por los emisores en el diseño de una subunidad de riego, así como en la distribución de presiones y uniformidad de riego de la instalación derivada del mismo; y, de otro, por la importancia de establecer una cuantificación precisa de la ET_0 en los ámbitos de la producción de los cultivos, el manejo del riego, la evaluación ambiental y la gestión de recursos hídricos.

1.4.2. OBJETIVOS PARTICULARES

1.4.2.1. Estudio de pérdidas de carga singulares

Servirse de las redes neuronales para crear una herramienta de predicción generalizable que mejore los modelos tradicionales existentes para la estimación de pérdidas localizadas en emisores integrados. Para ello, se utilizarán datos procedentes de ensayos con diferentes modelos comerciales de emisores.

En concordancia con el objetivo anterior, trazar estrategias procedimentales para generar modelos de predicción con potencial de generalización, apoyándose en una caracterización previa de los emisores estudiados, mediante su coeficiente de resistencia.

1.4.2.2. Estudio de la evapotranspiración de referencia

Analizar en primer lugar la validez de un modelo ANN (artificial neural networks) de 4 inputs (Zanetti et al., 2007) en diferentes contextos geográficos, y a continuación, estudiar su precisión en función de los índices de continentalidad considerados.

Comparar el comportamiento de dicho modelo con el de Hargreaves y Samani (1985), que también precisa la medición de pocas variables climáticas para su aplicación.

Estudiar estrategias de mejora de dicho modelo, manteniendo la esencia de su filosofía: estimar evapotranspiración de referencia sólo a partir de mediciones de temperatura. Para ello, se pretende introducir dos nuevos aspectos a considerar: 1) la generación de modelos ANN preliminares para la generación de variables no disponibles en las estaciones test, y 2) la suplantación de datos a partir de estaciones con índices de

continentalidad similares. De esta manera, se analizarán modelos ANN con distintas combinaciones de variables, considerando asimismo distintas alternativas en el momento de elegir la procedencia de dichas variables.

Proponer un modelo ANN que mejore las prestaciones del de 4-inputs considerando modelos preliminares y suplantación de datos.

1.5. Estructura del contenido

Debido a las notables diferencias existentes entre los ámbitos en que han sido aplicadas las redes neuronales en este trabajo, se ha optado por estructurar su contenido dando prioridad al fenómeno estudiado antes que al apartado metodológico tradicional. Es decir, el problema abordado se ha fijado como unidad temática de cada capítulo y éste se ha estructurado en los bloques generales siguientes: a) introducción, b) materiales y métodos, c) resultados y discusión, d) conclusiones y e) líneas futuras. Se ha pensado que esta organización es más apropiada y facilita la comprensión del contenido. Por último, se ha mantenido la bibliografía en único bloque general, pues las referencias específicas sobre redes neuronales artificiales son comunes en los cuatro capítulos.

Siguiendo tal criterio, tras el presente capítulo de introducción, el capítulo 2 se ha centrado en el estudio del problema de la estimación de pérdidas de carga localizadas; y los capítulos 3 y 4, en el análisis de la predicción de evapotranspiración de referencia. Así pues, en el capítulo 2 se plantea el estudio de un nuevo modelo ANN para predecir pérdidas singulares en emisores integrados. A continuación, el capítulo 3 recoge la cuestión de la validez de un modelo ANN de 4 inputs en la Comunidad Valenciana. Finalmente, el capítulo 4 abarca el desarrollo de un nuevo modelo ANN de 6 inputs, como alternativa al modelo anterior. El capítulo 3 no presenta apartado e) (líneas futuras), puesto que el capítulo 4 se considera como una continuación de la línea iniciada en el capítulo anterior. Con el objetivo de no entorpecer el seguimiento del hilo argumental, se ha preferido incluir la mayor parte de tablas y figuras en los anejos B, C y D, correspondientes a los resultados de los capítulos 2, 3 y 4, respectivamente.

capítulo 2

predicción de pérdidas de carga localizadas en
emisores integrados con ANNs

2.1. INTRODUCCIÓN	35
2.2. MATERIALES Y MÉTODOS	35
2.2.1. DESARROLLO EXPERIMENTAL	35
2.2.2. VARIABLES DEL MODELO.	38
2.2.3. GESTIÓN DE DATOS EXPERIMENTALES	41
2.2.4. PROPIEDADES DE LAS REDES NEURONALES UTILIZADAS E IMPLEMENTACIÓN EN <i>MATLAB</i>	44
2.2.4.1. <i>Propiedades de la ANN</i>	44
2.2.4.1.1. Modelo neuronal.....	44
2.2.4.1.2. Algoritmo de entrenamiento	45
2.2.4.1.3. Criterio de parada	46
2.2.4.2. <i>Implementación de las redes</i>	47
2.2.4.2.1. Arquitecturas analizadas. Número de repeticiones	47
2.2.4.2.2. Parámetros de entrenamiento.....	49
2.2.5. INDICADORES DE CALIDAD DEL COMPORTAMIENTO DE LAS REDES	50
2.3. RESULTADOS	53
2.3.1. SELECCIÓN DE LAS VARIABLES DEL MODELO.....	53
2.3.1.1. <i>h_i como variable de salida</i>	54
2.3.1.2. <i>α como variable de salida</i>	55
2.3.1.3. <i>Comparativa general</i>	55
2.3.2. COMPOSICIÓN DEL SUBGRUPO DE VERIFICACIÓN.....	58
2.3.3. PROPUESTA DE MODELO ANN	61
2.4. CONCLUSIONES.....	66
2.5. LÍNEAS DE FUTURO	67

2.1. Introducción

Como ya se ha dicho, para conseguir un diseño hidráulico adecuado de una instalación de riego se requiere cuantificar adecuadamente tanto las pérdidas de carga por rozamiento como las pérdidas de carga localizadas que tienen lugar en los emisores.

En el presente capítulo, se pretende aprovechar la capacidad de vinculación input-output de las redes neuronales artificiales para estudiar el fenómeno de las pérdidas de carga localizadas provocadas por emisores integrados y proponer nuevo modelo con capacidad de generalización real. Al no existir antecedentes bibliográficos sobre la utilización de ANNs para predicción de pérdidas de carga, se han propuesto estrategias procedimentales para desarrollar un modelo ANN adecuado. Básicamente, éstas deben ir encaminadas a dilucidar dos cuestiones: la combinación óptima inputs-output y la composición ideal de los subconjuntos de entrenamiento y validación cruzada. Asimismo, la metodología de test debe ser adecuada y dicho subconjunto debe ser representativo del conjunto.

Conviene recordar que este capítulo se ha llevado a cabo en colaboración con el profesor Giuseppe Provenzano, de la Universidad de Palermo, que aportó los datos experimentales. Dichos datos ya fueron objeto de estudio y condujeron a la determinación de sendos modelos de regresión para pérdidas localizadas en emisores integrados, que fue publicado (Provenzano y Pumo, 2004; Provenzano et al., 2005). En el siguiente apartado se describirá sucintamente el desarrollo experimental seguido, pues el objetivo principal del capítulo va más ligado a la aplicabilidad de la herramienta matemática que a la naturaleza del fenómeno analizado. Por ello, la metodología experimental se ha dejado en un segundo plano.

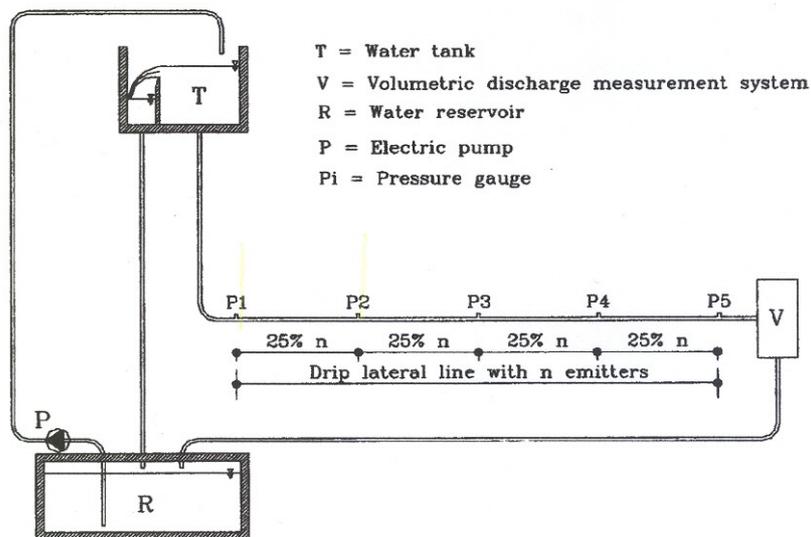
2.2. Materiales y métodos

2.2.1. DESARROLLO EXPERIMENTAL

Los experimentos se realizaron con laterales de polietileno de baja densidad de 100 m de longitud y diámetros nominales de 12, 16, 17 y 20 mm. La instalación experimental, representada en la figura 2.1, constaba de los siguientes elementos:

- un depósito de nivel constante situado 20 m sobre la superficie del suelo
- una bomba que alimenta el depósito con agua filtrada
- un termómetro
- cinco manómetros diferenciales y un manómetro de mercurio
- un sistema de resistencias eléctricas para calentar el agua circulante por las tuberías

Figura 2.1. Esquema del montaje utilizado para la toma de medidas experimentales (Provenzano et al., 2005)



Las tuberías fueron instaladas con una leve pendiente ascendente (0.4%) para facilitar la eliminación del aire antes de efectuar los ensayos.

Los efectos de las presiones en la sección transversal de la tubería fueron ignorados. Los experimentos se llevaron a cabo para un amplio rango de caudales y temperatura del agua para obtener un amplio abanico de valores de números de Reynolds. Asimismo, la longitud del lateral fue medida cada vez para tener en cuenta un eventual dilatación longitudinal.

Se instalaron 15 laterales comerciales con emisores coextrusionados de distintas formas y dimensiones geométricas (designados por las letras A,B,C...Q). Para cada modelo, en primer lugar se midieron los diámetros interiores de la tubería y del emisor. El diámetro interior de la tubería, D_t , se determinó midiendo muestras de 10-30 cm de longitud. Cada muestra se pesó con una balanza de precisión antes y después de ser rellena con

agua destilada a temperatura conocida. Así, conocido el peso, se calculaba el diámetro, considerando la densidad. Para medir el diámetro interno de cada emisor, D_e , se siguió el mismo procedimiento, mientras que su longitud se determinó con ayuda de un pie de rey. A efectos prácticos, en emisores no coaxiales (H a Q), se adjudicó al diámetro interior el significado que posee para los coaxiales.

Los puntos P1 a P5 de la figura corresponden a cinco tomas de presión diferencial, que permitieron medir las pérdidas de presión en los tramos de tubería que delimitaban. En la toma 5 se conectó, además, un manómetro de mercurio para determinar la presión en ese punto y, consecuentemente, derivar los valores de presión en las otras tomas. Las mediciones de presión acarrearán un error máximo de 0.05 mm, lo que correspondía a un error en la determinación de la altura de presión de 1mm. Cada medición se repitió tres veces.

Durante todo el proceso, se mantuvieron sellados los emisores integrados para facilitar las medidas. Asimismo, se ensayaron 13 condiciones de flujo por lateral. El valor del caudal se determinó midiendo el volumen de agua acumulada en 2 minutos en el extremo aguas abajo del lateral, teniendo presente la densidad de la misma. Para reducir el error, el proceso de determinación del caudal se repitió tres veces. La desviación estándar asociada fue siempre menor de 0.5 l/h.

Para cada caudal circulante, se determinó el valor experimental de las pérdidas de carga singulares como la diferencia entre las pérdidas de carga totales, medidas mediante los manómetros, y las pérdidas por rozamiento provocadas en la tubería y los emisores, determinadas mediante la ecuación Darcy-Weisbach. Para el coeficiente de fricción, se aplicó una expresión similar a la de Blasius. Así,

$$j = \frac{f}{D_t} \cdot \frac{V^2}{2g} \quad (2.1)$$

$$f = c_f \cdot Re^{-0.25} \quad (2.2)$$

donde j es el gradiente de pérdidas de carga por rozamiento por unidad de longitud (se utiliza minúscula para distinguir de la matriz jacobiana, que aparece más adelante), D_t (m) es el diámetro interior de la tubería, V (m/s) es la velocidad media del flujo, g (m/s^2) es la aceleración debida a la gravedad, $f(-)$ es el factor de fricción y Re (-) es el número

de Reynolds. El coeficiente c_f puede suponerse igual a 0.302 (Bagarello et al., 1995) o igual a un valor comprendido entre 0.281 y 0.345 (Von Bernuth y Wilson, 1989). Al disponer de medidas en cuatro tramos, los valores utilizados de las pérdidas localizadas corresponden a la media de los cuatro tramos.

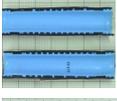
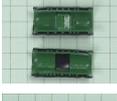
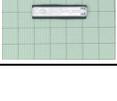
Estudios previos (von Bernuth y Wilson, 1989; von Bernuth, 1990; Bagarello et al., 1995) muestran que en tuberías de polietileno de pequeño diámetro, para Re comprendidos entre 2.000 y 36.000, la expresión anterior para f puede considerarse válida. En el rango de régimen laminar, $Re < 2000$, debido a las bajas velocidades del flujo, las pérdidas por rozamiento calculadas con las ecuaciones anteriores son del mismo orden de magnitud que las determinadas con la ecuación de Hagen-Poiseuille. Por otra parte, para $Re < 2000$, las pérdidas por rozamiento representan sólo un pequeño porcentaje de las pérdidas totales en el lateral. Así pues, en la práctica, la ecuación anterior de f puede utilizarse para determinar pérdidas por rozamiento incluso para $Re < 2000$.

La tabla 2.1 resume las características de los ensayos llevados a cabo para cada modelo de emisor, así como las propiedades geométricas de los mismos.

2.2.2. VARIABLES DEL MODELO.

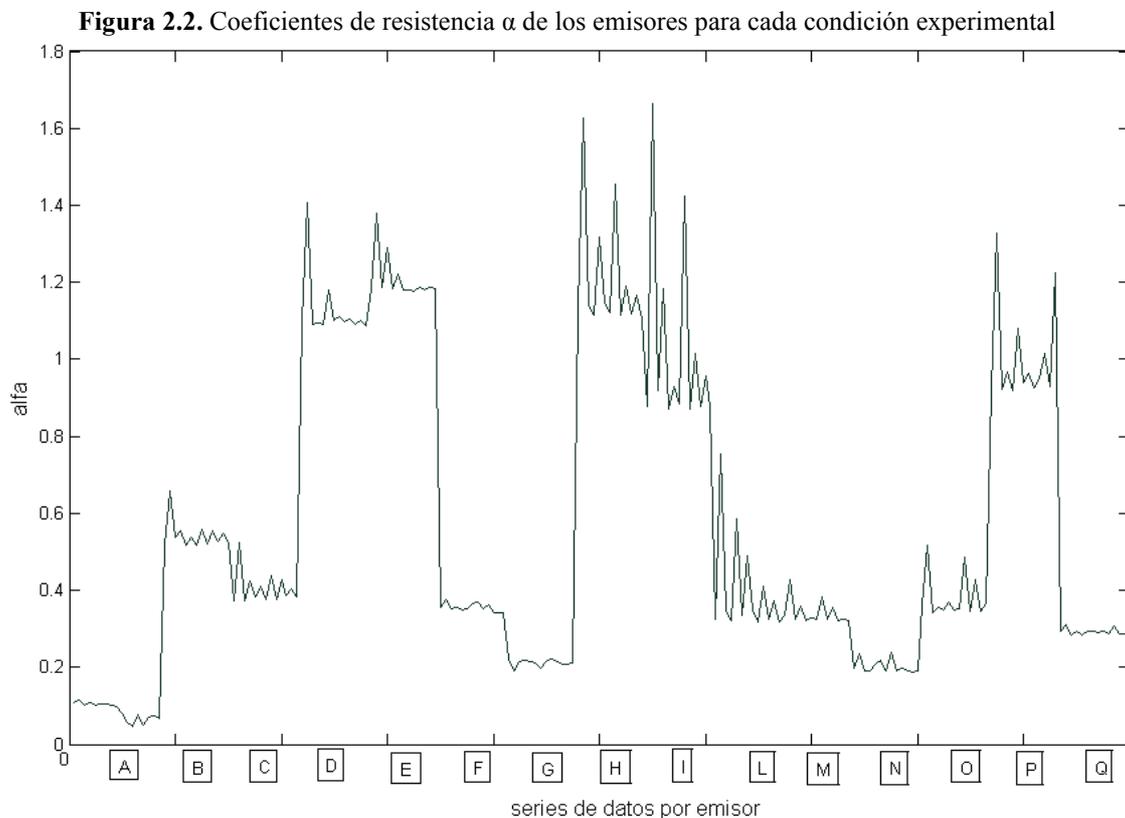
En este apartado, se pretende determinar la combinación óptima de variables de entrada y salida del modelo ANN. Para ello, se analizaron distintas alternativas, atendiendo a dos factores: el output estudiado y la combinación de variables input tenidas en cuenta. Así pues, según la variable de salida, se establecieron dos grandes grupos de modelos: los que entrenaban con valores experimentales de pérdidas singulares h_l por la inserción del emisor, y los que modelaban el coeficiente de resistencia α asociado, calculado teniendo en cuenta la altura cinética correspondiente a cada valor de h_l . Ambos outputs excluían las pérdidas por rozamiento producidas en el seno del emisor. Ello se justifica por dos hechos. En primer lugar, la naturaleza de las pérdidas es distinta. En segundo lugar, al calcular las pérdidas de carga por rozamiento en una tubería nunca se sustrae de la longitud de la misma la longitud correspondiente a los emisores. Se trata de una cuestión puramente conceptual, pues, en la práctica, el efecto de la longitud de todos los emisores es poco significativo.

Tabla 2.1. Caracterización de los emisores ensayados

emisor		imagen del emisor	Rangos de Re testados en la sección de emisor (-)	L_e (m)	D_e (m)	D_t (m)	S_e (m)
nombre	modelo						
A	SIPLAST mono DN16		2934-15719	0.06392	0.01280	0.01300	1.0
B	SIPLAST tandem DN16		2672-23822	0.06789	0.01151	0.01329	0.4
C	RAINBIRD goccialin DN16		2775-19947	0.06822	0.01214	0.01348	0.3
D	RAINBIRD gt-30 DN16		2912-19077	0.03566	0.01149	0.01362	0.3
E	RAINBIRD gocciatub DN16		4080-18706	0.03560	0.01160	0.01378	0.3
F	SIPLAST junior DN16		4197-19551	0.03209	0.01213	0.01378	1.0
G	SIPLAST mono DN20		4940-24386	0.06860	0.01582	0.01690	1.0
H	NETAFIM uniram DN16		4877-25462	0.04369	0.01174	0.01393	0.6
I	NETAFIM ram DN16		3999-25190	0.04204	0.01192	0.01387	0.3
L	NETAFIM ram DN20		3161-26584	0.04284	0.01552	0.01697	0.3
M	NETAFIM tiran DN17		4432-26196	0.07155	0.01362	0.01442	0.5
N	NETAFIM tiran DN20		3374-19254	0.07182	0.01624	0.01725	0.3
O	NETAFIM uniram DN20		3661-20960	0.04496	0.01547	0.01717	0.6
P	NETAFIM ram DN16		6363-20956	0.04231	0.01169	0.01360	0.3
Q	NETAFIM dripline DN12		8301-17176	0.03482	0.00935	0.00976	0.3

Por otra parte, si no se desglosa la longitud de la tubería en la correspondiente a la tubería propiamente dicha y la de los emisores, se comete el error, aunque de magnitud ínfima, de infravalorar las pérdidas por rozamiento, debido al menor diámetro interno del emisor respecto del lateral.

La figura 2.2 recoge los valores de los coeficientes de resistencia α de los emisores, correspondientes a los rangos de Re analizados, manteniendo el orden en que se tomaron las medidas experimentales. Esta figura sólo pretende ilustrar los distintos órdenes de magnitud de los coeficientes α de cada emisor y que estos coeficientes no dependen sólo de las propiedades geométricas de los emisores.



En función de la combinación considerada de inputs, se analizan cuatro tipos de modelo, con dos, tres, cuatro y cinco variables, respectivamente. A continuación, se presenta la tabla 2.2, con las distintas combinaciones de variables input estudiadas.

Una metodología alternativa hubiera podido consistir en un análisis preliminar de la significación relativa de cada variables sobre los outputs h_1 y α . Sin embargo, no se ha seguido este procedimiento porque también se pretendía llevar a cabo un estudio

comparativo de modelos ANN con el modelo existente de regresión, que considera sólo variables geométricas (Provenzano et al., 2005).

Tabla 2.2. Combinaciones de inputs consideradas

ANN de 2 inputs		ANN de 3 inputs	
D_e	D_t	L_e	$D_e D_t$
ANN de 4 inputs			
Re_t	$D_e D_t L_e$	Q_t	$D_e D_t L_e$
Q_t	$S_e D_e D_t$	L_e	$D_e D_t S_e$
ANN de 5 inputs			
D_e	$D_t L_e Re_t S_e$	D_e	$D_t L_e Q_t S_e$

donde D_e y D_t son los diámetros internos de emisor y lateral, respectivamente; L_e es la longitud del emisor; S_e es la separación entre emisores consecutivos; Re_t es el número de Reynolds de la tubería; Q_t es el caudal circulante.

2.2.3. GESTIÓN DE DATOS EXPERIMENTALES

Para cada emisor se disponía de trece condiciones de flujo o puntos. Con estos puntos, se podían plantear diferentes estrategias para evaluar el potencial de predicción de cada ANN propuesta y para comparar los resultados con los correspondientes a los modelos de regresión existentes.

Normalmente, en aplicaciones de redes neuronales, se suele reservar entre un 10 y un 20% de datos para la fase de test. Este porcentaje suele depender de la cantidad total de datos disponibles. Así, en nuestro caso, se reservaron dos puntos por emisor para testar, al tiempo que se utilizaban otros dos puntos por emisor para componer el subconjunto de validación cruzada (entrenamiento 1). Esto supone que se utilizaron un 15.4 % de datos para test y verificación, respectivamente. Conviene tener presente que el criterio seguido no es válido si se pretende desarrollar una herramienta de predicción, pero es útil para establecer una comparativa con los métodos tradicionales de regresión, pues éstos utilizan todos los datos disponibles para derivar la ecuación final. Los conceptos test y verificación o validación cruzada aparecen explicados en el apartado A.6.

Para desarrollar una herramienta para estimar pérdidas de carga singulares, conviene reservar series íntegras de datos de distintos emisores para la fase de test, con el fin de

obtener indicadores objetivos de la calidad del modelo. Así pues, la metodología seguida para desglosar el conjunto total de datos ha consistido en definir distintas combinaciones de emisores para integrar los sets de validación cruzada y test. Para ello, se ha considerado siempre el espectro de valores de α cubierto por cada combinación asignada. Con este procedimiento, se pretende determinar, aproximadamente, el número de emisores, así como la combinación específica de rangos asociados de α que son más adecuados para la definir los subconjuntos de test y verificación. De esta manera, se establecieron 7 tipos de entrenamiento:

- i) dos puntos por cada serie de datos de los emisores A-O para evitar el sobreajuste y dos series de datos íntegras (emisores P y Q) para entrenar (entrenamiento 2)
- ii) 2 emisores para evitar el sobreajuste y dos emisores para test (entrenamientos 3-6)
- iii) 3 emisores para impedir el sobreajuste y dos emisores para test (entrenamientos 7-9)
- iv) 3 emisores para evitar el sobreajuste y 3 emisores para test (entrenamientos 10-14)
- v) 4 emisores para prevenir el sobreajuste y dos emisores para test (entrenamientos 15-19)
- vi) 4 emisores para evitar el sobreajuste y 3 para test (entrenamientos 20,21)
- vii) 5 emisores para prevenir el sobreajuste y 2 para test (entrenamiento 22).

La selección de emisores para cada entrenamiento se halla resumida en la tabla 2.3.

El planteamiento seguido exige los datos de más de un emisor para conformar el subconjunto de verificación. Por tanto, la asignación de los datos de más de 3 emisores para el set de test genera un problema en el proceso de entrenamiento. Esto se debe a que las series de datos que quedan para entrenar la red no son suficientes para hacerlo satisfactoriamente. Así pues, las combinaciones contempladas en la tabla anterior sirvieron para tantear la conformación óptima de los subconjuntos de entrenamiento y verificación.

Atendiendo al espectro de valores α correspondientes a los emisores estudiados, se establecieron dos grandes grupos de emisores: los que presentan un valor pequeño de α (emisores A,B,C,F,G,L,M,N,O,Q) y los que presenta un α grande (emisores D,E,H,I,P), fijando la frontera entre ambos grupos en un valor de α de 0.8. Se ha respetado la

nomenclatura por letras de los emisores propuesta por Provenzano et al. (2005) para facilitar la comparación entre los resultados de ambas partes.

El entrenamiento 1 se ha aplicado a todas las combinaciones de variables input contempladas en la tabla 2.2, así como para las dos posibilidades de variables output mencionadas. Una vez se ha determinado la combinación más adecuada, se ha entrenado esa combinación de variables de acuerdo con los otros 21 entrenamientos propuestos en la tabla 2.3.

Tabla 2.3. Fase de tanteo de estrategias de entrenamiento y test

nº entrenamiento	emisores de verificación	emisores de test
1	puntos 1 y 2 de A hasta Q	puntos 3 y 4 de A hasta Q
2	puntos 1 y 2 de A hasta O	P,Q
3	E,F	P,Q
4	B,C	P,Q
5	B,C	N,O
6	E,F	N,O
7	A,B,E	G,P
8	A,B,E	H,I
9	N,B,E	H,I
10	N,B,E	H,I,O
11	N,B,E	C,G,L
12	B,C,F	L,M,O
13	N,O,P	G,I,L
14	H,I,G	D,E,N
15	B,C,D,E	I,L
16	B,C,D,E	M,O
17	B,C,D,E	H,I
18	B,C,D,E	G,P
19	M,N,D,E	L,I
20	N,B,E,I	H,O,P
21	B,C,D,E	H,L,P
22	B,C,D,E,O	I,L

Después, cuando ya se ha encontrado la combinación óptima de verificación, se ha llevado a cabo un procedimiento ‘leave one out’ para evaluar el potencial de predicción de las ANNs.

Dicho método consiste en reservar, cada vez, una única serie de datos (en este caso los datos de un emisor) para test y entrenar con el resto (descontando los que se utilizan para evitar el sobreajuste). De tal manera, si disponemos de los datos de 15 emisores y

se determina que hacen falta x para la validación cruzada, el procedimiento ‘leave one out’ requiere $15-x$ procesos de entrenamiento y test.

2.2.4. PROPIEDADES DE LAS REDES NEURONALES UTILIZADAS E IMPLEMENTACIÓN EN *MATLAB*

En primera instancia se utilizó el paquete para cálculo de redes neuronales que ofrece el programa *Matlab*, el *Neural Network Toolbox*. Pero, durante 2008, se repitieron todos los cálculos mediante un programa implementado con *Matlab*, lo que posibilitó la automatización de los mismos. Dado el volumen de resultados, se ha optado por presentar únicamente los más recientes, pues son más fiables por el hecho de haber considerado un mayor número de repeticiones de cada entrenamiento (10) que en la primera etapa de cálculo, donde sólo se utilizaron 5, como se verá en el apartado 2.2.4.2.1.

2.2.4.1. Propiedades de la ANN

2.2.4.1.1. Modelo neuronal

La configuración de las neuronas y el cálculo del potencial post sináptico (PSP), ver apartado A.1.2 del anejo A, siguen el modelo propuesto por Haykin (1999), representado en la figura 2.3. Aquí,

$$v_k = \sum_{j=1}^n w_{kj} x_j + b_k \quad (2.3)$$

$$y_k = \varphi(v_k) \quad (2.4)$$

donde x_j es la señal de entrada, w_{kj} es el peso sináptico de la neurona k , v_k es la combinación lineal de señales, b_k es el umbral, y_k es el valor salida de la neurona y $\varphi(\cdot)$ es la función de activación o transferencia.

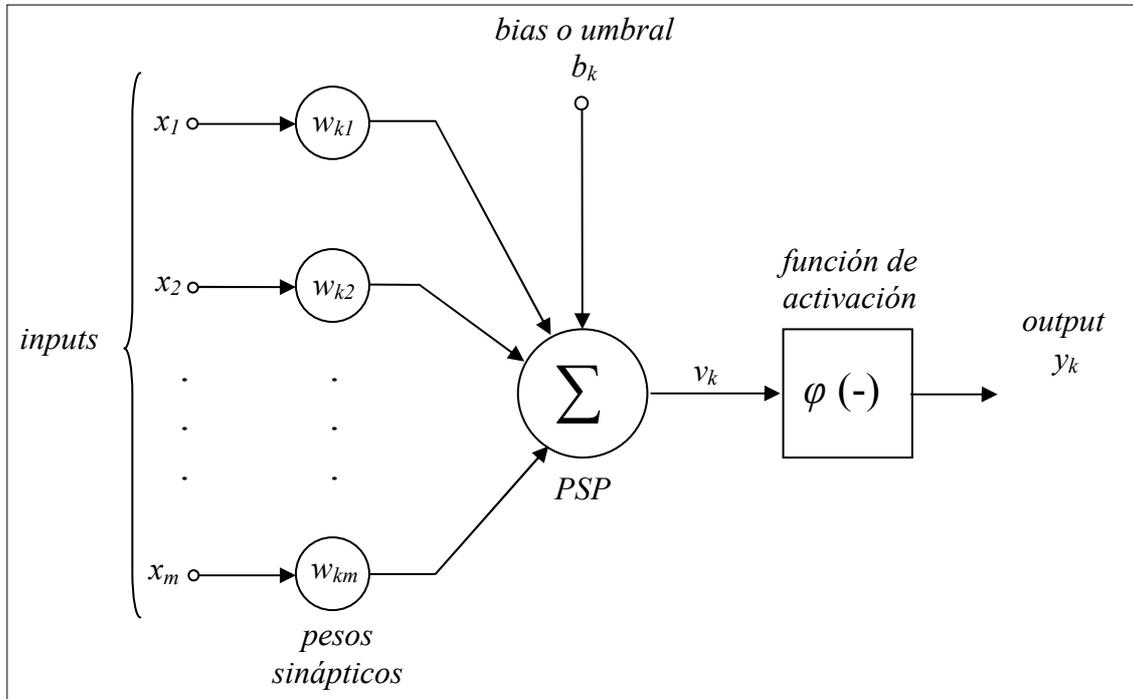
La función tangente hiperbólica (tansig) se escogió como función de activación para todas las neuronas ocultas de la red, lo cual constituye una práctica habitual (Demuth y Beale, 2003),

$$\varphi(l) = \frac{2}{1 + e^{-2l}} - 1 \quad (2.5)$$

Dicha función es adecuada porque no presenta problemas cuando se calcula su derivada a la hora de aplicar el algoritmo de aprendizaje. Por otra parte, se prefería tener un

intervalo de valores de activación entre -1 y 1 y considerar también valores negativos. Para la neurona de la capa de salida se escogió la función de activación lineal para evitar una salida de la red forzosamente truncada, como consecuencia del uso de funciones de activación acotadas, ver apartado A.1.3 del anejo A.

Figura 2.3. Esquema de procesado de las señales entre neuronas



Las redes utilizadas fueron de tipo feed-forward con retropropagación del error (o perceptron multinivel). Así, la señal se propaga capa a capa hacia delante hasta que se obtiene un valor de salida, que se compara con el valor respuesta deseado. Posteriormente, el error se utiliza como input para retroalimentar la red y ajustar los pesos capa a capa hacia atrás de acuerdo con el EBLA, ver apartado A.4.2.

2.2.4.1.2. Algoritmo de entrenamiento

Los problemas de minimización de las redes neuronales están a menudo mal condicionados. En estos casos, el algoritmo de aprendizaje Levenberg-Marquardt (ver apartado A.5.3) suele ser una buena elección. Al igual que los métodos quasi-Newton, este algoritmo se diseñó para alcanzar velocidades de entrenamiento de segundo orden sin tener que calcular el Hessiano. Aquí el Hessiano y el gradiente se calculan como:

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} \quad (2.6)$$

$$\mathbf{g} = \mathbf{J}^T \mathbf{e} \quad (2.7)$$

y en cada iteración se actualiza la siguiente fórmula

$$x_{k+1} = x_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T e_k \quad (2.8)$$

donde \mathbf{H} es el Hessiano, \mathbf{g} es el gradiente, μ gobierna el tamaño de cada paso hacia el mínimo, \mathbf{I} es la matriz identidad, \mathbf{J} es el Jacobiano, que contiene derivadas primeras de los errores respecto a pesos y umbrales, y e es un vector con los errores de la red.

En la expresión anterior, el primer término del corchete representa el incremento basado en la hipótesis lineal, y el segundo, un salto en la dirección del gradiente cambiado de signo. La matriz jacobiana puede calcularse mediante una técnica estándar de retropropagación mucho menos compleja de lo que sería el cálculo del Hessiano. Cuando μ vale cero, nos encontramos ante el método de Newton, utilizando la aproximación del Hessiano. Cuando μ es grande, la fórmula se convierte en la del gradiente conjugado, con un tamaño de paso pequeño. Se trata pues de un parámetro de control que va variando a lo largo de las iteraciones, y determina la importancia de cada una de las dos componentes. (Hagan y Menhaj, 1994; Hagan et al., 1996)

Este algoritmo permite llevar a cabo un rápido proceso de entrenamiento de redes feed forward de tamaño medio (donde el tamaño se mide por el número de pesos a determinar). Además, *Matlab* ofrece una implementación del mismo muy eficiente.

2.2.4.1.3. Criterio de parada

Se utilizó la técnica de la parada adelantada o ‘early stopping’ como criterio para finalizar el entrenamiento de la red. De esta manera, los datos de entrenamiento se dividieron en dos grupos: uno para el entrenamiento propiamente dicho, donde se establecían los pesos, y otro para verificación o validación-cruzada, ver apartado A.6.

El error calculado respecto a un set independiente de datos presenta, en general, un descenso al principio del proceso de aprendizaje seguido de un incremento cuando la red comienza a sobreajustar los datos del set de entrenamiento (Bishop, 1997). De acuerdo con este método, mientras el valor del indicador escogido, en nuestro caso el MSE (error medio cuadrático), del set de validación cruzada es menor que el de la iteración previa, el entrenamiento continúa. En caso contrario, se para el entrenamiento. Es decir, el entrenamiento se aborta cuando el error de verificación alcanza un mínimo.

En este punto la red habrá alcanzado su capacidad de generalización óptima. Si no se detiene, la red queda sobreentrenada y, a pesar de que el error de entrenamiento continúa descendiendo, el comportamiento global de la red se deteriora. Otros criterios de parada adicionales del proceso de entrenamiento que se han tenido en cuenta se enumeran a continuación.

- Se alcanza el número máximo de iteraciones o *maximum number of epochs to train*.
- Se sobrepasa el tiempo máximo de entrenamiento o *maximum time to train*. En nuestro caso, este parámetro no es restrictivo, pues se ha establecido a priori una duración ilimitada inf.
- Se alcanza un valor de error (MSE) igual a *performance goal*.
- El gradiente del error cae por debajo de *minimum performance gradient*.

Los valores de estos parámetros se hallan resumidos más adelante, en la sección 2.2.4.2.2.

2.2.4.2. Implementación de las redes.

Como se ha comentado, los cálculos que se presentan fueron obtenidos aplicando un programa implementado con el *Matlab Editor*.

2.2.4.2.1. Arquitecturas analizadas. Número de repeticiones

Según Isasi-Viñuela y Galván-León (2004), el número de capas ocultas y el número de neuronas de éstas deben ser elegidas por el diseñador y no existe una regla o método que determine el número óptimo de neuronas ocultas para resolver un problema dado. Así, en la mayor parte de las aplicaciones prácticas, estos parámetros se determinan por prueba y error. Además, cabe tener en cuenta que, si bien el número de neuronas ocultas puede influir en el comportamiento de la red (capacidad de generalización), en el caso del perceptrón multicapa, generalmente, el número de neuronas ocultas no es un parámetro significativo, pues dado un problema, pueden existir una gran cantidad de arquitecturas capaces de resolver de manera adecuada dicho problema. En este sentido, añadir o eliminar una neurona oculta no influye de manera significativa en la capacidad

de la red. Sin embargo, sí existe un subconjunto de arquitecturas con un número similar de neuronas ocultas dotadas con un potencial de generalización óptimo, y éste se determina en base a consideraciones subjetivas.

Atendiendo al razonamiento expuesto en el párrafo anterior, para cada combinación contemplada en la tabla 2.2, se definieron una serie de arquitecturas que se resumen en la tabla 2.4, donde están expresadas como n° de neuronas de la capa de entrada – n° de neuronas de la (primera) capa oculta – n° de neuronas de la segunda capa oculta (en su caso) – n° de neuronas de la capa de salida.

Para cada arquitectura se calcularon los errores de los conjuntos de entrenamiento, validación cruzada y test. Así, se seleccionó la arquitectura con menor error en el set de validación cruzada. Para llevar a cabo la comparativa entre los modelos con diferente combinación de inputs, se seleccionó, para cada grupo de x-inputs, la red correspondiente a la arquitectura óptima. En la segunda fase del estudio, se analizaron sólo arquitecturas con una capa oculta, con 1,2...15 neuronas, pues se pretendía asegurar una mayor capacidad de generalización.

Tabla 2.4. Arquitecturas estudiadas para cada combinación de variables input

x = 2 hasta 5	
x - 1 - 1	x - 1 - 1 - 1
x - 5 - 1	x - 5 - 5 - 1
x - 10 - 1	x - 10 - 10 - 1
x - 15 - 1	x - 15 - 15 - 1
x - 20 - 1	x - 20 - 20 - 1
x - 25 - 1	x - 25 - 25 - 1
x - 30 - 1	x - 30 - 30 - 1
x - 50 - 1	x - 50 - 50 - 1

Estas arquitecturas fueron entrenadas y testadas 10 veces para evitar dentro de lo posible el efecto derivado de la asignación inicial aleatoria de los pesos, característica de los programas que permiten aplicar ANNs, ver apartado A.4.4 del anejo A. La repetición que proporcionaba el menor error de validación era seleccionada para la comparativa entre arquitecturas.

Por otra parte, dado el gran número de arquitecturas y combinaciones de entrenamiento contempladas, los ordenadores disponibles no permitían realizar los cálculos con un número de repeticiones superior a 10, pues hubieran consumido para ello un tiempo abusivo.

2.2.4.2.2. Parámetros de entrenamiento

En este caso, sólo se establecieron los siguientes parámetros: el tipo de red (Multilayer Perceptron), el algoritmo de entrenamiento (Levenberg-Marquardt), la función de error (MSE) y la función de activación (función tangente hiperbólica en las neuronas ocultas y función lineal en la neurona de la capa de salida). Los parámetros relativos a la aplicación del algoritmo Levenberg-Marquardt fueron los que *Matlab* recomienda por defecto, pues aseguran un avance seguro hacia el mínimo de la superficie de error de la performance function, aunque el proceso se pueda ver ralentizado (tabla 2.5).

Tabla 2.5. Parámetros elegidos para el proceso de entrenamiento

<i>performance function</i>	MSE
<i>maximum number of epochs to train</i>	100
<i>performance goal</i>	0
<i>maximum validation failures</i>	5
<i>minimum performance gradient</i>	1E-10
<i>initial μ</i>	0.001
<i>μ decrease factor</i>	0.1
<i>μ increase factor</i>	10
<i>maximum μ</i>	1E+10
<i>maximum time to train</i>	inf

La función de error o performance function utilizada en el algoritmo de entrenamiento (búsqueda de un mínimo en la superficie de error) ha sido el MSE o error medio cuadrático. El parámetro *initial μ* es el valor inicial asignado para μ en la fórmula de Levenberg-Marquardt (ecuación 2.8). Este valor es multiplicado por *μ decrease factor*, cuando la función de error se reduce en una época (tras la presentación completa de la familia de patrones de entrenamiento, recuérdese que el algoritmo Levenberg-Marquardt se implementa por bloques, ver anejo A), o por *μ increase factor*, cuando la función de error se vería incrementada en una época. El algoritmo se detiene si μ alcanza un valor superior a *maximum μ* .

Los vectores de validación se utilizan para adelantar la parada del entrenamiento cuando el error de verificación empeora o permanece igual durante un número de patrones de entrenamiento igual a *maximum validation failures* a contar desde la última vez que se había reducido.

2.2.5. INDICADORES DE CALIDAD DEL COMPORTAMIENTO DE LAS REDES

La función de error seleccionada fue el error medio cuadrático o *mean squared error* (MSE), definido como

$$MSE = \frac{\sum_{i=1}^n (y_{m_i} - y_{e_i})^2}{n} \quad (2.9)$$

donde y_m es la salida del modelo e y_e es la respuesta deseada. Se eligió esta función debido a sus propiedades estadísticas y porque se trata de un valor mejor comprendido que otros indicadores. Se trata de una función no negativa, diferenciable y que penaliza errores grandes frente a pequeños.

Además del citado MSE, se calculó el *performance index* c , propuesto por Camargo y Sentelhas (1997), definido como

$$c = d \cdot r \quad (2.10)$$

donde

$$r = \frac{\text{cov}(y_e, y_m)}{\sigma_e \sigma_m} \quad (2.11)$$

$$d = 1 - \frac{\sum_{i=1}^n (y_{m_i} - y_{e_i})^2}{\sum_{i=1}^n (|y_{m_i} - \bar{y}_e| + |y_{e_i} - \bar{y}_e|)^2} \quad (2.12)$$

d es el coeficiente de ajuste propuesto por Willmott (1981), r es el coeficiente de correlación, y_e e y_m son los vectores de valores esperados y estimados, respectivamente, σ_e y σ_m son las desviaciones estándar correspondientes, \bar{y}_e es la media de los valores esperados. c es un valor adimensional con rango entre 0 y 1, donde 1 implica un ajuste perfecto.

La figura 2.4 representa las etapas claves seguidas en la generación de los modelos ANN programados en *Matlab* que han sido utilizados en este capítulo. Los pasos

seguidos en la aplicación de las redes pueden resumirse en tres etapas. En primer lugar se determina la mejor combinación de inputs-output y se compara su rendimiento con el modelo existente de regresión (16 combinaciones: 8 combinaciones de inputs x 2 outputs). A continuación, para esta combinación, se determina el número de emisores y los valores α más adecuados para componer el subgrupo de verificación (21 combinaciones, tabla 2.3). Finalmente, se llevan a cabo varios procesos ‘leave one out’ para proponer un modelo válido con potencial real de predicción (120 combinaciones, apartado B.3.1).

Figura 2.4. Esquema resumen de los procesos implementados en *Matlab* para el estudio de hl

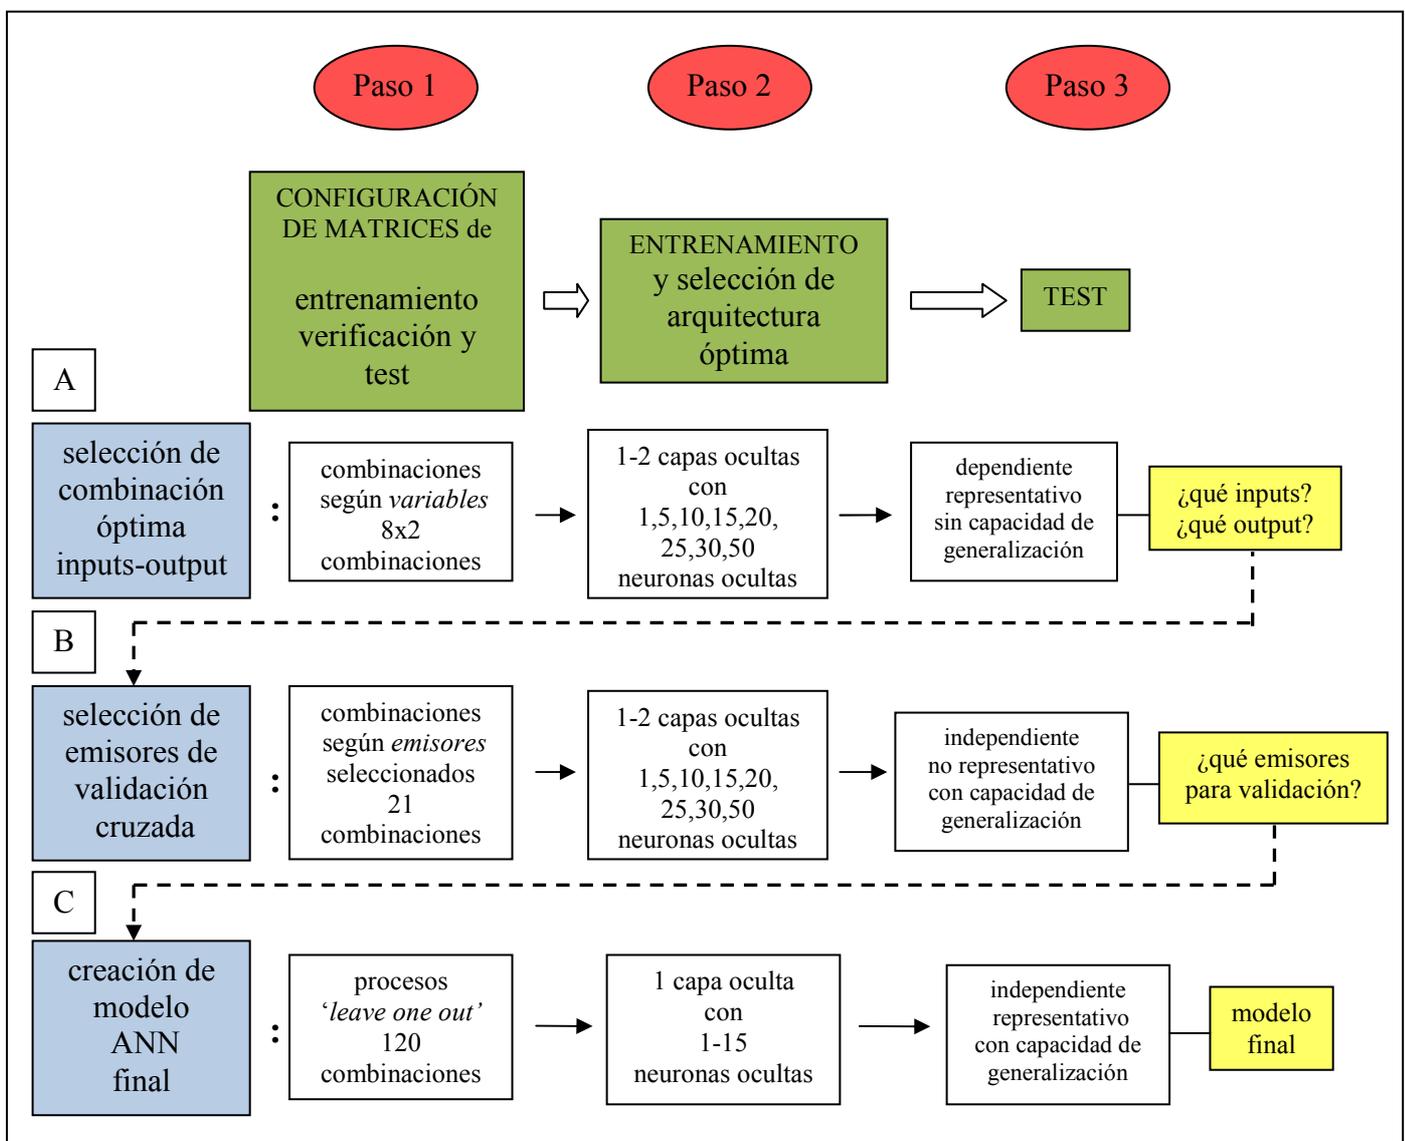
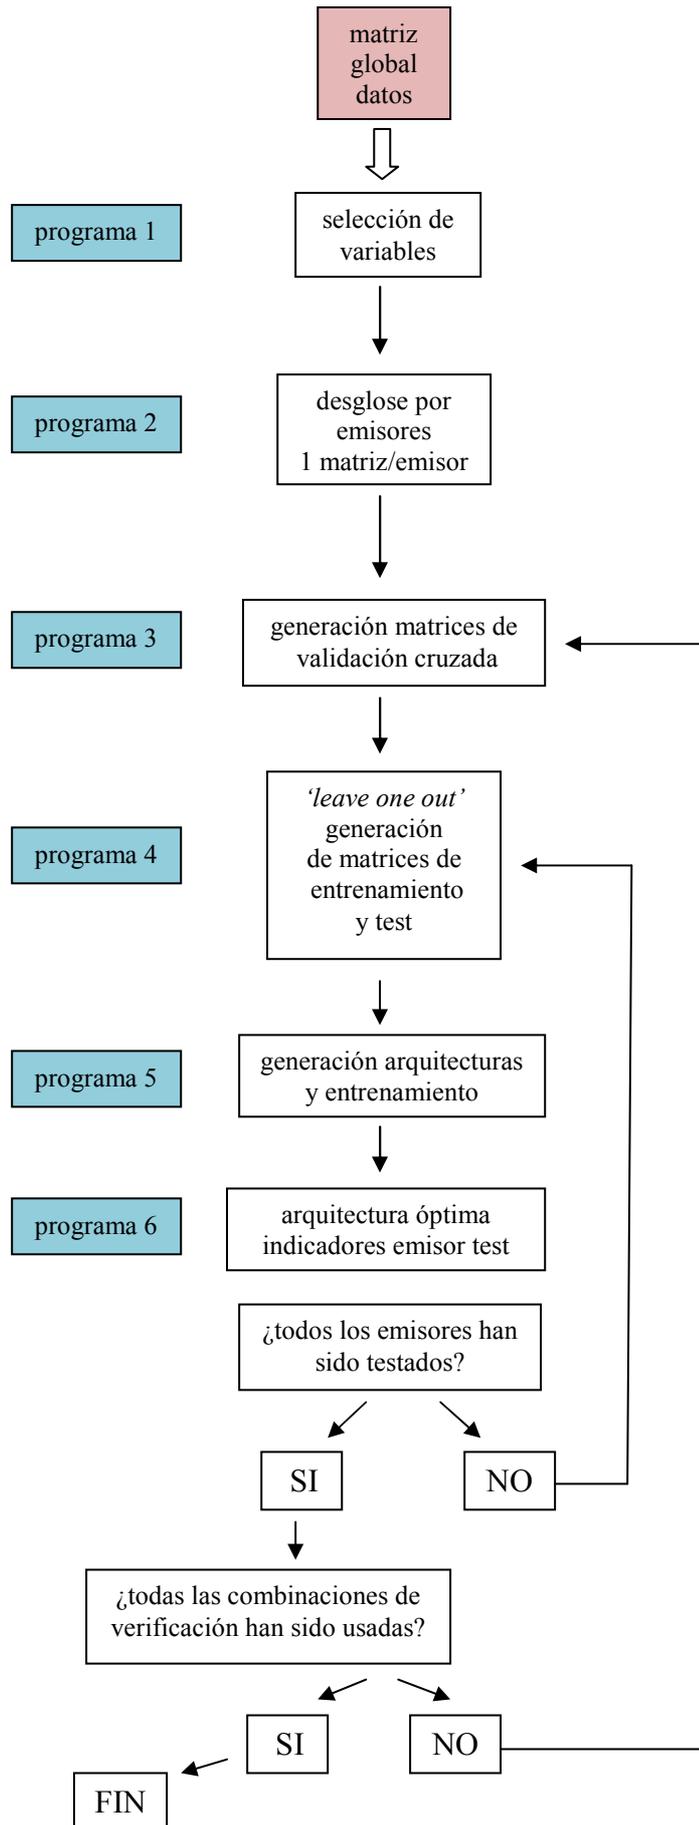


Figura 2.5. Esquema de funcionamiento del programa implementado para generar el modelo ANN final



En términos de programación, los pasos fundamentales consisten en crear las matrices de datos que se utilizarán posteriormente para entrenar, verificar y testar; en establecer una serie de arquitecturas, llevar a cabo los correspondientes procesos de entrenamiento utilizando las matrices anteriores y determinar la configuración óptima; y en testar dichas configuraciones y analizar los rendimientos obtenidos para responder a una cuestión concreta. Dicha cuestión varía en cada apartado de este capítulo, como se acaba de comentar.

La figura 2.5 resume las acciones más importantes que se han manejado para ejecutar en *Matlab* el modelo final para predecir h_1 . Dicho esquema no incluye los programas secundarios que han sido necesarios para definir y acondicionar los sistemas de matrices. Estos procesos paralelos han sido indispensables para garantizar un correcto funcionamiento de bucles y cálculo de funciones, y no se han incluido aquí para facilitar la comprensión global del proceso.

2.3. Resultados y discusión

En todos los casos el criterio de parada más restrictivo fue el de la parada adelantada.

2.3.1. SELECCIÓN DE LAS VARIABLES DEL MODELO

Como se ha mencionado en el apartado de materiales y métodos, se han estudiado dos grandes grupos de modelos, según el output considerado (valores experimentales de h_1 o valores asociados del coeficiente de resistencia α). En primera instancia, cada ANN de x -inputs, de acuerdo con las arquitecturas contempladas en la tabla 2.4, se sometió al entrenamiento 1. Para poder llevar a cabo la comparativa, se utilizaron los valores de velocidad del agua para transformar los valores estimados de α en valores de $h_1(\alpha)$. A continuación, en la tabla 2.6, se muestran los indicadores de rendimiento de las arquitecturas óptimas para cada combinación de inputs.

El modelo de regresión (Provenzano et al., 2005) corresponde a la expresión 1.13. En el anejo B, se puede encontrar los errores de la repetición óptima asociados a los sets de entrenamiento, validación cruzada y test de todas las arquitecturas propuestas en la tabla 2.4. En gris aparece el menor error de verificación.

Tabla 2.6. Indicadores de rendimiento de los modelos óptimos obtenidos con el entrenamiento 1

output	h_1		$h_1(\alpha)$	
n° inputs	2 inputs	3 inputs	2 inputs	3 inputs
inputs	$D_e D_t$	$L_e D_e D_t$	$D_e D_t$	$L_e D_e D_t$
arquitectura	2 - 5 - 5 - 1	3 - 10 - 1	2 - 20 - 20 - 1	3 - 15 - 15 - 1
c (-)	0.54246	0.52431	0.90401	0.87476
MSE (m^2)	3.7893E-04	4.0402E-04	9.7120E-05	1.3079E-04
n° inputs	4 inputs		4 inputs	
inputs	$Re_t D_e D_t L_e$	$Q_t D_e D_t L_e$	$Re_t D_e D_t L_e$	$Q_t D_e D_t L_e$
arquitectura	4 - 15 - 15 - 1	4 - 10 - 10 - 1	4 - 15 - 15 - 1	4 - 20 - 20 - 1
c (-)	0.99824	0.99981	0.90074	0.90102
MSE (m^2)	1.7569E-06	1.8652E-07	1.1009E-04	1.0941E-04
inputs	$Q_t D_e D_t S_e$	$L_e D_e D_t S_e$	$Q_t D_e D_t S_e$	$L_e D_e D_t S_e$
arquitectura	4 - 15 - 15 - 1	4 - 5 - 1	4 - 25 - 25 - 1	4 - 15 - 15 - 1
c (-)	0.99975	0.52516	0.90301	0.90068
MSE (m^2)	2.5900E-07	3.9498E-04	1.0803E-04	9.8549E-05
n° inputs	5 inputs		5 inputs	
inputs	$D_e D_t L_e Q_t S_e$	$D_e D_t L_e Re_t S_e$	$D_e D_t L_e Q_t S_e$	$D_e D_t L_e Re_t S_e$
arquitectura	5 - 10 - 10 - 1	5 - 10 - 10 - 1	5 - 20 - 20 - 1	5 - 20 - 20 - 1
c (-)	0.99750	0.99977	0.90311	0.90227
MSE (m^2)	2.4533E-06	2.2675E-07	1.0740E-04	1.0842E-04
regresión $h_1(\alpha)$				
inputs	$D_e D_t$			
c (-)	0.83150			
MSE (m^2)	1.9303E-04			

2.3.1.1. h_1 como variable de salida

Dentro de los modelos ANN que consideran exclusivamente variables geométricas, la mejor combinación corresponde al modelo con los inputs D_e y D_t ($c=0.542$) frente a las combinaciones D_e , D_t , L_e ($c=0.524$) y D_e , D_t , L_e y S_e ($c=0.525$), lo que concuerda con los resultados obtenidos por Provenzano y Pumo (2004) y Provenzano et al. (2005). Esto pone de relieve la mayor influencia de las variables D_e y D_t sobre h_1 que la de L_e y S_e . Por otra parte, la introducción en el modelo de un input de flujo (Q_t o Re_t) aumenta el rendimiento del modelo, pasándose a valores de c cercanos a 1. Los modelos de 4 inputs con parámetros de flujo son preferibles a los de 5 inputs, pues presentan rendimientos iguales o mayores y precisan una variable menos. Así, basta con elegir una variable entre S_e y L_e . El modelo con mejores indicadores considera D_e , D_t , L_e y Q_t ($c=0.99981$). Estos resultados demuestran la clara influencia de los parámetros de flujo

sobre h_1 . Asimismo, Q_t y Re_t parecen tener la misma significación en la determinación de h_1 .

Las arquitecturas óptimas de los modelos con parámetros de flujo como inputs presentan dos capas ocultas con 10 y 15 neuronas. Dichas configuraciones son complejas y presentan baja capacidad de generalización, aunque este aspecto es secundario en este apartado, dado que el set de test no es independiente del de entrenamiento.

2.3.1.2. α como variable de salida

Todos los modelos presentan valores de c alrededor de 0.9, lo que pone de manifiesto que basta considerar inputs geométricos, más en concreto, sólo D_e y D_t , para modelar α . Este hecho vuelve a concordar con los resultados de Provenzano y Pumo (2004) y Provenzano et al. (2005). Todas las arquitecturas óptimas presentan dos capas ocultas con 15, 20 ó 25 neuronas. Al igual que en el apartado anterior, este aspecto es secundario, dada la estrategia de entrenamiento-test utilizada.

La tabla 2.7 presenta los indicadores de calidad de los modelos ANN utilizados para calcular $h_1(\alpha)$ en la tabla 2.6. Como podía preverse, los rendimientos mejoran respecto a los asociados a $h_1(\alpha)$, ya que las ANNs se han entrenado con valores de α . En este caso, sí se aprecian diferencias, aunque sólo sean del 2-3%, entre los c de los modelos que contemplan sólo variables de entrada geométricas y modelos que consideran, además, algún parámetro de flujo, en concordancia con el apartado anterior. Sin embargo, puede afirmarse que α depende fundamentalmente de variables geométricas. Los valores de MSE aumentan en general respecto a los modelos $h_1(\alpha)$, debido a que el orden de magnitud de α es mayor que el de h_1 .

2.3.1.3. Comparativa general.

Comparando modelos análogos, concretamente los que consideran D_e y D_t como inputs y α como output, se comprueba que las ANNs ofrecen mejor comportamiento que la regresión ($c=0.904$ vs $c=0.832$, para $h_1(\alpha)$, y $c=0.976$ vs $c=0.915$, para α). En la figura 2.6 se aprecia cómo los puntos correspondientes al modelo ANN se acercan más que los

del modelo de regresión a la línea de ajuste perfecto, con alguna excepción para valores altos de h_1 . Este hecho cabe atribuirlo a la mayor capacidad de vinculación input-output de las redes neuronales sobre las técnicas estadísticas tradicionales.

Tabla 2.7. Indicadores de rendimiento de los modelos óptimos obtenidos con el entrenamiento 1 para estimar α

output	α	
n° inputs	<i>2 inputs</i>	<i>3 inputs</i>
inputs	$D_e D_t$	$L_e D_e D_t$
arquitectura	2 - 20 - 20 - 1	3 - 15 - 15 - 1
c (-)	0.9762	0.9657
MSE (m ²)	8.4273E-03	1.0177E-02
n° inputs	<i>4 inputs</i>	
inputs	$Re_t D_e D_t L_e$	$Q_t D_e D_t L_e$
arquitectura	4 - 15 - 15 - 1	4 - 20 - 20 - 1
c (-)	0.9995	0.9996
MSE (m ²)	9.5512E-05	7.8422E-05
inputs	$Q_t S_e D_e D_t$	$L_e D_e D_t S_e$
arquitectura	4 - 25 - 25 - 1	4 - 15 - 15 - 1
c (-)	0.9989	0.9696
MSE (m ²)	2.2799E-04	9.8377E-03
n° inputs	<i>5 inputs</i>	
inputs	$D_e D_t L_e Q_t S_e$	$D_e D_t L_e Re_t S_e$
arquitectura	5 - 20 - 20 - 1	5 - 20 - 20 - 1
c (-)	0.9994	0.9994
MSE (m ²)	1.2500E-04	1.3050E-04
	regresión α	
inputs	$D_e D_t$	
c (-)	0.9146	
MSE (m ²)	1.8129E-02	

La tabla 2.6 revela que los valores experimentales de h_1 son más apropiados que los coeficientes α como variable output cuando se consideran parámetros de flujo como inputs. Por el contrario, los valores de α son más adecuados cuando sólo se consideran variables geométricas. Este hecho cabría atribuirlo a la definición de α , cuyo cálculo implica la sustracción del efecto producido por la altura cinética sobre h_1 . Como consecuencia de ello, los valores de α son más geoméricamente dependientes que los valores de h_1 .

Figura 2.6. Modelo ANN de 2 inputs vs modelo de regresión (Provenzano et al., 2005)

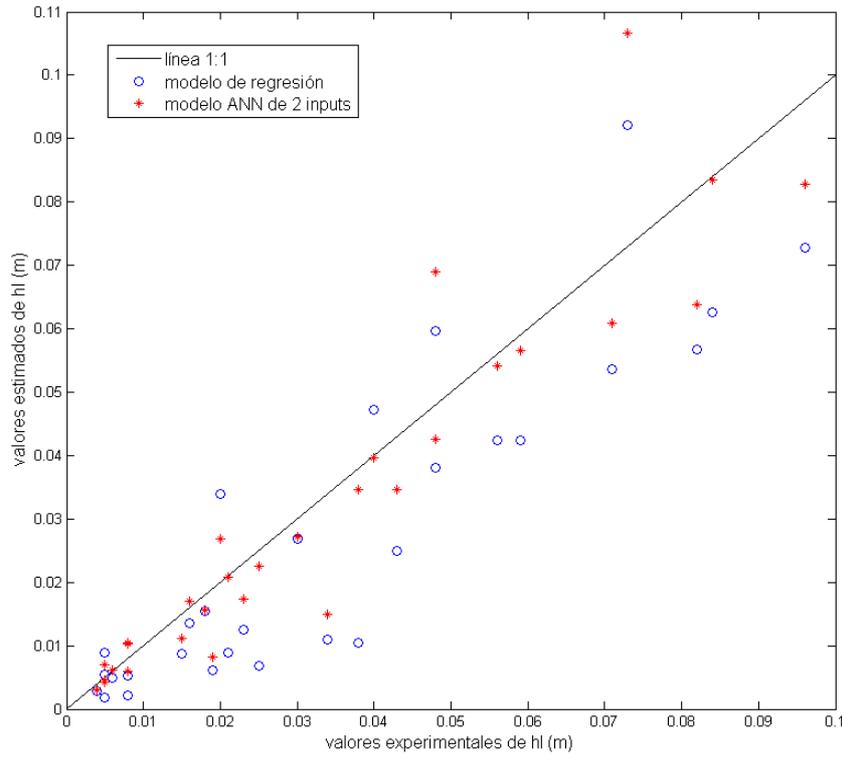
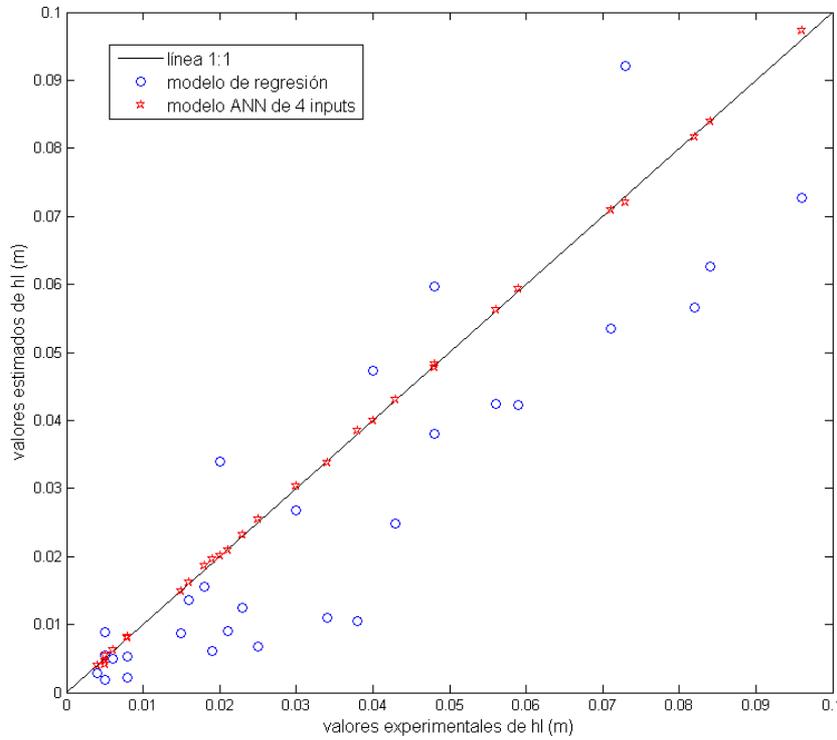


Figura 2.7. Modelo ANN de 4 inputs vs modelo de regresión (Provenzano et al., 2005)



El modelo con mejor rendimiento corresponde a la relación inputs-output $D_e D_t L_e Q_t - h_1$. La mejora sustancial obtenida parece estar en relación con una clara dependencia de

los valores de h_1 con parámetros de flujo, así como con la ya citada mejor capacidad de vinculación de datos de las ANN.

En la figura 2.7, se comparan las predicciones del modelo de regresión con el modelo ANN óptimo, el de 4 inputs. Llama la atención la calidad del ajuste de éste último, con todos los puntos prácticamente sobre la línea de ajuste perfecto. La exactitud de este ajuste se halla vinculada al comportamiento de las ANNs cuando se somete al entrenamiento planteado, donde el set de test no es completamente independiente del de entrenamiento, pues está compuesto por puntos pertenecientes a emisores que también han sido considerados en la fase de entrenamiento. Como se ha comentado, esta estrategia no es válida para evaluar el potencial de predicción de un modelo, pero sí lo es para llevar a cabo una comparativa con los modelos de regresión, que no utilizan sets de test independientes. Por otra parte, esta estrategia también es adecuada para determinar la combinación óptima de variables a considerar, porque, aunque no es completamente independiente, el subconjunto de test sí es representativo del total. Así pues, los resultados de esta sección demuestran la conveniencia de considerar como inputs parámetros de flujo en los modelos para predicción de h_1 .

2.3.2. COMPOSICIÓN DEL SUBGRUPO DE VERIFICACIÓN

En este apartado, se pretende dilucidar de manera orientativa la composición que debe presentar un set de verificación para llevar a cabo un entrenamiento adecuado. Concretamente, con esta fase de tanteo, se desea determinar el número de emisores necesarios para dicho set, así como el espectro de valores de α que debe cubrir el mismo. Para ello, el modelo óptimo del apartado anterior, el modelo de 4 inputs D_e , D_t , L_e y Q_t , se ha sometido a los entrenamientos 2-22 de la tabla 2.3. La tabla 2.8 presenta los indicadores de rendimiento de las arquitecturas óptimas para dichos entrenamientos. Nuevamente, los errores de la repetición óptima referidos a los sets de entrenamiento, verificación y test de todas las arquitecturas analizadas se hallan en el anejo B. En gris se ha marcado el menor error de validación cruzada.

Conviene recordar que estas estrategias de tanteo se establecieron buscando distintas combinaciones entre los espectros de α cubiertos por el set de validación y por el de test. Por ello, no existe homogeneidad en el número de entrenamientos de cada tipo (que

consideran un mismo número de emisores para validar y testar). De esta manera, los indicadores de estas redes no son representativos del total, pues sólo se testa cada vez un número reducido de emisores. Sin embargo, esta metodología permite vaticinar el número de emisores mínimo, así como los espectros del coeficiente de resistencia que son necesarios para entrenar adecuadamente un modelo ANN para estimar h_l . Por otra parte, el coste de cálculo de todas las combinaciones de verificación posibles aplicando un procedimiento ‘leave one out’ hubiera resultado excesivo, y más si añadimos el hecho de que cada arquitectura debe entrenarse 10 veces para evitar el efecto de la asignación inicial aleatoria de pesos.

Tabla 2.8. Índices de rendimiento de arquitecturas óptimas obtenidos bajo los entrenamientos 2-22

ANN de 4 inputs (Q_t , D_e , D_b , L_e)							
entrenamiento	2	3	4	5	6	7	8
arquitectura	4 - 10 - 10 - 1	4 - 15 - 1	4 - 5 - 1	4 - 15 - 1	4 - 1 - 1	4 - 5 - 5 - 1	4 - 25 - 1
c (-)	0.208	0.212	0.034	0.166	0.643	0.994	0.965
MSE (m^2)	2.820E-02	1.839E-02	2.757E-03	4.321E-04	9.291E-05	8.774E-06	4.992E-05
verificación	2 puntos A-O	E,F	B,C	B,C	E,F	A,B,E	A,B,E
test	P,Q	P,Q	P,Q	N,O	N,O	G,P	H,I
entrenamiento	9	10	11	12	13	14	15
arquitectura	4 - 5 - 5 - 1	4 - 5 - 5 - 1	4 - 5 - 5 - 1	4 - 5 - 5 - 1	4 - 10 - 1	4 - 1 - 1	4 - 20 - 1
c (-)	0.939	0.583	0.797	0.456	0.771	0.929	0.789
MSE (m^2)	7.440E-05	5.142E-04	6.892E-05	1.406E-03	4.965E-04	1.213E-04	3.315E-04
verificación	N,B,E	N,B,E	N,B,E	B,C,F	N,O,P	H,I,G	B,C,D,E
test	H,I	H,I,O	C,G,L	L,M,O	G,I,L	D,E,N	I,L
entrenamiento	16	17	18	19	20	21	22
arquitectura	4 - 10 - 1	4 - 15 - 1	4 - 25 - 1	4 - 1 - 1	4 - 10 - 1	4 - 5 - 1	4 - 15 - 1
c (-)	0.685	0.833	0.907	0.937	0.438	0.966	0.859
MSE (m^2)	1.089E-04	2.803E-04	1.852E-04	1.070E-04	7.186E-04	3.988E-05	3.251E-04
verificación	B,C,D,E	B,C,D,E	B,C,D,E	M,N,D,E	N,B,E,I	B,C,D,E	B,C,D,E,O
test	M,O	H,I	G,P	L,I	H,O,P	H,L,P	L,I

Los modelos que consideran 2 emisores para verificación y test (entrenamientos 3-6) presentan un c medio de 0.264. Los que consideran 3 emisores para validar (entrenamientos 7-14) presentan un c medio de 0.966 cuando se testan sobre sets de 2 emisores (entrenamientos 7-9), y un c medio de 0.707 cuando se testan sobre sets de 3 emisores (entrenamientos 10-14). De igual manera, aquellos que consideran 4 emisores para validar (entrenamientos 15-21), presentan un c medio de 0.8302 cuando el set de test consta de 2 emisores (entrenamientos 15-19), y un c medio de 0.702 cuando el set

de test consta de 3 emisores (entrenamientos 20-21). El entrenamiento 22 considera 5 emisores para validar y 2 para testar, con un $c=0.859$. Estos indicadores parecen mostrar que la calidad del rendimiento del modelo depende de la relación entre el rango de valores α de los emisores de verificación y el de los de test, aunque utilizando siempre, al menos, 3 emisores para verificar. Con 2 emisores, parece difícil que todas las condiciones de flujo del subconjunto de test hayan sido cubiertas por el espectro de los datos de validación. Ello explicaría que, en general, los modelos con 3 hasta 5 emisores de validación presenten índices de rendimiento aceptables.

Si se comparan los entrenamientos con 3 y 4 emisores para verificación, se puede observar que los mejores rendimientos se obtienen para 3 emisores de validación y dos de test ($c=0.966$), lo que puede justificarse por el hecho de que hay un emisor más disponible para entrenar, con lo que 3 emisores serían suficientes para validar. Finalmente, el caso del entrenamiento 2 es el más parecido al que se ha utilizado en el apartado 1 para establecer las variables del modelo, con la diferencia de que el set de test sí es independiente del de entrenamiento. El bajo rendimiento obtenido con este modelo puede deberse a la elección de los puntos de cada emisor escogidos para validar. Así, este conjunto de puntos no resultaría representativo y no estaría cubriendo las condiciones de flujo de los emisores P y Q. Un análisis detallado de las condiciones de cada punto de las series P y Q para una mejor selección de los puntos de verificación podría ser clave para mejorar este rendimiento.

Así pues, en lo que se refiere al conjunto de datos contemplados en este estudio, puede decirse que se necesitan, al menos, 3 ó 4 emisores cualitativamente representativos del espectro total de valores de α para componer el set de verificación. Este número de emisores deberá ser mayor si aumenta el rango de valores de α de la población de emisores estudiados. Sin embargo, es difícil establecer una combinación óptima de emisores de verificación, pues, como se ha comentado, los indicadores de calidad del modelo están referidos a un conjunto determinado de emisores de test.

Las arquitecturas óptimas con una capa oculta predominan sobre las de dos capas. Asimismo, las arquitecturas con dos capas suelen presentar 5 neuronas en las capas ocultas. Sin embargo, es difícil extraer conclusiones definitivas sobre la arquitectura

ideal de las ANN porque, al ser una fase de tanteo, sólo se estudiaron unas pocas combinaciones validación-test.

2.3.3. PROPUESTA DE MODELO ANN

Una vez establecido el número mínimo de emisores necesarios para validar, se fijaron cinco combinaciones de verificación, 3 modelos con 3 emisores (NBH, ABE y NBE) y 2 modelos con 4 emisores (BCDE y GBHI). En los modelos con 4 emisores de verificación, se escogieron, atendiendo a la clasificación propuesta en el apartado de métodos, 2 emisores con valores de α cualitativamente altos (DE y HI, respectivamente) y 2 emisores con valores de α cualitativamente bajos (BC y GB, respectivamente). En los modelos con 3 emisores de verificación, se eligieron 2 emisores con valores de α cualitativamente bajos (NB, AB y NB, respectivamente) y un valor de α cualitativamente alto (H, E y E, respectivamente). La selección de un solo emisor en este último caso se justifica por el hecho de que, al presentar valores de h_i de mayor orden de magnitud, la fiabilidad de las medidas es mayor. Asimismo, el emisor B fue seleccionado en todos los casos siguiendo el mismo razonamiento, ya que, dentro del grupo de emisores con valores bajos de α , es el que presenta mayores valores de α .

A continuación, se llevó a cabo para cada caso un proceso 'leave one out', es decir, se realizó un barrido de emisores de test reservando en cada proceso de entrenamiento un solo emisor de test. Una vez finalizado dicho proceso, se excluyó del mismo el emisor con peor c , hasta que el valor medio de c de cada conjunto 'leave one out' superase 0.85 (tabla 2.9). Con ello se pretendía eliminar del proceso los emisores en que podía haberse cometido mayores errores de medición. Los rendimientos individuales para cada entrenamiento y emisor testado se encuentran desglosados en el anejo B (apartado B.3.1). Asimismo, para cada combinación de emisores de entrenamiento-validación-test asociados a cada etapa del procedimiento 'leave one out', se analizaron diferentes arquitecturas en busca de la de menor error de validación. Los errores de esta fase de cálculo se hallan también en el anejo B (apartado B.3.3).

A diferencia de los apartados anteriores, se ha optado por analizar únicamente arquitecturas de una capa oculta. Con ello se persigue aprovechar la ventaja que ofrecen las arquitecturas más sencillas: su mayor capacidad de generalización. Esta metodología

se justificaría por la consideración de unos emisores de test completamente independientes de los utilizados para calibrar la red y por el objetivo de desarrollar una herramienta con potencial de predicción. Cabe comentar brevemente que se llevaron a cabo un pequeño número de tanteos aplicando arquitecturas de dos capas también. Esto supuso la obtención de rendimientos considerablemente más bajos que los obtenidos con una única capa oculta. Estas estrategias de tipo ‘prueba y error’ se justifican por la ausencia de procedimientos definitivos para seleccionar arquitecturas óptimas en la literatura sobre redes neuronales.

Tabla 2.9. Indicadores de rendimiento medios de cada proceso ‘leave one out’

emisores de validación	NBH	ABE	NBE	BCDE	GBHI
emisores excluidos	Ninguno				
c (-)	0.777	0.861	0.761	0.839	0.851
MSE (m ²)	4.1759E-04	1.4876E-04	5.5531E-04	9.5055E-05	3.1837E-04
emisores excluidos	Q	Q	Q	G	Q
c (-)	0.926	0.929	0.930	0.772	0.918
MSE (m ²)	7.0894E-05	9.3689E-05	6.5532E-05	1.3032E-03	5.2026E-05
emisores excluidos	-	-	-	G,Q	-
c (-)				0.876	
MSE (m ²)				8.7212E-05	

Analizando individualmente los índices de rendimiento para cada emisor de test del proceso ‘leave one out’ (anejo B, apartado B.3.1), se encuentran una serie de valores inaceptables, fundamentalmente en la primera etapa de dicho proceso, cuando aún no se ha excluido ningún emisor. Las causas de dichos rendimientos pueden ser varias. Así, puede ocurrir:

- que el emisor de test esté mal medido
- que algún emisor del set de validación esté mal medido
- que los datos de algún emisor considerado en el set de entrenamiento estén mal medidos e introduzcan errores en el modelo.

De esta manera, resulta difícil atribuir las causas a un único factor, por lo que sólo estamos en condiciones de indicar un número de emisores sospechosos de contener datos anómalos o mal medidos o para los que el modelo no es válido.

Si se analizan los rendimientos individuales de cada emisor de test en la primera etapa del proceso ‘leave one out’ en relación con los rendimientos obtenidos en la segunda etapa, al excluir el emisor Q (anexo B, apartado B.3.1), puede comprobarse lo siguiente. Para el trío de verificación NBH, los valores de c de los emisores A, F, G, L pasan de 0.48, 0.59, 0.50 y 0.71 a 0.78, 0.84, 0.79 y 0.98, respectivamente. Para el trío de verificación ABE, los valores de c de los emisores H y N pasan de 0.76 y 0.52 a 0.85 y 0.98, respectivamente, mientras que el de F desciende de 0.91 a 0.68. Para el trío de verificación NBE, los valores de c de los emisores A, G y L pasan de 0.23, 0.51 y 0.54 a 0.89, 0.82 y 0.81, respectivamente. Con el grupo de validación GBHI, los valores de c de L, N y O pasan de 0.80, y 0.62 a 0.92 y 0.73, respectivamente, mientras que el valor de c de A desciende de 0.87 a 0.71. Los emisores que no se mencionan mantienen en ambos casos un buen rendimiento. La mejora media introducida en estos procesos ‘leave one out’ podría deberse a que cada proceso de entrenamiento se completa más adecuadamente al excluir los datos de Q. Por otra parte, la caída de rendimiento en la predicción de algunos emisores al ser excluido Q, podría sugerir que éstos también contienen fallos. Aunque, como se ha dicho, es difícil sacar conclusiones definitivas. Cuando el grupo de validación cruzada está conformado por los emisores BCDE, destaca el bajo valor de c que presenta el emisor de test G (0.21). Al excluir a éste del proceso, los valores de c de F, L y Q descienden de 0.80, 0.85 y 0.95 a 0.31, 0.79 y 0.16, respectivamente. Al excluir los datos de Q, los rendimientos se recuperan, pasando los valores de c de 0.31 (F), 0.79 (L) y 0.67 (O) a 0.64, 0.89 y 0.95, respectivamente. La justificación de este comportamiento podría ir en la misma línea que en el caso anterior.

Así pues, podría establecerse que existe un grupo de emisores con rango bajo de valores α (Q, G, A, F, L), cuyas mediciones experimentales podrían presentar algún error o inexactitud. Ello podría deberse al bajo orden de magnitud de las pérdidas localizadas, por lo que los sensores de presión podrían no ser suficientemente precisos. En este sentido, este hecho justificaría la ausencia de una tendencia clara entre los valores de α y Re para emisores con rango bajo de valores α (Provenzano y Pumo, 2004). Asimismo, si se analizan las tablas desglosadas con los rendimientos individuales de cada proceso ‘leave one out’, se hace visible que las predicciones con peores rendimientos corresponden siempre a emisores de test con valores α bajos, mientras que las pérdidas localizadas de los emisores de test con valores altos de α son estimadas siempre con gran precisión. No obstante, en términos absolutos, los menores rendimientos aludidos

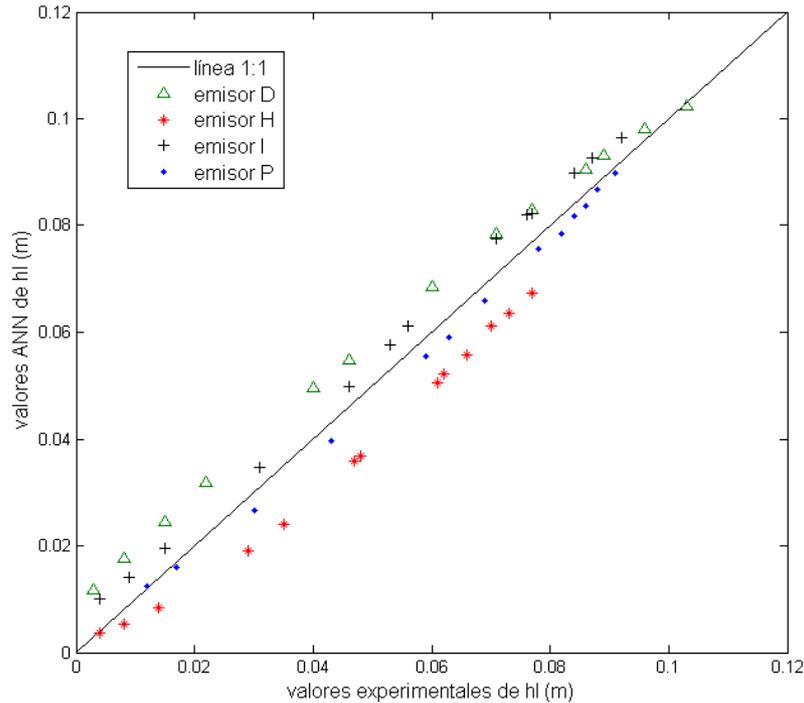
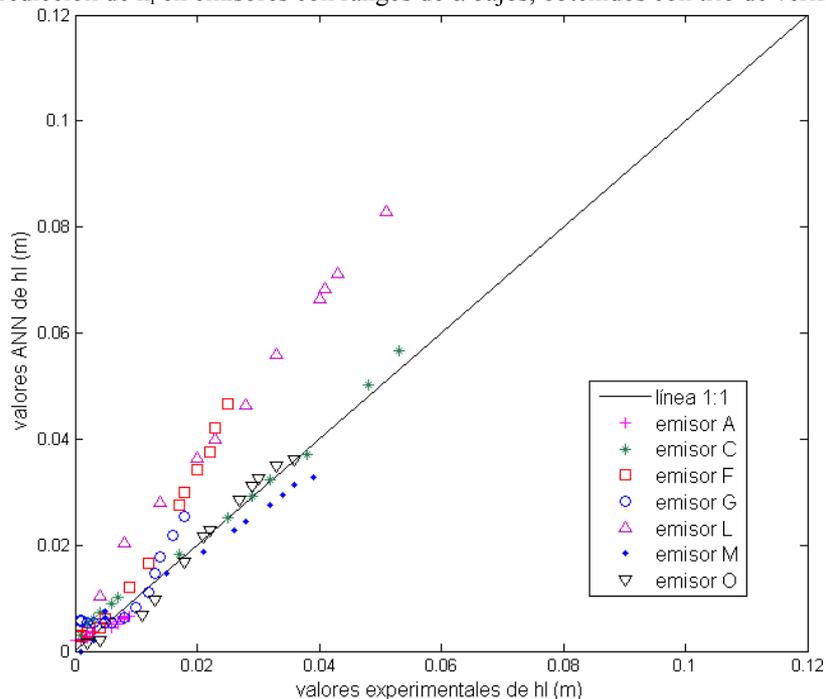
tendrían poca repercusión en la práctica debido al pequeño orden de magnitud de las pérdidas localizadas provocadas por dichos emisores.

Por otra parte, en la mayor parte de los casos, las arquitecturas óptimas presentan menos de seis neuronas ocultas, lo pone de manifiesto la baja complejidad del problema de vinculación input-output.

A continuación, en la figuras 2.8 y 2.9, se muestran las predicciones obtenidas con el grupo de verificación que conduce al mejor rendimiento medio, el NBE ($c=0.93$), desglosadas en emisores con rangos de α altos y bajos, aunque individualmente pueda haber otros modelos que permitan obtener mejores predicciones para un emisor determinado. En el anejo B se adjuntan las figuras correspondientes al resto de combinaciones de validación cruzada (apartado B.3.2).

En general, puede decirse que los emisores con rangos altos de α suelen presentar una tendencia a ser infraestimados o sobreestimados. Así, los valores de los emisores I y D son infraestimados, mientras que los de P y H, aunque con menor tendencia, son sobreestimados. Al analizar las tendencias de las predicciones de los emisores con rangos bajos de α , se observa que éstas son mucho más difusas. Así, únicamente los valores de F y L parece que tienden a ser infraestimados. Éstos suelen ser también los que más se alejan de la línea de ajuste perfecto.

Podría haber otra causa que justificara los malos rendimientos obtenidos en algunos casos, al margen de la exactitud de las medidas experimentales realizadas: el número de repeticiones de cada entrenamiento. Siguiendo este razonamiento, la causa que provocaría la variabilidad de los rendimientos de algunos modelos podría ser la influencia de la asignación inicial aleatoria de pesos cuando comienza el proceso de entrenamiento, que debería enmendarse con un número suficientemente elevado de repeticiones del mismo. El factor limitante en este caso, dada la gran cantidad de arquitecturas y combinaciones de validación y test que se estudian y el equipo de cálculo de que se dispone, sería el coste operacional del proceso al incrementar en más de 10 el número de repeticiones. Es preciso recordar también la simplificación introducida al definir el diámetro interior de los emisores no coaxiales, donde se atribuyó a dicho parámetro el mismo significado que posee para los emisores coaxiales.

Figura 2.8. Predicción de h_l en emisores con rangos de α altos, obtenidos con trío de verificación NBE**Figura 2.9.** Predicción de h_l en emisores con rangos de α bajos, obtenidos con trío de verificación NBE

Este hecho podría exigir un estudio aparte sobre la conveniencia de introducir un nuevo input en el modelo para considerar este aspecto. No obstante, conviene recordar que la herramienta de predicción propuesta permite obtener valores medios de c por encima de 0.85, calculados para datos de test completamente ajenos al desarrollo del modelo. Esto supone un gran avance en comparación con los modelos estadísticos tradicionales por

dos motivos. En primer lugar, los indicadores de calidad de los modelos ANN son mejores. En segundo lugar, los indicadores asociados a los modelos de regresión son engañosos porque se han obtenido para los mismos datos que han servido para generar el modelo, lo que hace suponer que serán peores cuando se refieran a un set de test independiente.

2.4. Conclusiones

El modelo ANN con mejores prestaciones resultó ser el de 4 inputs (diámetro interior de la tubería, diámetro interior del emisor, longitud del emisor y caudal circulante por la tubería). Asimismo, se observó que es preferible modelar como variable output los valores experimentales de pérdida de carga localizada, descontando las pérdidas por rozamiento que se generan en el interior del emisor, que utilizar los coeficientes de resistencia α asociados a dichas pérdidas de carga.

En la fase de comparación, todos los modelos neuronales resultaron más exactos que el de regresión, especialmente el citado en el párrafo anterior, que, para la estrategia de entrenamiento utilizada esta fase, rozaba el ajuste perfecto.

Para evaluar adecuadamente la capacidad real de generalización de los modelos ANN conviene reservar series completas de emisores para la fase de test del mismo. Para asegurar un entrenamiento adecuado del modelo, hay que destinar para la etapa de validación cruzada los datos de un conjunto de emisores cuyos valores α asociados cubran todo el espectro de valores α del total de datos considerados. Así, para el conjunto de datos considerado, son necesarios los datos de 3 ó 4 emisores para la etapa de verificación, con valores α representativos del total.

Los 5 modelos ANN propuestos, resultantes de los procesos 'leave one out' y de la omisión de dos emisores sospechosos de presentar errores de medida, presentan índices de rendimiento c medios por encima de 0.85.

Los modelos ANN propuestos predicen con mayor exactitud las pérdidas de carga localizadas asociadas a emisores con rangos altos de valores de α , en comparación con emisores con rangos bajos de valores de α .

2.5. Líneas de futuro

Las líneas de futuro deben centrarse en cuatro vertientes. En primer lugar, debe analizarse con profusión el número mínimo de repeticiones que es necesario para asegurar la estabilidad de los resultados obtenidos y analizar con detalle la influencia de la simplificación introducida al definir los diámetros interiores de los emisores no coaxiales. En segundo lugar, puede estudiarse la determinación de criterios claros y objetivos para establecer la arquitectura óptima de la red neuronal. En tercer lugar, cabe la posibilidad de analizar estrictamente todas las combinaciones de validación cruzada que pueden plantearse para un número determinado de emisores. Es importante tener presente que estas tres líneas precisan, sin embargo, la disponibilidad de una buena infraestructura de computación. Finalmente, deberían analizarse las prestaciones que ofrecen las redes neuronales para la predicción de pérdidas localizadas en emisores con otras geometrías, así como estudiar la posibilidad de definir nuevos parámetros que permitieran desarrollar modelos ANN para la predicción de pérdidas de carga localizadas independientemente de la geometría de la inserción. En esta línea, podrían aplicarse ANNs para estudiar las pérdidas de carga singulares provocadas por la inserción de los laterales en las secundarias.

capítulo 3

aplicabilidad de un modelo ANN de 4 inputs
para predicción de ET_0

3.1. INTRODUCCIÓN.....	73
3.2. MATERIALES Y MÉTODOS.....	73
3.2.1. OBTENCIÓN DE DATOS CLIMÁTICOS.....	73
3.2.2. GESTIÓN DE DATOS CLIMÁTICOS.....	74
3.2.3. OBTENCIÓN DE TARGETS Y CARACTERIZACIÓN DE ESTACIONES	75
3.2.4. PROPIEDADES DE LAS REDES NEURONALES UTILIZADAS E IMPLEMENTACIÓN EN <i>MATLAB</i>	79
3.2.4.1. <i>Propiedades de la ANN</i>	79
3.2.4.2. <i>Implementación de las redes</i>	80
3.2.4.2.1. <i>Neural Networks Toolbox</i>	80
3.2.4.2.2. <i>Matlab Editor</i>	81
3.2.5. INDICADORES DE CALIDAD DEL COMPORTAMIENTO DE LAS REDES.....	83
3.3. RESULTADOS Y DISCUSIÓN.....	84
3.3.1. CÁLCULOS REALIZADOS CON EL <i>NEURAL NETWORKS TOOLBOX</i>	84
3.3.2. CÁLCULOS REALIZADOS CON EL <i>MATLAB EDITOR</i>	90
3.4. CONCLUSIONES	93

3.1. Introducción

Como continuación del trabajo de Zanetti et al. (2007) se pretende analizar la aplicabilidad del modelo ANN de 4 inputs en cuatro estaciones meteorológicas de la Comunidad Valenciana, dos costeras (Altea y Benavites) y dos interiores (Campo Arcís y Castalla), así como su capacidad para predecir valores de ET_o fuera de la estación que ha servido de sede para generar el modelo. Asimismo, los resultados de estas predicciones se compararán con las del modelo de Hargreaves.

3.2. Materiales y métodos

Los cálculos de este capítulo se llevaron a cabo de dos maneras diferentes. Primero se utilizó el *Neural Networks Toolbox* de *Matlab* y, meses más tarde, cuando se desarrolló el modelo posterior de 6 inputs para la predicción de ET_o (capítulo 4), se adaptó una parte del mismo para recalculer el problema de la aplicabilidad del modelo de 4 inputs (Zanetti et al., 2007).

3.2.1. OBTENCIÓN DE DATOS CLIMÁTICOS

Las series históricas de las variables climáticas consideradas en este estudio fueron obtenidas a través de las estaciones climáticas del Instituto Valenciano de Investigaciones Agrarias (IVIA) en las localidades de Altea, Benavites, Campo Arcís y Castalla, cuya posición geográfica queda definida con la siguiente tabla y en la figura 3.1.

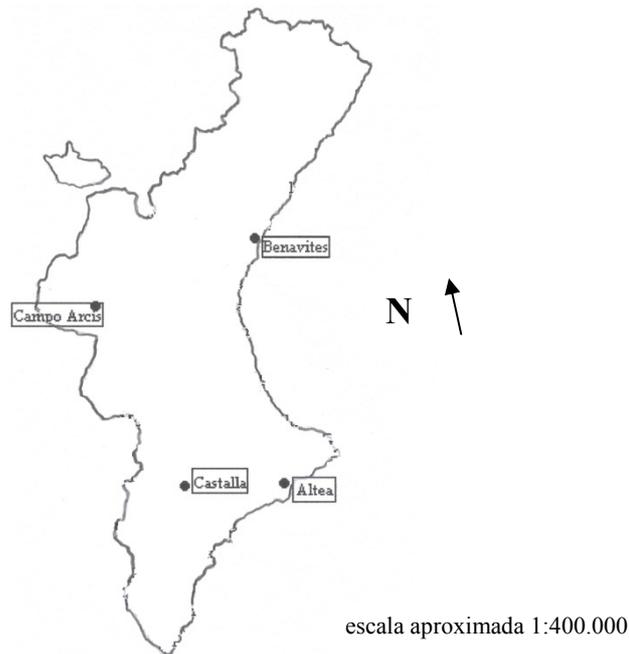
Tabla 3.1. Datos geográficos de las estaciones climáticas

estación	latitud (° ' ")	longitud (° ' ")	altitud (m)
Altea	38 36 20 N	00 04 39 W	210
Benavites	39 44 00 N	00 12 54 W	8
Castalla	38 36 19 N	00 40 22 W	708
Campo Arcís	39 26 04 N	01 09 39 W	584

Estas estaciones fueron seleccionadas debido a que presentaban mayor disponibilidad de datos que otras estaciones de la red del IVIA. Así, se utilizó una estación meteorológica automática para recoger los valores diarios de las siguientes variables durante 8 años:

- Temperatura máxima, T_{max}
- Temperatura mínima, T_{min}
- Temperatura media, T
- Número de horas de sol, N
- Radiación solar, R_s
- Humedad relativa, HR
- Velocidad del viento (a 2 m de altura), u_2

Figura 3.1. Situación geográfica de las estaciones estudiadas



3.2.2. GESTIÓN DE DATOS CLIMÁTICOS

Los datos climáticos corresponden al periodo entre enero de 2000 y enero de 2008 y pueden considerarse normales desde un punto de vista climático, pues no presentan oscilaciones bruscas a tener en cuenta. Los datos de 2006 y 2007 fueron utilizados para la validación cruzada y la fase de test, respectivamente, mientras que el resto de datos fueron utilizados para entrenar la red neuronal. Es decir, la asignación de datos para establecer los grupos de entrenamiento, verificación y test se realizó siguiendo un criterio cronológico.

En este capítulo se considera la generación de dos modelos ANN: el modelo de 4 inputs y un modelo de 7 inputs, utilizado como elemento de control. Así, éste considera también la humedad relativa, la radiación solar y la velocidad del viento. A priori, el

modelo de 7 inputs debía presentar mejor comportamiento, pues considera todas las variables de las que depende físicamente la ET_o . La consideración conjunta de R_a y R_s responde al ensamblaje de las matrices, que se realizó a posteriori, añadiendo a las del modelo de 4 inputs las variables R_s , HR y u_2 . Aunque pueda resultar redundante la consideración de ambas variables, dado el papel jugado por el modelo de 7 inputs, se dejó en un segundo plano esta cuestión, pues no es determinante en la consecución de los objetivos planteados. De esta manera, las variables climáticas tenidas en cuenta en ambos modelos se resumen en la tabla 3.2.

Tabla 3.2. Variables consideradas en los modelos ANN estudiados

	modelo 4 inputs	modelo 7 inputs
Inputs	$T_{\max}, T_{\min}, N, R_a$	$T_{\max}, T_{\min}, N, R_a, R_s, HR, u_2$
Output	ET_o	ET_o
Target	ET_o^{PM}	ET_o^{PM}

donde T_{\max} es la temperatura máxima, T_{\min} es la temperatura mínima, N es el número diario de horas de sol, R_a es la radiación extraterrestre, R_s es la radiación solar, HR es la humedad relativa, u_2 es la velocidad del viento, medida a 2 m de altura, ET_o es la evapotranspiración de referencia y ET_o^{PM} es la predicción de ET_o calculada mediante la ecuación de Penman Monteith.

3.2.3. OBTENCIÓN DE TARGETS Y CARACTERIZACIÓN DE ESTACIONES

La ecuación FAO-56/Penman Monteith (Allen et al., 1998) fue empleada para el cálculo de los targets o valores respuesta deseados, necesarios para entrenar el modelo. Ello se debe a la imposibilidad de utilizar lisímetros para generar valores de referencia de ET_o , debido a su limitado número en la Comunidad Valenciana. Es decir,

$$ET_o^{PM} = \frac{0.408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 u_2)} \quad (3.1)$$

donde ET_o^{PM} es la evapotranspiración de referencia calculada con la ecuación de Penman-Monteith (mm/día); R_n es la radiación neta en la superficie del cultivo (MJ/m²/día); G es la densidad de flujo de calor en el suelo (MJ/m²/día); T es la temperatura media diaria (°C); γ es la constante psicrométrica (kPa/°C); Δ es la pendiente de la curva de la presión de vapor (kPa/°C); e_s es la presión de saturación de vapor (kPa); e_a es la presión de vapor real (kPa); u_2 es la velocidad del viento a dos

metros de altura (m/s). Para aplicar esta ecuación es preciso derivar previamente algunas de las variables que intervienen en la misma, concretamente, R_n , G , Δ , e_s , e_a y γ . Para esto se emplearon las siguientes fórmulas (Allen et al., 1998). Primero se calculó la pendiente de la curva de la presión de vapor de saturación Δ y la constante psicrométrica correspondiente a la altitud de la estación meteorológica γ .

$$\Delta = \frac{4098 \left[0.6108 e^{\frac{17.27 T}{T+237.3}} \right]}{(T + 237.3)^2} \quad (3.2)$$

donde T es la temperatura media diaria en °C, y

$$\gamma = 0.665 \cdot 10^{-3} P \quad (3.3)$$

con

$$P = 101.3 \left(\frac{293 - 0.0065 z}{293} \right)^{5.26} \quad (3.4)$$

donde z es la altitud en m . Después se calcularon unos operadores, **a**, **b** y **c**, definidos como

$$a = \frac{\Delta}{[\Delta + \gamma (1 + 0.34 u_2)]} \quad (3.5)$$

$$b = \frac{\gamma}{[\Delta + \gamma (1 + 0.34 u_2)]} \quad (3.6)$$

$$c = \frac{900}{T + 273} u_2 \quad (3.7)$$

donde u_2 se expresa en m/s. A continuación, se calculó la presión de vapor de saturación e_s , como

$$e_s = \frac{e^o(T_{max}) + e^o(T_{min})}{2} \quad (3.8)$$

con

$$e^o(T) = 0.6108 e^{\frac{17.27 T}{T+237.3}} \quad (3.9)$$

donde T se expresa en °C, y la presión de vapor real, como

$$e_a = e_s \frac{HR}{100} \quad (3.10)$$

donde HR es la humedad relativa media en %. De ambas se deriva el déficit de presión de vapor DPV:

$$DPV = e_s - e_a \quad (3.11)$$

Los valores de la radiación extraterrestre R_a y del número diario de horas de sol, se estimaron a partir del día del año, J , y de la latitud de la estación con las siguientes fórmulas:

$$\delta = 0.409 \operatorname{sen} \left(\frac{2\pi}{365} J - 1.39 \right) \quad (3.12)$$

$$d_r = 1 + 0.033 \cos \left(\frac{2\pi}{365} J \right) \quad (3.13)$$

$$w_s = \arccos [-\tan (\tau) \tan (\delta)] \quad (3.14)$$

$$R_a = \frac{24 (60)}{\pi} G_{sc} d_r [w_s \operatorname{sen} (\tau) \operatorname{sen} (\delta) + \cos (\tau) \cos (\delta) \operatorname{sen} (w_s)] \quad (3.15)$$

donde δ es la declinación solar (radianes); w_s es el ángulo solar del ocaso (radianes); τ es la latitud (radianes); d_r es la distancia inversa relativa tierra-sol (-); R_a es la radiación extraterrestre ($\text{MJm}^{-2}\text{día}^{-1}$); G_{sc} es la constante solar 0.0820 ($\text{MJm}^{-2}\text{min}^{-1}$); J es el día del año (-); y N es el número de horas diarias de sol (-). La radiación solar R_s se calculó a partir del número de horas de sol diarias como

$$R_s = \left(a_s + b_s \frac{N}{N} \right) R_a \quad (3.16)$$

con

$$N = \frac{24}{\pi} w_s \quad (3.17)$$

donde N es el número de horas diarias de sol medidas (-); N es el número de horas diarias de sol teóricas (-); y a_s y b_s son constantes de regresión (se recomiendan los valores 0.25 y 0.5 respectivamente cuando no se dispone de valores de radiación solar reales). Cuando se dispone de valores medidos de R_s en la estación meteorológica basta con corregir las unidades a $\text{MJm}^{-2}\text{día}^{-1}$. La radiación de onda corta con cielo raso R_{so} , que es la radiación solar que llegaría a la superficie terrestre un día sin nubes, se obtiene también en $\text{MJm}^{-2}\text{día}^{-1}$ como

$$R_{so} = (0.75 + 2 \cdot 10^{-5} z) R_a \quad (3.18)$$

donde z es la altitud de la estación meteorológica (m). La radiación solar neta, que es la que resulta del balance entre la que llega a la superficie terrestre y la que se refleja, se calcula con

$$R_{ns} = (1 - \alpha) R_s \quad (3.19)$$

donde α es el albedo o fracción reflejada de la radiación solar que llega a la superficie terrestre (para una pradera verde como cultivo de referencia se acepta un valor de 0.23). La radiación solar absorbida por la tierra se convierte en calor. En algunos procesos, incluyendo la emisión de radiación, la tierra pierde energía. La tierra, que está a una temperatura menor a la del sol, emite energía radiante con longitudes de onda mayores a las del sol. Por esto a la radiación terrestre se la considera en este estudio como radiación de onda larga. Esta radiación emitida es absorbida por la atmósfera o se pierde en el espacio. La atmósfera incrementa su temperatura a costa de esta radiación, y como consecuencia de esto, irradia su propia radiación, que en parte regresa a la tierra. Es decir, la tierra emite y recibe radiación de onda larga, y la diferencia entre ambas se calcula mediante la expresión

$$R_{nl} = \sigma \left[\frac{T_{max,K}^4 + T_{min,K}^4}{2} \right] (0.34 - 0.14 \sqrt{e_a}) \left(1.35 \frac{R_s}{R_{so}} - 0.35 \right) \quad (3.20)$$

donde R_{nl} es la radiación de onda larga neta emitida ($\text{MJm}^{-2}\text{dia}^{-1}$); T es la temperatura (grados Kelvin); σ es la constante de Stefan-Boltzmann ($4.903 \cdot 10^{-9} \text{ MJK}^{-4}\text{m}^{-2}\text{dia}^{-1}$); y e_a es la presión de vapor real (kPa).

Finalmente, la radiación neta R_n se calcula como la diferencia entre la radiación neta de onda corta que llega a la superficie y la radiación neta de onda larga emitida. Es el resultado del balance entre energía absorbida, reflejada y emitida por la superficie terrestre. Es decir

$$R_n = R_{ns} - R_{nl} \quad (3.21)$$

El flujo de calor del suelo G es la energía utilizada en el calentamiento del suelo y resulta positivo cuando éste se calienta y negativo cuando se enfría. No obstante, en el balance diario la magnitud de G es despreciable en comparación con R_n y, por tanto, no se considerará su efecto, aunque no ocurriría lo mismo si lleváramos a cabo un balance de energías horario. Llegados a este punto, se está en disposición de calcular la evapotranspiración mediante la fórmula de Penman-Monteith-FAO.

Por otra parte, los resultados de los modelos ANN se han comparado con los que se obtienen aplicando otro método basado en mediciones de temperatura, el de Hargreaves (Hargreaves y Samani, 1985), cuya expresión para la ET_o es

$$ET_o^H = 9.388 \cdot 10^{-4} R_a (T_{\max} - T_{\min})^{0.5} (T + 17.8) \quad (3.22)$$

donde R_a es la radiación extraterrestre ($\text{MJ}/\text{m}^2/\text{día}$), T_{\max} es la temperatura máxima diaria ($^{\circ}\text{C}$), T_{\min} es la temperatura mínima ($^{\circ}\text{C}$) y T es la temperatura media diaria ($^{\circ}\text{C}$). Los valores de la radiación extraterrestre R_a y del número diario de horas de sol, necesarios para aplicar el modelo de 4 inputs, se estimaron a partir de las ecuaciones

Por otra parte, con el objetivo de acotar geográficamente la validez del modelo ANN de 4 inputs se pretende definir un parámetro que caracterice a la estación considerada. Dado que se están estudiando modelos basados en medidas de temperatura, parece razonable establecer un índice de continentalidad, que plasme el grado de fluctuación térmica de la estación estudiada. Para ello, tras consultar diferentes índices de continentalidad existentes, por ejemplo los índices de Gorzinsky y Conrad (Pérez-Cueva, 1994), se propuso uno que incluyera, además de la temperatura, la mínima distancia al mar. Así,

$$IC = \frac{\frac{1}{n_d} \sum (T_{\max_i} - T_{\min_i})}{T_{\max_j} - T_{\min_j}} d_m \quad (3.23)$$

donde el subíndice i hace referencia al valor diario; el subíndice j hace referencia al periodo global considerado; d_m es la distancia mínima al mar en km; y n_d es el número de días considerado.

3.2.4. PROPIEDADES DE LAS REDES NEURONALES UTILIZADAS E IMPLEMENTACIÓN EN *MATLAB*

En general, las propiedades de las redes utilizadas son las mismas que en el capítulo 2, con la excepción de las arquitecturas estudiadas. Por otra parte, en este capítulo se lleva a cabo una comparativa entre los resultados obtenidos mediante el uso del *Neural Networks Toolbox* y el *Editor de Matlab*. Los aspectos que no se especifiquen a continuación son coincidentes con los contemplados en el capítulo anterior.

3.2.4.1. Propiedades de la ANN

Las novedades que se plantean respecto al capítulo anterior tienen por objetivo seguir las pautas metodológicas seguidas por Zanetti et al. (2007), para poder comparar los

resultados obtenidos con los de dichos autores. De todas maneras, en general, los aspectos más relevantes, como la tipología de ANN, así como el algoritmo de aprendizaje y sus parámetros asociados son coincidentes.

En su estudio, Zanetti et al. (2007) compararon los resultados obtenidos mediante el uso de sendas funciones de activación, la tangente hiperbólica y la función sigmoideal, no apreciándose apenas diferencias. Por ello, y en concordancia con el capítulo 2, sólo se utilizó la primera de ellas.

3.2.4.2. Implementación de las redes

Como se ha comentado, en primera instancia se utilizó la aplicación de *Matlab* para trabajar con redes neuronales, el *Neural Network Toolbox*.

Meses más tarde, se adaptó un programa elaborado para la mejora del modelo de 4 inputs (capítulo 4), y se recalcularon los casos contemplados en este capítulo. Los aspectos estructurales y funcionales de las ANN tratados hasta ahora son comunes en ambos casos, pues en los dos se trataba de perceptrones multinivel.

3.2.4.2.1. Neural Networks Toolbox

Siguiendo el estudio de Zanetti et al. (2007), se contemplaron las arquitecturas de la tabla 3.3. Para cada arquitectura se calcularon los errores de los conjuntos de entrenamiento, validación cruzada y test, así como los errores de test al aplicar el modelo ANN fuera de la sede de entrenamiento, esto es, con los sets de test de las tres estaciones restantes. Podría haberse realizado un análisis de los tres primeros errores para determinar la arquitectura óptima y, con ésta, testar el modelo en las estaciones restantes. Sin embargo, dado el pequeño número de arquitecturas estudiadas, se testaron todas las arquitecturas fuera de la sede. Asimismo, se calculó el error medio del comportamiento de un modelo fuera de la sede de entrenamiento. Así, por otra parte, se ha seleccionado la arquitectura con menor error de verificación, que, a priori, atesora la mayor capacidad de generalización, y, por otra, la de menor test exterior. Se han comparado ambas arquitecturas y se ha elegido la más sencilla, siempre que el error de verificación sea del mismo orden de magnitud.

El hecho de que la arquitectura con menor error de validación cruzada pueda presentar mayor error de test medio en el exterior que otra no implica que no sea la de mayor potencial de generalización, pues los resultados podrían invertirse al considerar más estaciones de test exterior. Este hecho es relevante en nuestro caso, pues sólo se han estudiado cuatro estaciones.

Tabla 3.3. Arquitecturas de 4 inputs analizadas con *Neural Network Toolbox*

1 capa oculta	2 capas ocultas
4 - 5 - 1	4 - 5 - 5 - 1
4 - 10 - 1	4 - 10 - 10 - 1
4 - 15 - 1	4 - 15 - 15 - 1
4 - 20 - 1	4 - 20 - 20 - 1

Todas las arquitecturas fueron entrenadas y testadas 5 veces para evitar dentro de lo posible el efecto derivado de la asignación inicial aleatoria de los pesos, característica de los *softwares* para aplicación de ANNs. La repetición que proporcionaba el menor error de validación era seleccionada para la comparativa entre arquitecturas. Al tratarse de un proceso de cálculo prácticamente manual, muy pesado, se estableció un número pequeño de repeticiones (5). Conviene destacar que no se hace ninguna referencia a este respecto en el artículo de Zanetti et al. (2007) ni en artículos anteriores en el ámbito de las estimación de necesidades hídricas, por lo que podría pensarse que los autores no repiten el proceso de entrenamiento.

3.2.4.2.2. *Matlab Editor*

En segunda instancia se desarrolló un programa utilizando el editor de *Matlab*. Dicha herramienta permite adaptar el potencial de cálculo de *Matlab* para lograr unos fines más concretos y agilizar, por otra parte, el proceso de cálculo.

Tabla 3.4. Arquitecturas analizadas con *Matlab Editor*

1 capa oculta	2 capas ocultas
4 - 1 - 1	4 - 1 - 1 - 1
...	...
4 - n - 1	4 - n - n - 1

Aprovechando esa mayor versatilidad, se generó un programa que contempla más casos que en el apartado del *Neural Network Toolbox*. Se ha demostrado que una red neuronal con dos capas ocultas es un aproximador universal de cualquier función (Irie y Miyake,

1988). Así, dicho programa calcula arquitecturas con una y dos capas ocultas, cada una con una hasta n neuronas (tabla 3.4). En el caso de las dos capas ocultas, ambas presentan cada vez igual número de neuronas. Y todo ello, estableciendo a priori el número de repeticiones deseado del proceso de entrenamiento.

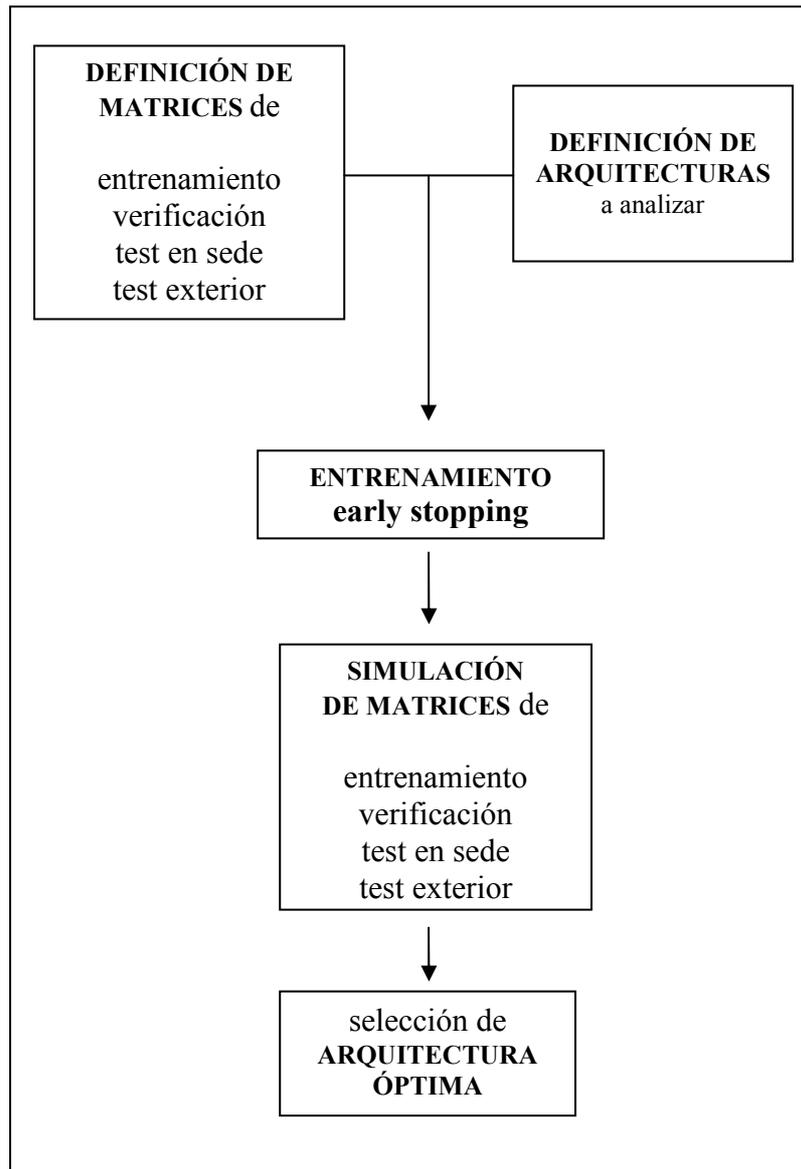
El número de repeticiones y el número máximo de neuronas se fijaron en veinte. De las veinte repeticiones del entrenamiento de cada arquitectura, se escoge aquella con menor error de validación. Una vez se dispone de los errores de entrenamiento, verificación y test de la mejor repetición de cada arquitectura, se comparan los errores de validación para escoger de manera automática la mejor arquitectura. Pueden adoptarse dos criterios. Se elige la arquitectura con menor error de validación o bien se compara la evolución entre error de verificación y error de test de cada arquitectura. Así, entre dos arquitecturas con error de validación cruzada semejante, se escoge la de menor error de test o la más sencilla.

En este estudio se adoptó el primer criterio, pues plantea una programación clara y directa. El segundo tiene una componente subjetiva difícil de programar. No obstante, se llevó a cabo una comprobación de las evoluciones de los distintos errores y sus arquitecturas correspondientes para comprobar que la arquitectura con menor error de verificación no presentara un error de test desproporcionado. Por otra parte, en caso de empate relativo entre dos arquitecturas, con una y dos capas ocultas respectivamente, se escogió la de una sola capa oculta, por su mayor sencillez y mayor potencial de generalización. Para este fin se definió un margen máximo admisible de diferencia entre el error de verificación mínimo de redes con una y dos capas ocultas, para primar las arquitecturas con una capa oculta. Dicho margen se fijó en 0.008 (mm/día)^2 , tras un tanteo del orden de magnitud de los MSE obtenidos en el proceso de entrenamiento. De esta manera, si el error de validación cruzada mínimo correspondía a una arquitectura con dos capas ocultas, pero su diferencia con respecto al error de verificación mínimo de las redes con una capa oculta era menor al margen fijado, se desechaba la arquitectura más compleja en favor de la más sencilla.

Al utilizar el editor de *Matlab* se mantuvieron los parámetros de entrenamiento propuestos por el programa en su *Toolbox*, pues aseguran una convergencia fiable hacia el mínimo de la superficie de error.

La figura 3.2 resume los pasos fundamentales seguidos en la implementación del programa con *Matlab Editor*. En general, el procedimiento es muy similar al seguido en el capítulo anterior, si bien aquí sólo hay una combinación de matrices de entrenamiento, validación cruzada y test, pues, como se ha dicho, los datos climáticos de todos los años pueden considerarse normales.

Figura 3.2. Pasos generales seguidos en la implementación del programa con *Matlab Editor*



3.2.5. INDICADORES DE CALIDAD DEL COMPORTAMIENTO DE LAS REDES

Los indicadores son coincidentes con los contemplados en el capítulo anterior.

3.3. Resultados y Discusión

3.3.1. CÁLCULOS REALIZADOS CON EL *NEURAL NETWORKS TOOLBOX*

En primera instancia se presentan los resultados obtenidos con el *Neural Networks Toolbox*. Así, la tabla 3.5 resume los índices de rendimiento correspondientes a las arquitecturas óptimas seleccionadas en cada estación, así como el rendimiento de cada modelo en el exterior. Las tablas generales que aglutinan todos los casos considerados se encuentran en los apartados C.1.1.1 y C.1.2.1 del anejo C.

En Castalla, las arquitecturas con menor error de test exterior y error de verificación eran demasiado complejas, con dos capas ocultas (tabla C.1). Así, se consideraron otras arquitecturas con una capa oculta, con errores de verificación y test exterior del mismo orden de magnitud. Sin embargo, dado que todas las arquitecturas de una capa oculta cumplen este requisito, la elección de la misma tomó un carácter arbitrario, escogiéndose finalmente la más sencilla, la de 5 neuronas.

En el caso del modelo ANN de 7 inputs, la elección fue más fácil, pues en tres casos la misma arquitectura presentaba menor error de verificación y de test exterior simultáneamente y, en el cuarto, la arquitectura con menor error de test exterior poseía un error de verificación sólo ligeramente por encima del mínimo y era más sencilla.

La pregunta que puede surgir es cuanto puede permitirse que aumente el error de validación/test medio exterior a costa de reducir el número de neuronas. Así, en lugar de las dos arquitecturas 7 - 15 - 1, podrían haberse escogido las de 7 - 5 - 1, pues los errores no aumentan ostensiblemente, y más teniendo en cuenta que el orden de magnitud de los mismos en el modelo de 7 inputs es muy bajo. Sin embargo, para seguir un criterio uniforme y cuantificable se ha respetado la elección de entre los errores comentados antes.

Asimismo, la tabla 3.5 presenta los valores del *performance index* c , propuesto por Camargo y Sentelhas (1997). Conviene destacar que dichos índices dependen del tamaño y valores de cada muestra y, por tanto, es posible encontrar una estación con mejor error cuadrático y peor *performance index* que otra.

Por otra parte, la drástica reducción del error (o el incremento de c) que se produce en el modelo de 7 inputs indica que el proceso de ensamblaje de las matrices así como el entrenamiento de los datos se ha realizado correctamente.

Tabla 3.5. Caracterización de arquitecturas óptimas. MSE en (mm/día)²

ANN		4 inputs		7 inputs	
índice de rendimiento		MSE	c (-)	MSE	c (-)
arquitectura óptima		4 - 10 - 1		7 - 10 - 1	
Altea	entrenamiento	0.1934	0.9487	0.0184	0.9952
	validación cruzada	0.2338	0.9398	0.0155	0.9961
	test	0.2129	0.9506	0.0155	0.9965
	Benavites	0.3655	0.9021	0.0423	0.9902
	Campo Arcís	0.6253	0.9136	0.1644	0.9783
	Castalla	0.6812	0.9027	0.2246	0.9706
	media test exterior	0.5573	0.9061	0.1438	0.9797
arquitectura óptima		4 - 10 - 1		7 - 15 - 1	
Benavites	entrenamiento	0.2504	0.9138	0.0122	0.9959
	validación cruzada	0.2875	0.9126	0.0145	0.9956
	test	0.3537	0.9285	0.0480	0.9934
	Altea	0.3272	0.9078	0.0189	0.9947
	Campo Arcís	0.7448	0.9084	0.0878	0.9862
	Castalla	0.9770	0.8764	0.1431	0.9773
	media test exterior	0.6918	0.9044	0.0930	0.9856
arquitectura óptima		4 - 5 - 1		7 - 15 - 1	
Campo Arcís	entrenamiento	0.2464	0.9528	0.0213	0.9960
	validación cruzada	0.2675	0.9520	0.0184	0.9968
	test	0.2784	0.9381	0.0734	0.9902
	Benavites	0.3406	0.9087	0.0304	0.9926
	Altea	0.3536	0.9426	0.0211	0.9965
	Castalla	0.6154	0.9081	0.0405	0.9929
	media test exterior	0.4115	0.9183	0.0481	0.9919
arquitectura óptima		4 - 5 - 1		7 - 5 - 1	
Castalla	entrenamiento	0.3826	0.9304	0.0433	0.9923
	validación cruzada	0.3654	0.9347	0.0375	0.9935
	test	0.5442	0.9229	0.0601	0.9906
	Benavites	0.8991	0.8648	0.0329	0.9910
	Campo Arcís	0.4990	0.9322	0.0296	0.9952
	Altea	0.4157	0.9255	0.0402	0.9930
	media test exterior	0.6474	0.9066	0.0409	0.9923

Un análisis de los errores cuadráticos de la tabla anterior permite comprobar que el modelo ANN de 4 inputs, cuando se testa en la propia sede, ofrece mejor rendimiento global en las estaciones costeras que en las interiores, 0.2129 (Altea) y 0.3537

(Benavites) (mm/día)² frente a 0.2784 (Campo Arcís) y 0.5442 (Castalla) (mm/día)². Asimismo, se comprueba que los modelos entrenados en sedes costeras presentan menor error cuando se testan en localidades costeras que los modelos entrenados en sedes interiores cuando se testan en localidades de interior, 0.3655 (Altea en Benavites) y 0.3272 (Benavites en Altea) frente a 0.6154 (Campo Arcís en Castalla) y 0.499 (Castalla en Campo Arcís). Esta tendencia se invierte al testar modelos de sedes costeras en localidades de test interiores y modelos de sedes interiores en localidades de test costeras, 0.6253 y 0.6812 (Altea en Campo Arcís y Castalla) y 0.7448 y 0.977 (Benavites en Campo Arcís y Castalla) frente a 0.3536 y 0.3406 (Campo Arcís en Altea y Benavites) y 0.4157 y 0.8991 (Castalla en Altea y Benavites), aunque este último caso sea una excepción. Los valores están expresados en (mm/día)²

Este comportamiento podría justificarse por el hecho de que en climas costeros, con menor oscilación térmica debido a la influencia del mar, las redes neuronales son capaces de establecer más fácilmente la relación entre las variables involucradas y hallar la tendencia correcta. Por el contrario, en estaciones de interior, con mayores fluctuaciones térmicas y, por tanto, con presencia de mayor rango de temperaturas, el modelo tiene dificultades para vincular las variables que intervienen, pero, sin embargo, ese mayor rango en los inputs considerados permite obtener predicciones relativamente razonables cuando se utiliza el modelo fuera de la sede, concretamente en localidades con menor oscilación de temperaturas, por ejemplo, en la costa. A ello contribuye también la menor complejidad de las arquitecturas óptimas de las estaciones interiores.

En la tabla 3.6 se muestran los indicadores de calidad de las predicciones obtenidas con el modelo de Hargreaves. Comparando tales índices con los del modelo ANN, se comprueba que las redes neuronales ofrecen mejores rendimientos siempre que los modelos se testen en la sede. En la práctica, si sólo se dispone de una sede, puede ser preferible aplicar Hargreaves antes que testar un modelo ANN fuera de la sede. A la vista del índice de continentalidad propuesto, pueden asignarse las categorías cualitativas ‘costero’ e ‘interior’ para IC menores o mayores a 2, respectivamente, para fijar de alguna manera la frontera entre ambas categorías. Estos índices permitirían definir con mayor precisión las categorías cualitativas ‘costero’ e ‘interior’ para establecer el ámbito de validez del modelo entrenado en una sede determinada. De esta manera, podría fijarse el rango de IC por debajo del cual podría ser preferible usar el

modelo ANN fuera de su sede antes que la ecuación de Hargreaves. Para determinar dicho rango, sería conveniente considerar más casos de estudio.

Tabla 3.6. Indicadores estadísticos de la predicción obtenida mediante el modelo de Hargreaves para el año 2007. Índice de continentalidad propuesto calculado para 2007 en las estaciones estudiadas

referido a 2007		modelo de Hargreaves	
estación	índice de continentalidad (-)	MSE (mm/día) ²	c (-)
Altea	0.2475	0.3164	0.9319
Benavites	0.4038	0.4101	0.8959
Campo Arcís	17.2703	0.3800	0.9373
Castalla	5.5998	0.6090	0.9078

Globalmente, el rendimiento del modelo de 4 inputs fuera de la sede no puede considerarse aceptable y tiene bastante margen de mejora. Dicha mejora podría acarrear la consideración de nuevas variables que pudieran resultar fundamentales en la determinación de la evapotranspiración de referencia, como la humedad relativa o la velocidad del viento.

En el caso del modelo de 7 inputs, la tendencia observada es la misma (tabla 3.5). Al testar en la sede de entrenamiento, los errores son menores en estaciones costeras (0.0155 y 0.048 en Altea y Benavites, respectivamente, frente a 0.0734 y 0.0601 en Campo Arcís y Castalla, respectivamente). Al testar en estaciones de carácter distinto al de la sede, las sedes interiores ofrecen mejor rendimiento al ser testadas en las costeras que las costeras al ser testadas en las interiores (0.1644 y 0.2246 de Altea en Campo Arcís y Castalla, respectivamente, 0.0878 y 0.1431 de Benavites en Campo Arcís y Castalla, respectivamente, frente a 0.0304 y 0.0211 de Campo Arcís en Benavites y Altea, respectivamente, y 0.0329 y 0.0402 de Castalla en Benavites y Altea, respectivamente). Al contrario que en el caso del modelo de 4 inputs, al testar el modelo en una localidad del mismo tipo de que la sede, el rendimiento siempre es bueno (0.0423 de Altea en Benavites, 0.0189 de Benavites en Altea, 0.0405 de Campo Arcís en Castalla y 0.0296 de Castalla en Campo Arcís). Los valores están expresados en (mm/día)².

Pese a los bajos errores de este modelo, incluso al estimar fuera de la sede de entrenamiento, la utilidad práctica de este modelo es mínima, ya que en caso de disponer de todas las variables para su aplicación, se aplicaría directamente la ecuación

de Penman Monteith. Como se ha comentado, este modelo sólo se ha hecho servir como elemento de control del de 4 inputs. Por otra parte, conviene destacar que en caso de haber utilizado valores experimentales de ET_0 para entrenar el modelo, el rendimiento del modelo ANN de 7 inputs hubiera sido con gran seguridad mayor que la propia ecuación de Penman Monteith, tal como apuntan Kumar et al. (2002).

Vistos los órdenes de magnitud de los errores asociados a los modelos estudiados cuando son testados en la sede de entrenamiento y fuera de ella, puede desprenderse que la utilidad de dicho modelo queda restringida al papel de modelo de emergencia. Es decir, la única aplicación plausible que puede contemplarse es su uso en la sede de entrenamiento cuando el modelo de Penman-Monteith no puede ser aplicado, por ejemplo cuando se produce una avería en el sistema de recogida de datos y sólo hay disponibles valores de temperatura.

A continuación se muestran sendas figuras, 3.3 y 3.4, donde se representan los valores estimados por los modelos de 4 y 7 inputs, respectivamente, frente a los valores correspondientes de Penman-Monteith, cuando se aplican al subconjunto de inputs de test de Altea.

Cada uno de los 4 subgráficos que componen cada figura corresponde a una sede de entrenamiento distinta (Altea en rojo, Benavites en azul, Campo Arcís en verde y Castalla en negro). Estas figuras permiten establecer la tendencia de cada modelo a infraestimar o sobreestimar los valores de referencia, así como a verificar los órdenes de magnitud de la ET_0 local. El resto de figuras correspondientes al resto de estaciones de test se hallan recogidas en los apartados C.1.1.2 y C.1.2.2 del anejo C.

En general, parece que los modelos de 4 inputs entrenados en sedes costeras tienen una ligera tendencia a infraestimar, especialmente cuando se testan en localidades de interior. El modelo de 4 inputs entrenado en Castalla parece que presenta una tendencia a sobreestimar, mientras que Campo Arcís no muestra ninguna tendencia concreta. Los modelos de 7 inputs no parecen presentar una tendencia clara a sobreestimar o infraestimar. Conviene tener presente que no pueden extraerse tendencias concluyentes y generalizables debido al escaso número de estaciones involucradas.

Figura 3.3. ET_o PM vs ET_o ANN 4 inputs testados en Altea y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

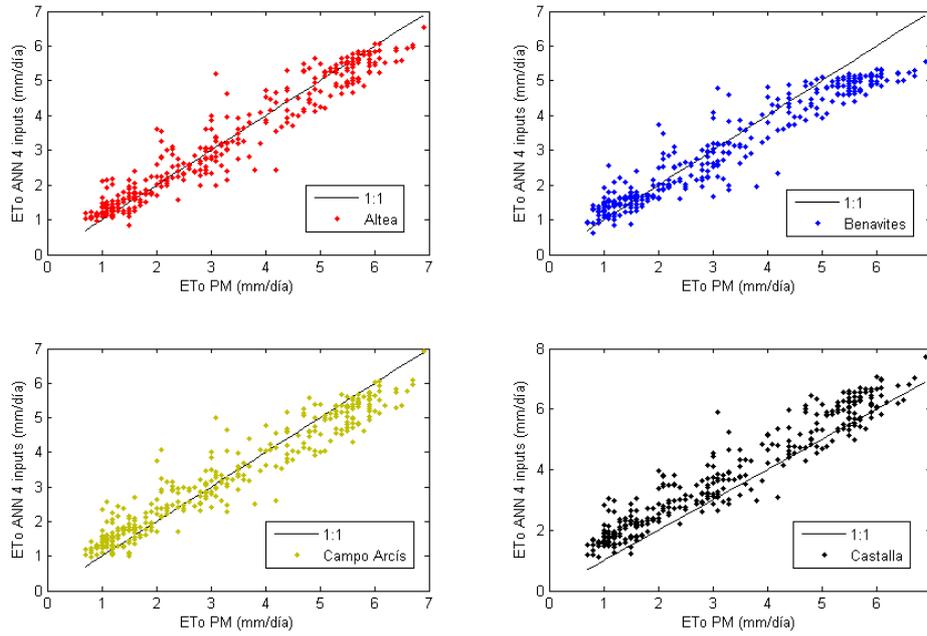
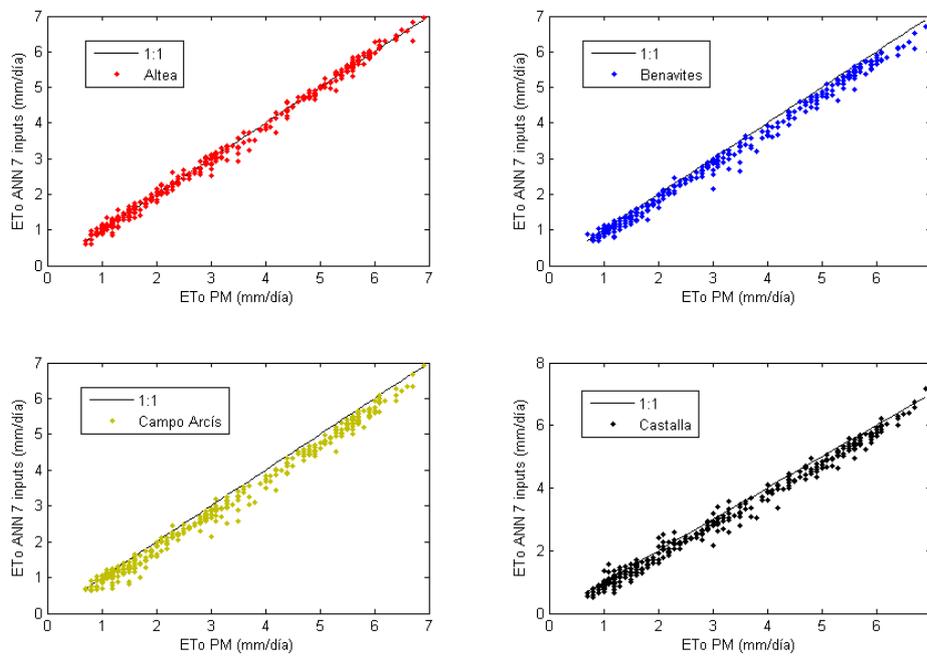


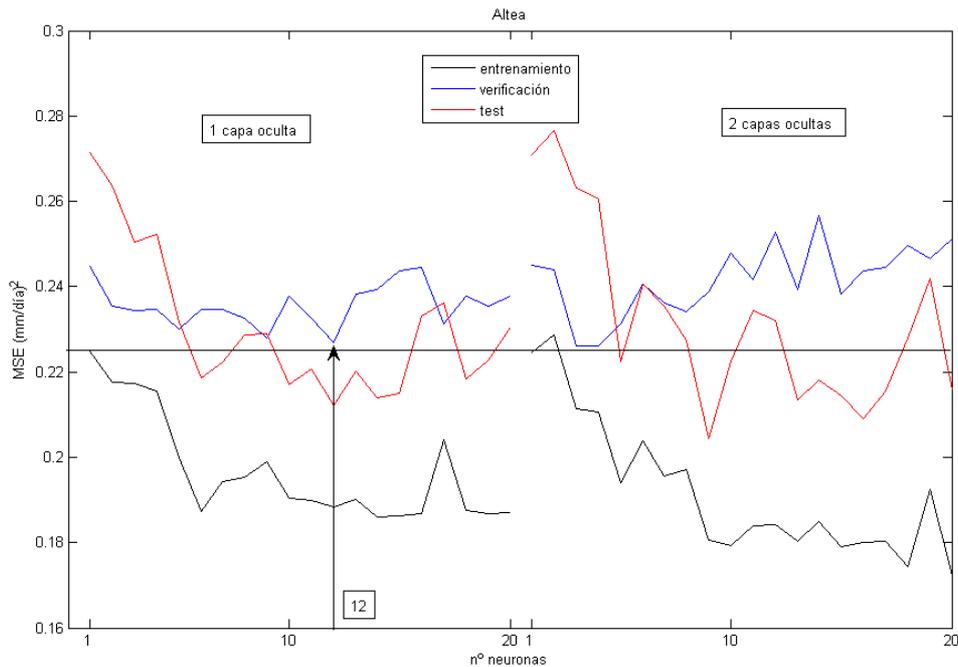
Figura 3.4. ET_o PM vs ET_o ANN 7 inputs testados en Altea y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)



3.3.2. CÁLCULOS REALIZADOS CON EL MATLAB EDITOR

La figura 3.5 esquematiza el proceso de selección de la arquitectura óptima de entre las topologías consideradas en Altea, el único caso en el que el error mínimo de validación corresponde a una arquitectura con dos capas ocultas.

Figura 3.5. Error cuadrático vs nº de neuronas para los conjuntos de entrenamiento, validación cruzada y test. Altea



Aquí, la arquitectura 4 - 4 - 4 - 1 posee un error de validación igual a 0.2261, frente al de la 4 - 12 - 1 que vale 0.2268. Además, el error asociado de test de esta arquitectura más simple es menor (0.2123 frente a 0.2606). Valores en $(\text{mm}/\text{día})^2$. De acuerdo con la metodología seguida, se ha dado prioridad a la arquitectura más sencilla, pues la diferencia de errores (0.0007) es menor al margen establecido (0.008)

Los demás gráficos que representan la evolución del error cuadrático frente al número de neuronas consideradas en las demás estaciones se hallan en los apartados C.2.1.1 y C.2.2.1 del anejo C. Las arquitecturas óptimas de los modelos de 4 y 7 inputs se hallan resumidas en la tabla 3.7, donde se incluyen también los indicadores de rendimiento de dichos modelos. No se presentan los errores de entrenamiento y verificación por estar implícitos en las figuras citadas anteriormente.

Tabla 3.7. Índices de rendimiento de las arquitecturas óptimas de 4 y 7 inputs para los sets de test, obtenidos con el *Matlab Editor*. MSE en (mm/día)²

Modelo ANN		4 inputs		7 inputs	
arquitectura óptima		4 - 12 - 1		7 - 17 - 1	
índice		MSE	c	MSE	c
Altea	Altea	0.2123	0.9588	0.0142	0.9968
	Benavites	0.4373	0.8963	0.0458	0.9904
	Campo Arcís	0.3820	0.9352	0.2403	0.9695
	Castalla	0.5929	0.9057	0.2212	0.9693
	media test exterior	0.4707	0.9124	0.1691	0.9764
arquitectura óptima		4 - 8 - 1		7 - 12 - 1	
índice		MSE	c	MSE	c
Benavites	Altea	0.4965	0.9167	0.0555	0.9925
	Benavites	0.3000	0.9154	0.0210	0.9942
	Campo Arcís	0.4675	0.9332	0.0930	0.9846
	Castalla	0.9303	0.8908	0.1590	0.9732
	media test exterior	0.5659	0.9131	0.0910	0.9840
arquitectura óptima		4 - 12 - 1		7 - 17 - 1	
índice		MSE	c	MSE	c
Campo Arcís	Altea	0.2854	0.9376	0.0400	0.9924
	Benavites	0.3547	0.9058	0.0301	0.9922
	Campo Arcís	0.3541	0.9420	0.0235	0.9961
	Castalla	0.6467	0.9060	0.0492	0.9913
	media test exterior	0.4518	0.9179	0.0343	0.9932
arquitectura óptima		4 - 16 - 1		7 - 13 - 1	
índice		MSE	c	MSE	c
Castalla	Altea	0.7104	0.9039	0.0931	0.9829
	Benavites	0.8956	0.8628	0.0555	0.9851
	Campo Arcís	0.4250	0.9391	0.0468	0.9923
	Castalla	0.3706	0.9334	0.0392	0.9932
	media test exterior	0.5637	0.9118	0.0472	0.9902

En general, cuando se testa el modelo en la sede de entrenamiento, los resultados son del mismo orden de magnitud que los obtenidos mediante el *Toolbox*, En Altea 0.2129 frente a 0.2123, en Benavites 0.3 frente a 0.3537, en Campo Arcís 0.3541 frente a 0.2784 y en Castalla 0.3706 frente a 0.5442.

En cuanto a la capacidad de generalización de los modelos fuera de la sede, la pauta de comportamiento se mantiene en líneas generales. La leve caída de rendimiento en algunos casos, por ejemplo el modelo entrenado en Castalla, puede ser debido a la elección de arquitecturas más complejas, con menor capacidad de generalización,

debido al cambio de criterio seguido en este apartado por los motivos aludidos anteriormente.

Todo lo dicho en los dos párrafos anteriores es extrapolable para el modelo de 7 inputs. Además, al igual que con los resultados obtenidos con el *Toolbox*, llama la atención la baja calidad relativa de los modelos entrenados en sedes costeras y testados en estaciones de interior (Altea en Campo Arcís y Castalla, 0.2403 y 0.2212, respectivamente, Benavites en Campo Arcís y Castalla, 0.093 y 0.159, respectivamente). Valores en (mm/día)².

Las tendencias de los modelos de 4 y 7 inputs a infraestimar y sobreestimar parecen concordar con las de los modelos obtenidos con ayuda del *Neural Networks Toolbox*. Los gráficos correspondientes se hallan en los apartados C.2.1.2 y C.2.2.2 del anejo C.

Estos resultados inducen a pensar que 5 repeticiones son suficientes para evitar el efecto de la asignación inicial aleatoria de pesos.

Finalmente, parece lógico cuestionar la idoneidad del uso del error medio cuadrático (MSE) como indicador del rendimiento de la red en tanto que no proporciona un indicador absoluto que permita comparar resultados correspondientes a conjuntos de test distintos. Esto se debe a que la exactitud de un modelo puede resultar relativa según el orden de magnitud de los valores de test que se han utilizado para calcular el MSE. Por ello, en adelante parece aconsejable utilizar también otros índices de rendimiento, como el error medio absoluto relativo o AARE (average absolute relative error), definido como

$$AARE = \frac{1}{n} \cdot \sum_{i=1}^n \left| \frac{y_{m_i} - y_{e_i}}{y_{e_i}} \right| \quad (3.24)$$

donde y_m son los valores obtenidos con el modelo, y_e son los valores experimentales y n hace referencia al número de elementos utilizados para obtener la media.

3.4. Conclusiones

En general, la validez del modelo ANN de 4 inputs propuesto por Zanetti et al. (2007) debe restringirse para estimar valores locales de ET_0 en la sede de entrenamiento, pues la capacidad de generalización del modelo es deficiente. La mejora de las prestaciones del modelo pasa por la consideración de nuevas variables que puedan resultar decisivas en el fenómeno de la evapotranspiración, como la humedad relativa o la velocidad del viento.

Asimismo, la aplicación de dicho modelo sólo parece lógica en la sede y, sólo, cuando el uso de la ecuación de Penman-Monteith no es viable, por falta de datos disponibles, a causa de averías en el sistema de medida o porque la estación que se utilizó para generar datos para crear el modelo simplemente ya no está disponible.

El comportamiento del modelo depende del contexto continental o de régimen térmico de la sede de entrenamiento, caracterizado aquí por medio del índice de continentalidad IC. Así, en estaciones costeras, dentro de un intervalo de IC concreto por determinar, donde el mar suaviza las oscilaciones térmicas, las redes son capaces de generar mejores vinculaciones input-output que en estaciones de interior, donde las fluctuaciones térmicas son más drásticas. Por el contrario, en estas últimas, dentro de otro rango de IC, por el mismo motivo, se contempla un rango de variables más amplio y, así, los modelos entrenados en ellas poseen mejor capacidad de generalización que las sedes costeras. Estos índices de continentalidad deberían servir para trazar zonas de aplicabilidad del modelo de una sede concreta, donde el test fuera de la sede podría darse por aceptable.

La automatización del proceso de selección de la arquitectura óptima exige un análisis detallado que clarifique la reducción máxima admisible del número de neuronas que justifique un incremento dado sobre el error mínimo de validación cruzada.

A la vista de los errores asociados al proceso de entrenamiento, analizando conjuntamente el error de entrenamiento, validación cruzada y test, parece que una capa oculta resulta suficiente para establecer la relación no lineal entre los inputs y el output, tal como apuntaban Kumar et al. (2002) y Arca et al. (2004).

En este estudio se crearon cuatro modelos ANN que fueron testados en la sede y en tres estaciones exteriores frente al caso de estudio pionero (Zanetti et al., 2007), donde sólo se creó un único modelo que se testó con datos locales y en una estación cercana a la sede. Sin embargo, cuatro casos de estudio siguen sin permitir sacar conclusiones definitivas sobre la validez y el ámbito de aplicabilidad del modelo ANN de 4 inputs y exigen un análisis más exhaustivo y detallado, considerando un número mayor de localidades enmarcadas dentro de un abanico más amplio de condiciones continentales.

En este modelo neuronal analizado, repetir 5 veces el proceso de entrenamiento basta para paliar los efectos derivados de la asignación inicial aleatoria de pesos

capítulo 4

predicción de ET_0 aplicando ANNs
y suplantación de datos

4.1. INTRODUCCIÓN.....	99
4.2. MATERIALES Y MÉTODOS.....	99
4.2.1. OBTENCIÓN DE DATOS CLIMÁTICOS.....	100
4.2.2. GESTIÓN DE DATOS CLIMÁTICOS.....	100
4.2.3. OBTENCIÓN DE TARGETS Y CARACTERIZACIÓN DE ESTACIONES	101
4.2.4. GESTIÓN DE INPUTS Y MODELOS CONSIDERADOS	103
4.2.5. PROPIEDADES DE LAS REDES NEURONALES UTILIZADAS	111
4.2.6. IMPLEMENTACIÓN EN <i>MATLAB</i>	112
4.3. RESULTADOS Y DISCUSIÓN.....	116
4.3.1. SELECCIÓN DEL RANGO MÁXIMO DE IC. SELECCIÓN DEL MODELO Y DE LA ALTERNATIVA DE TEST ÓPTIMOS.....	116
4.3.2. ANÁLISIS DEL MODELO ÓPTIMO.....	123
4.4. CONCLUSIONES	133
4.5. TRABAJO FUTURO	134

4.1. Introducción

Al final del capítulo 3 se sugirió la posibilidad de mejorar el modelo ANN de 4 inputs partiendo de la premisa de considerar nuevas variables climáticas que pudieran resultar determinantes en el fenómeno de la evapotranspiración.

Durante los últimos años se han llevado a cabo diversos estudios sobre la importancia relativa de distintas variables climáticas consideradas en la determinación de la evapotranspiración de referencia (Saxton, 1975; Smajstrla et al., 1987; Sohrabi et al., 1988; Piper, 1989; Ley et al., 1994; Mohan y Arumugam, 1996; Rana y Katerji, 1998; Hupet y Vanclooster, 2001; Irmak et al., 2006). Irmak et al. (2006) y Mohan y Arumugam (1996) destacan la relevancia de la humedad relativa en el proceso de la evapotranspiración. Por ello, el modelo ANN de 4 inputs, basado fundamentalmente en medidas de temperatura, podría presentar bajos índices de rendimiento cuando se utiliza para estimar ET_0 fuera de la sede a causa de la omisión de la humedad relativa como variable de entrada, debido a la especificidad de las relaciones locales entre temperatura y ET_0 .

Así pues, en este capítulo se presenta un nuevo modelo ANN de 6 inputs que permite la predicción de la evapotranspiración de referencia a partir de datos locales de temperatura máxima y mínima, número de horas de sol, radiación extraterrestre (donde las últimas dos variables son función de la latitud de la estación y del día del año) y datos exógenos de humedad relativa y ET_0 de estaciones con índices de continentalidad similares. Es conveniente tener presente que, aunque el modelo demande dos variables de entrada más que el anterior modelo de 4 inputs, éstas no corresponden a la estación de test, por lo que este modelo sigue exigiendo, exclusivamente, datos de temperatura en la estación estudiada.

4.2. Materiales y métodos

A diferencia del capítulo anterior, en éste todos los cálculos se realizaron con el *Matlab Editor*, aprovechando la mayor versatilidad que ofrece la programación. Como se verá, el planteamiento del problema exigirá, entre otras cosas, la propuesta de criterios de

selección de estaciones secundarias proveedoras de datos para cada caso, lo que justifica la implementación de un programa específico apropiado.

4.2.1 OBTENCIÓN DE DATOS CLIMÁTICOS

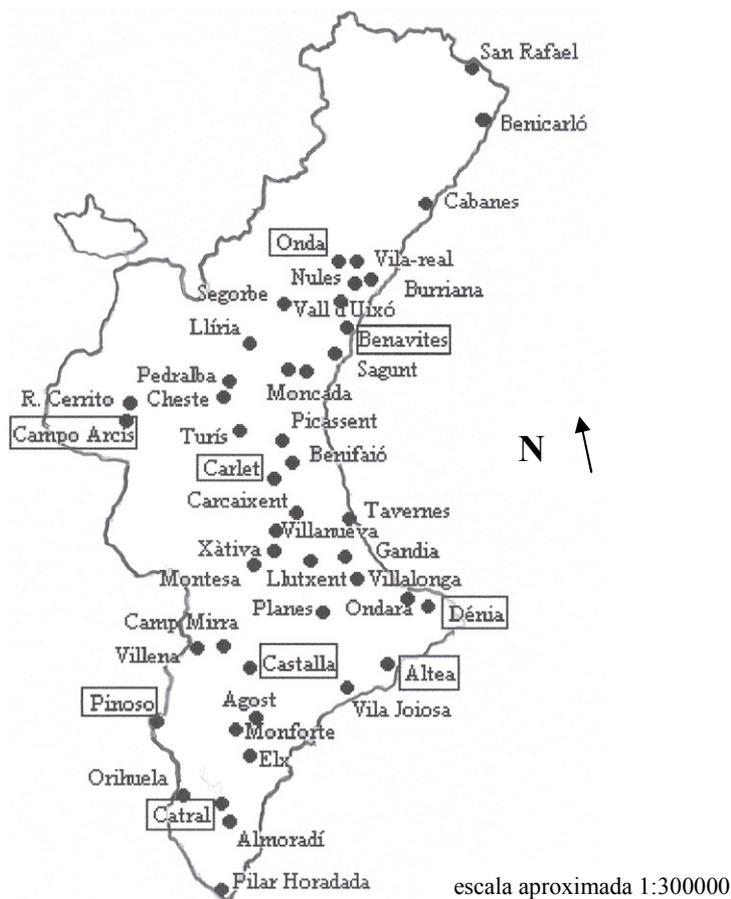
Al igual que en el capítulo anterior los datos provienen de la red de estaciones climáticas del Instituto Valenciano de Investigaciones Agrarias y las propiedades de los equipos son las mismas. Sin embargo, con el objetivo de poder dar mayor generalidad a las conclusiones a extraer, se han utilizado cuarenta y tres estaciones, repartidas por toda la comunidad. Dichas estaciones se han elegido fundamentalmente por criterios de disponibilidad de datos y de caracterización de continentalidad, de tal manera que se contara con un número semejante de estaciones con un mismo patrón continental. Las estaciones consideradas se muestran en la figura 4.1, donde sólo aquellas englobadas en un recuadro han servido para entrenar modelos ANN. El resto ha servido para testar el potencial de generalización de dichos modelos.

4.2.2. GESTIÓN DE DATOS CLIMÁTICOS

Las estaciones que actuaron como sedes de entrenamiento de los modelos ANN fueron escogidas de tal manera que presentaran la misma cantidad de datos climáticos y pertenecieran a contextos variados de continentalidad. Así, se utilizaron los datos correspondientes al periodo entre enero de 2000 y enero de 2008, que pueden considerarse normales desde un punto de vista climático, sin fluctuaciones radicales durante dicho intervalo. Los datos de 2004 y 2006 fueron destinados para los procesos de validación cruzada y test, respectivamente, mientras que el resto de años se reservó para llevar a cabo el entrenamiento (2183 patrones de aprendizaje). La asignación de los años para las fases de entrenamiento, validación cruzada y test no fue establecida cronológicamente en tanto que no todas las estaciones de test contaban con suficientes datos de 2007 y las estaciones sede presentaban un número considerable de huecos en 2005. Sin embargo, este hecho no altera la validez del estudio, debido al carácter aleatorio y fluctuante de los fenómenos meteorológicos.

Al contrario que en el capítulo anterior, en este caso no se ha generado un modelo ANN de control (modelo de 7 inputs), pues su implementación en *Matlab* es muy distinta y no permitiría verificar nada.

Figura 4.1. Situación geográfica de las estaciones climáticas utilizadas en el estudio



4.2.3. OBTENCIÓN DE TARGETS Y CARACTERIZACIÓN DE ESTACIONES

Nuevamente, la ecuación FAO-56 Penman Monteith fue utilizada para generar los targets o valores deseados para entrenar los modelos neuronales, al ser el método estándar para determinar ET_0 (Allen et al., 1998). Tal y como se explicará más adelante, dichos valores de ET_0 también serán considerados como variables de entrada cuando actúen como datos auxiliares procedentes de estaciones secundarias.

Por otra parte, se ha utilizado el índice de continentalidad IC, definido en el capítulo anterior, para caracterizar el grado de oscilación térmica de cada estación. Asimismo, se han comparado los resultados del modelo que se propone con los de dos modelos *térmicos*: el método de Hargreaves (Hargreaves y Samani, 1985) y el modelo ANN de 4 inputs (Zanetti et al., 2007). Las expresiones de todos los parámetros necesarios para la aplicación de dichos modelos ya se presentaron en el capítulo 3. La tabla 4.1 presenta los datos que caracterizan a las estaciones consideradas en este estudio.

Tabla 4.1. Caracterización de las estaciones climáticas de estudio

estación	código	papel	años considerados	latitud (° ' ")	longitud (° ' ")	altitud (m)	IC (-)
Pilar de la Horadada	1-1	test	2006	37 52 12 N	00 48 37 W	77	0.2475
Altea	1-2	sede	2000-2008	38 36 20 N	00 04 39 W	210	0.2486
Vila Joiosa	1-3	test	2006	38 31 46 N	00 15 19 W	138	0.2565
Tavernes de Valldigna	1-4	test	2006	39 05 47 N	00 14 12 W	15	0.3497
Sagunt	1-5	test	2006	39 38 57 N	00 17 33 W	33	0.3738
Ribera de Cabanes	1-6	test	2006	40 08 06 N	00 08 51 E	34	0.4040
Benavites	1-7	sede	2000-2008	39 44 00 N	00 12 54 W	8	0.4671
Borriana	1-8	test	2006	39 53 20 N	00 06 16 W	98	0.4785
Ondara	1-9	test	2006	38 49 11 N	00 00 27 E	49	1.1278
Denia-Gata	1-10	sede	2000-2008	38 47 38 N	00 05 01 E	102	1.2241
Vall d'Uixó	1-11	test	2006	39 47 51 N	00 13 38 W	100	1.5365
Vila Real	1-12	test	2006	39 56 00 N	00 06 00 W	42	1.8533
Villalonga	2-1	test	2006	38 53 35 N	00 11 29 W	92	2.1436
Gandía	2-2	test	2006	38 57 55 N	00 14 58 W	113	2.2024
Benicarló	2-3	test	2006	40 24 42 N	00 24 06 E	12	2.6750
Almoradí	2-4	test	2006	38 05 27 N	00 46 17 W	74	2.6972
Moncada	2-5	test	2006	39 37 11 N	00 20 56 W	35	2.7400
Elx	2-6	test	2006	38 16 00 N	00 42 00 W	86	2.8967
Picassent	2-7	test	2006	39 21 49 N	00 29 47 W	115	2.9316
San Rafael del Rio	2-8	test	2006	40 35 44 N	00 22 13 E	205	3.0396
Llutxent	2-9	test	2006	38 54 10 N	00 23 52 W	200	3.1780
Catral	2-10	sede	2000-2008	38 09 16 N	00 48 15 W	27	3.6088
Agost	2-11	test	2006	38 25 40 N	00 38 36 W	345	3.6360
Villanueva	2-12	test	2006	39 04 00 N	00 31 22 W	58	4.1082
Carcaixent	2-13	test	2006	39 07 00 N	00 26 00 W	35	4.3031
Monforte del Cid	2-14	test	2006	38 23 59 N	00 43 44 W	244	4.4712
Carlet	2-15	sede	2000-2008	39 07 00 N	00 26 00 W	35	4.5356
Planes	2-16	test	2006	38 47 08 N	00 21 04 W	519	4.7903
Castalla	3-1	sede	2000-2008	38 36 19 N	00 40 22 W	708	5.0039
Onda	3-2	sede	2000-2008	39 58 12 N	00 12 31 W	185	5.0395
Xàtiva	3-3	test	2006	38 59 59 N	00 32 55 W	124	5.1868
Segorbe	3-4	test	2006	39 49 05 N	00 28 54 W	358	5.6787
Orihuela	3-5	test	2006	38 10 58 N	00 57 13 W	99	6.1311
Turís	3-6	test	2006	39 24 02 N	00 41 01 W	299	6.3450
Montesa	3-7	test	2006	38 57 20 N	00 38 13 W	267	6.8242
Pedralba	3-8	test	2006	39 34 04 N	00 42 59 W	200	7.2597
Lliria	3-9	test	2006	39 41 31 N	00 37 31 W	250	7.7561
Cheste	3-10	test	2006	39 31 18 N	00 44 30 W	323	8.3233
Pinoso	3-11	sede	2000-2008	38 25 43 N	01 03 34 W	606	8.3561
Camp de Mirra	3-12	test	2006	38 40 49 N	00 46 18 W	627	9.1614
Villena	3-13	test	2006	38 35 48 N	00 52 24 W	495	9.6550
Requena Cerrito	3-14	test	2006	39 29 00 N	01 06 00 W	692	14.9251
Campo Arcís	3-15	sede	2000-2008	39 26 04 N	01 09 39 W	584	15.5038

4.2.4. GESTIÓN DE INPUTS Y MODELOS CONSIDERADOS

En este capítulo se propone un modelo ANN nuevo que considera 6 inputs: temperatura máxima, temperatura mínima, horas de sol diarias, radiación solar, humedad relativa y evapotranspiración de referencia exógena.

En general, las novedades que introduce el presente modelo de 6 inputs consisten, en comparación con el modelo de 4 inputs (Zanetti et al., 2007), en la consideración de datos climáticos exógenos (datos procedentes de estaciones secundarias de apoyo) y la aplicación preliminar de modelos ANN para la generación de datos de radiación solar (R_s) y humedad relativa (HR), que posteriormente serán utilizados como inputs en el modelo ANN para predicción de ET_o . De esta manera, el modelo de 6 inputs requiere las mismas variables de la estación de test que el modelo de 4 inputs (temperaturas diarias máxima y mínima y latitud), pero, por otra parte, saca partido de valores procedentes de predicciones preliminares de humedad relativa y radiación solar y valores de ET_o^{PM} de estaciones con un IC similar. Así, dicho IC es utilizado para seleccionar las estaciones secundarias más apropiadas que actuarán como proveedoras de datos auxiliares.

Por una parte, cada vez se generan tres modelos ANN. Además del modelo final para predicción de ET_o , se desarrollan dos modelos ANN preliminares para generar dos variables climáticas que no estarán disponibles en las estaciones de test, la radiación solar y la humedad relativa, variables que van a ser necesarias a la hora de aplicar el modelo de ET_o . Por otra, las variables input de entrenamiento consideradas pueden proceder de la misma sede donde se entrena el modelo o de una sede secundaria con índice de continentalidad similar. Así, dependiendo de las variables input tenidas en cuenta en el aprendizaje de los tres modelos involucrados en el proceso (R_s , HR y ET_o) así como de su origen (variables locales o exógenas), se analizaron seis alternativas de modelo. La tabla 4.2 esquematiza el conjunto de alternativas que se han estudiado en la modelación de R_s , HR y ET_o , atendiendo a la combinación de variables consideradas así como a su origen respectivo.

Es importante aclarar el doble papel desempeñado por las variables HR y ET_o . En relación con el modelo preliminar para predicción de humedad relativa, los datos locales

de HR actúan como targets o valores respuesta deseados, mientras que los datos exógenos de HR participan como inputs; por otra parte, en relación con el modelo para predicción de ET_o, los valores de HR (locales o exógenos) y los valores exógenos de ET_o se consideran como inputs, mientras que los valores de ET_o local actúan como targets.

De esta manera, se están planteando dos modelos que dependen de la misma variable que se pretende determinar, aunque procedente de otra estación enmarcada en un contexto climático parecido. Es decir,

$$ET_o = f(ET_o') \quad (4.1)$$

$$HR = f(HR') \quad (4.2)$$

donde el superíndice indica que la variable procede de otras estaciones. Este planteamiento pretende comprobar si las ANNs son capaces de vincular la tendencia de su variable de salida (ET_o o HR) con la que presenta ésta en estaciones similares desde el punto de vista de la continentalidad, ya que las redes no atienden al significado físico de las variables que consideran. De igual forma, se ha planteado algún modelo (tabla 4.2) del tipo

$$R_s = f(ET_o') \quad (4.3)$$

Tabla 4.2. Resumen de variables consideradas en los distintos modelos para predicción de radiación solar, humedad relativa y evapotranspiración de referencia

fase de entrenamiento: variables input				
caso	origen de las variables	modelo preliminar R_s	modelo preliminar HR	modelo final ET_o
0	sede principal	T _{max} T _{min} R _a N	T _{max} T _{min} R _s N ET _o	T _{max} T _{min} HR R _s N
	sede auxiliar	-	HR	ET _o
1	sede principal	T _{max} T _{min} R _a N	T _{max} T _{min} R _s N	T _{max} T _{min} HR R _s N
	sede auxiliar	-	HR	ET _o
2	sede principal	T _{max} T _{min} R _a N	T _{max} T _{min} N	T _{max} T _{min} N
	sede auxiliar	-	R _s HR ET _o	R _s HR ET _o
3	sede principal	T _{max} T _{min} R _a N	T _{max} T _{min} R _s N	T _{max} T _{min} HR R _s N
	sede auxiliar	ET _o	HR ET _o	ET _o
4	sede principal	T _{max} T _{min} R _a N	T _{max} T _{min} N	T _{max} T _{min} N
	sede auxiliar	ET _o	R _s HR ET _o	R _s HR ET _o
5	sede principal	T _{max} T _{min} R _a N	T _{max} T _{min} R _s N	T _{max} T _{min} R _s N
	sede auxiliar	-	HR ET _o	HR ET _o

No se trata de probar combinaciones al azar, sino de relacionar tendencias de variables correspondientes a estaciones muy similares. Por otra parte, si se analizan las variables

que intervienen en cada modelo de la tabla 4.2, se comprobará que el sentido del modelo es distinto según se aplique en una estación de test o en una sede. Así, en condiciones normales, en la sede ya se dispone de suficientes variables climáticas para aplicar la ecuación PM. Por ello, los modelos planteados sólo tienen sentido en las sedes cuando las variables extra (HR y R_s) dejan de estar disponibles, por ejemplo, a causa de una avería en la estación meteorológica o porque ésta simplemente ya no existe. Siguiendo este razonamiento puede decirse que estos modelos cobran todo su sentido al ser aplicados fuera de la sede. Finalmente, con algunas de las alternativas de la tabla 4.2, al considerar variables no sólo de la sede principal, sino también de una sede auxiliar, se pretende simular la situación en la que estos modelos van a ser realmente útiles, es decir, en una estación de test en la que se importarán datos de otra estación auxiliar.

En primer lugar, se crea el modelo preliminar para predecir valores de radiación solar R_s . Los inputs procedentes de la sede de entrenamiento son temperatura máxima, temperatura mínima, radiación extraterrestre y horas de sol diarias. Sin embargo, hay dos alternativas, la 3 y la 4, que también consideran como inputs valores de ET_o^{PM} que provienen de una estación secundaria.

En segundo lugar, se crea el modelo preliminar para estimar valores de humedad relativa HR . En este caso, los valores de temperatura máxima, temperatura mínima y horas de sol diarias siempre proceden de la sede principal; los valores de humedad relativa siempre provienen de una sede secundaria similar a la principal; el resto de variables, radiación solar y evapotranspiración, según la alternativa estudiada, pueden proceder de la sede principal o de una sede secundaria.

Finalmente, en el mismo sentido, en la fase de entrenamiento del modelo de 6 inputs para predicción de ET_o se consideran siempre valores locales de la sede principal de temperatura máxima, temperatura mínima y horas de sol diarias, valores exógenos de ET_o (los valores locales son targets) y valores locales o externos de radiación solar y humedad relativa. Para facilitar la comprensión de la idea propuesta, las figuras 4.2 a 4.4 ilustran el desarrollo del modelo ANN de 6 inputs, paso a paso, para el caso concreto de la alternativa 3. En general, pueden establecerse dos etapas en la gestión de los datos climáticos: la generación del modelo (modelo preliminar R_s en figura 4.2,

modelo preliminar HR en figura 4.3, y modelo ET_0 en figura 4.4) y la simulación o test del modelo (figura 4.5). Para simplificar los esquemas, en las cuatro figuras, los datos auxiliares provienen exclusivamente de la estación secundaria con índice de continentalidad más cercano al de la estación considerada. En estas figuras las variables subrayadas son las que funcionan como targets en el proceso de aprendizaje de la red neuronal. Los modelos que se crean están asociados a la sede principal (sede 1) al ser la estación que más datos aporta al proceso.

Conviene tener presente que en el momento de testar el modelo de ET_0 , los valores de radiación solar y humedad relativa proceden de simulaciones de los modelos preliminares creados. Asimismo, como existen nueve sedes de entrenamiento, cuando llega el momento de testar el modelo de ET_0 , se debe escoger una de las nueve simulaciones que existen por estación de test. A priori, el modelo (sede) que se utiliza para determinar ET_0 no tiene por qué ser el mejor para proveer las simulaciones preliminares de HR y R_s . Así, se pueden seguir varias estrategias, según qué modelo se elija para proveer dichas estimaciones preliminares.

Figura 4.2. Esquema de la generación del modelo para predicción de ET_0 particularizado para la alternativa 3. Paso 1: creación del modelo preliminar de R_s

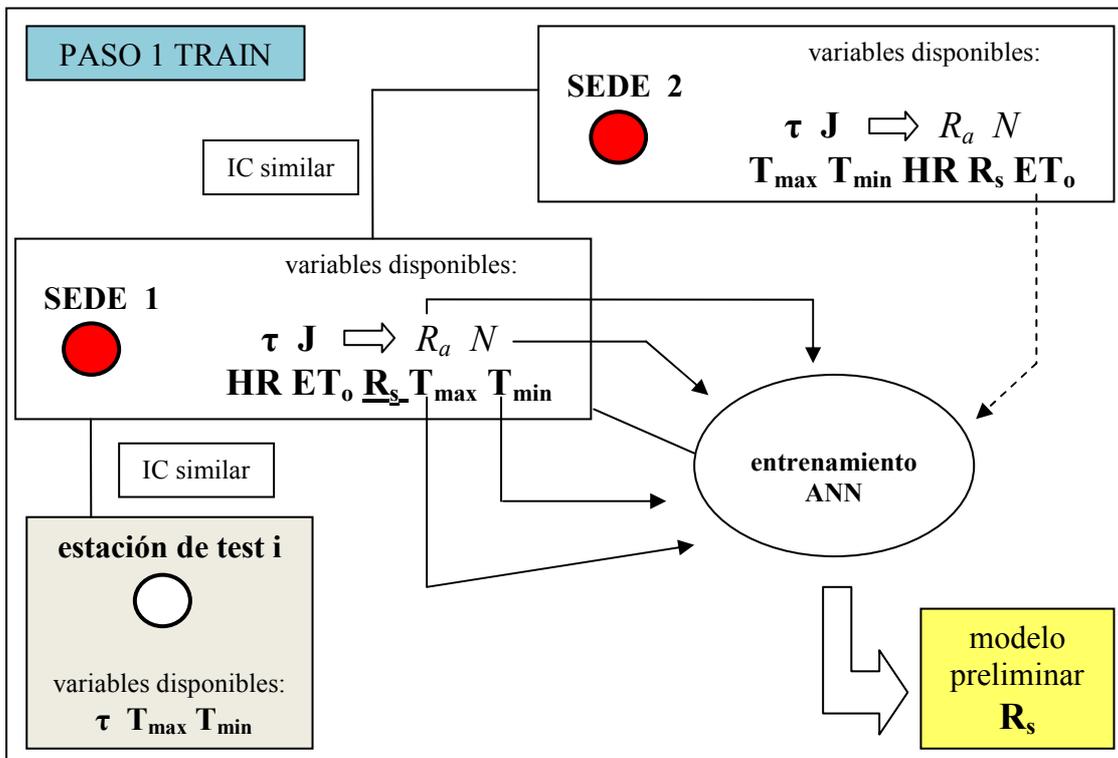


Figura 4.3. Esquema de la generación del modelo para predicción de ET_0 particularizado para la alternativa 3. Paso 2: creación del modelo preliminar de HR

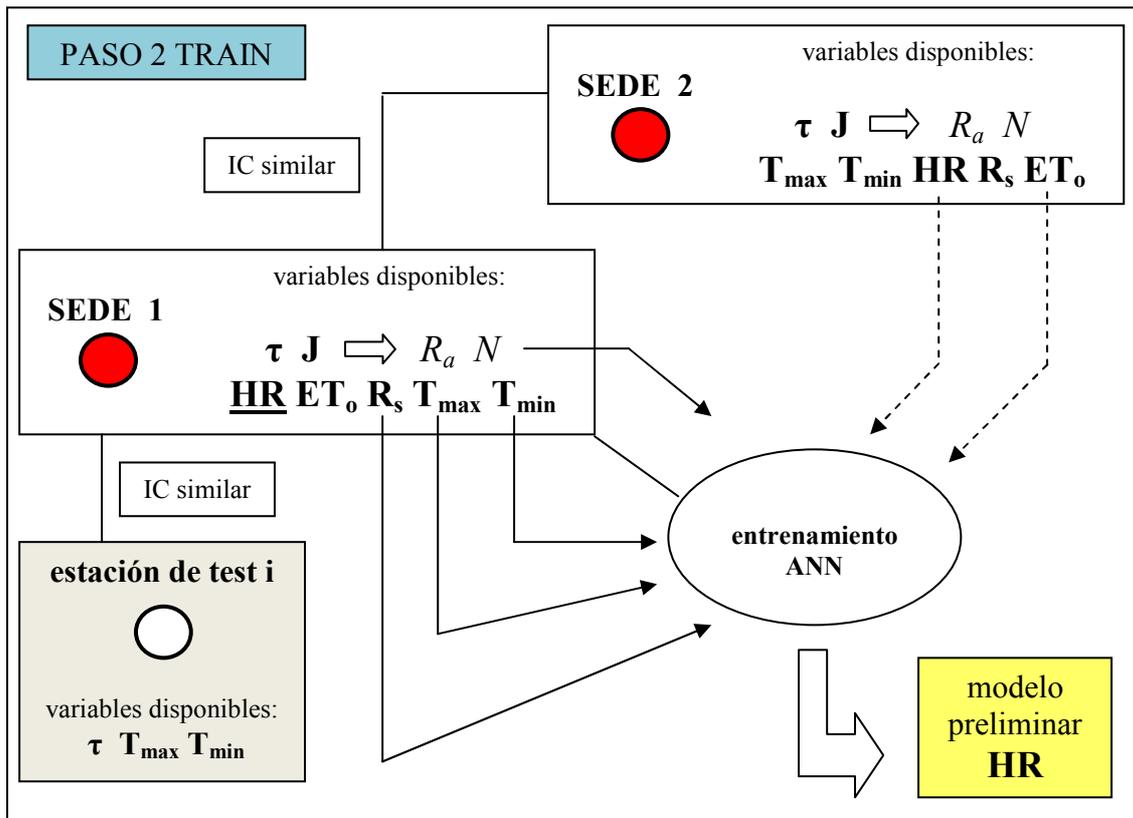


Figura 4.4. Esquema de la generación del modelo para predicción de ET_0 particularizado para la alternativa 3. Paso 3: creación del modelo de ET_0

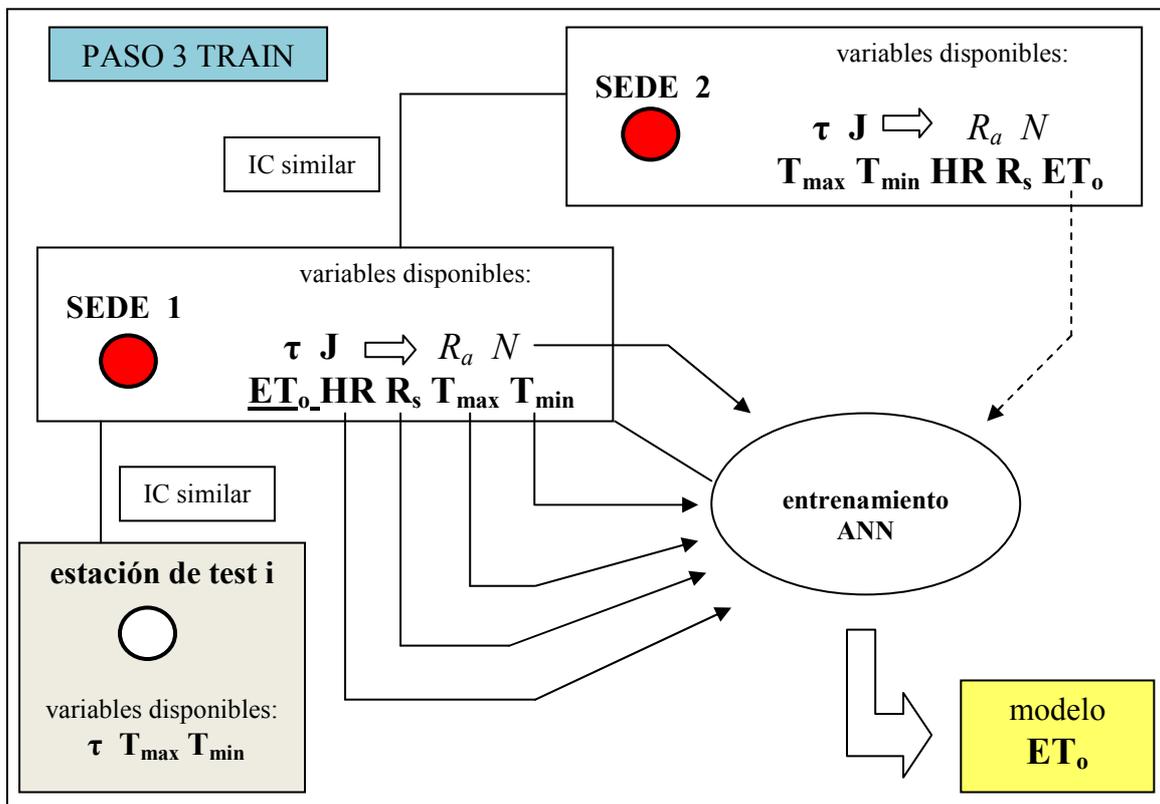
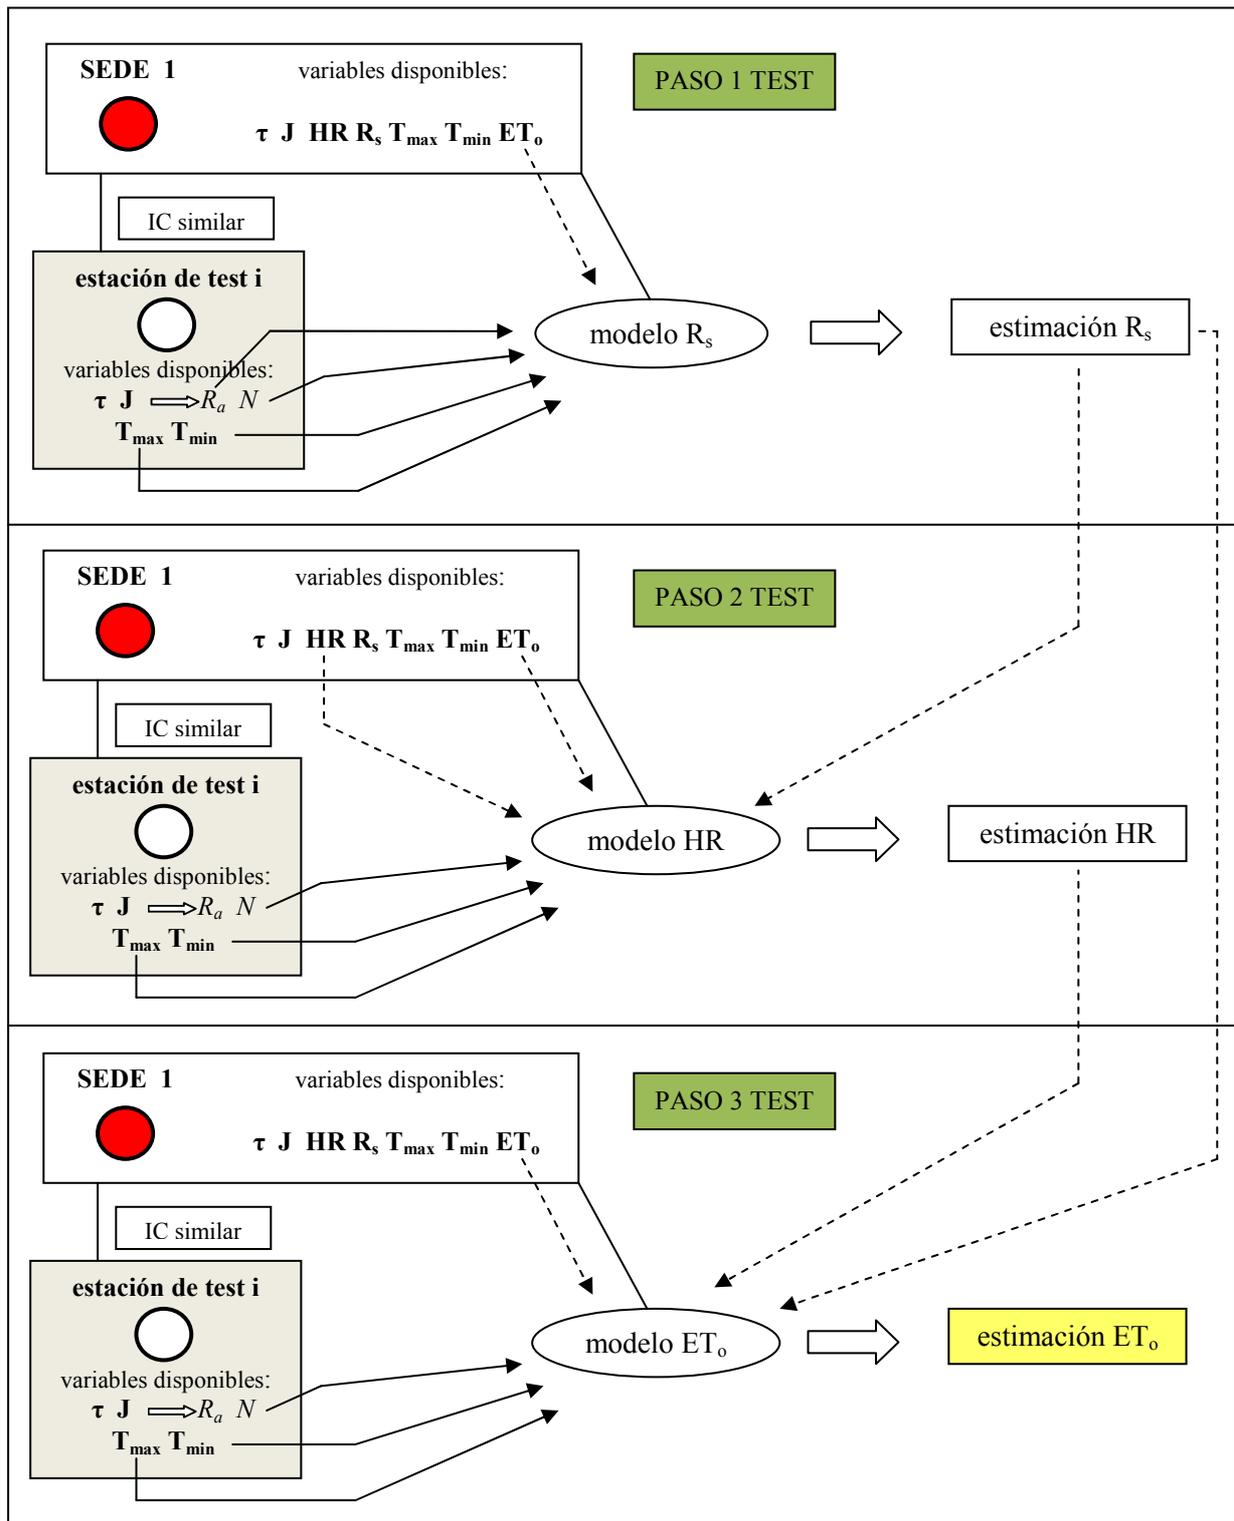


Figura 4.5. Esquema del proceso de simulación del modelo ANN para predicción de ET_o en una estación de test con una única estación auxiliar



Las estaciones han sido agrupadas en tres clases en función de sus respectivos valores de IC. De esta manera, se crearon las categorías ‘costera’, ‘intermedia’ e ‘interior’, con rangos de IC comprendidos entre 0-2, 2-5 y 5-20, respectivamente. Atendiendo a este criterio, las sedes quedan divididas en tres por grupo (costeras: Altea, Benavites, Denia;

intermedias: Carlet, Catral, Onda; interiores: Castalla, Campo Arcís y Pinoso). En relación con estas categorías cualitativas se crearon unos códigos que constan de dos números: el primero hace referencia al tipo de estación (1 costera, 2 intermedia, 3 interior) y el segundo hace referencia a la posición ocupada dentro de cada conjunto siguiendo un orden creciente de IC (tabla 4.1), y está relacionado con el orden con que han sido introducido los datos en las matrices y elementos *celda* de *Matlab*. La introducción de dichos códigos responde a dos razones. En primer lugar, son importantes en términos de implementación del programa, como se verá más adelante, pues se utilizan para gestionar la selección de los modelos preliminares de radiación solar y humedad relativa más adecuados para cada modelo final de ET_0 . En segundo lugar, estas categorías han sido propuestas para poder referir a diferentes contextos continentales los resultados finales obtenidos.

Los índices de continentalidad están referidos a una localidad y un intervalo concreto de tiempo, por lo que una misma estación tendrá distintos valores de IC para los subconjuntos de test (un año) y entrenamiento (seis años). Los valores referidos al set de test, que son los que aparecen en la tabla 4.1 se han utilizado para procesar los resultados. Esto justifica que en esta tabla aparezcan dos sedes en la categoría 2 y cuatro en la categoría 3. Sin embargo, las sedes han sido clasificadas atendiendo al set de entrenamiento. Y, así, los valores de los índices de continentalidad correspondientes a las sedes son (siguiendo el mismo orden que antes): costeras (0.229/0.408/1.084), intermedias (4.091/3.418/4.147) e interiores (5.021/17.241/8.585), respectivamente. A la vista de estos números, puede comprobarse que Onda corresponde a la categoría ‘intermedia’ cuando es considerada como sede de entrenamiento (IC=4.147), mientras que se enmarca como ‘interior’ cuando es analizada como estación de test (IC=5.0395). Ello se justifica por el intervalo de tiempo correspondiente y por los valores concretos arbitrarios con que se han definido los límites entre categorías cualitativas de continentalidad. Como se ha comentado la única finalidad de éstos consiste en ser utilizados para referir los resultados para tres intervalos locales de IC.

En general, el proceso de aplicación de cada alternativa contemplada en la tabla 4.2 consiste, en primer lugar, en entrenar los tres modelos, radiación solar, humedad relativa y evapotranspiración de referencia (hay que recordar que existen 9 sedes que generan estos tres modelos), y, en segundo lugar, llegado el momento de testar el modelo de

ET_0 , se pueden seguir diferentes estrategias, según el criterio que se siga para escoger la sede del modelo preliminar de R_s y HR. De entre todas las combinaciones posibles, las que se han considerado aparecen resumidas en la tabla 4.3.

En el **primer caso**, la estación de test y la sede donde se entrenan los modelos preliminares de radiación solar y humedad relativa pertenecen a la misma categoría cualitativa o rango de IC. Por ejemplo, si se quiere testar el modelo de ET_0 en una estación costera (una de las doce), los modelos preliminares de R_s y HR habrán sido entrenados en una sede costera.

En el **tercer caso**, mientras el modelo de humedad relativa se escoge de la misma manera que en el primer caso, el modelo preliminar de radiación solar se entrena en una sede interior. En el **cuarto caso**, ambos modelos preliminares se han entrenado en sedes interiores. Estos tres criterios fueron esbozados a partir de una fase de tanteo que parecía sugerir la posibilidad de que los modelos de humedad relativa y la radiación solar tuvieran mayor potencial de generalización al ser entrenados en estaciones de interior. Ello podría ser debido al hecho de que en estaciones de interior el rango de valores de entrenamiento es más amplio al estar sometidas a mayores fluctuaciones climáticas, como se apuntaba en el capítulo 3.

Tabla 4.3. Alternativas de test consideradas

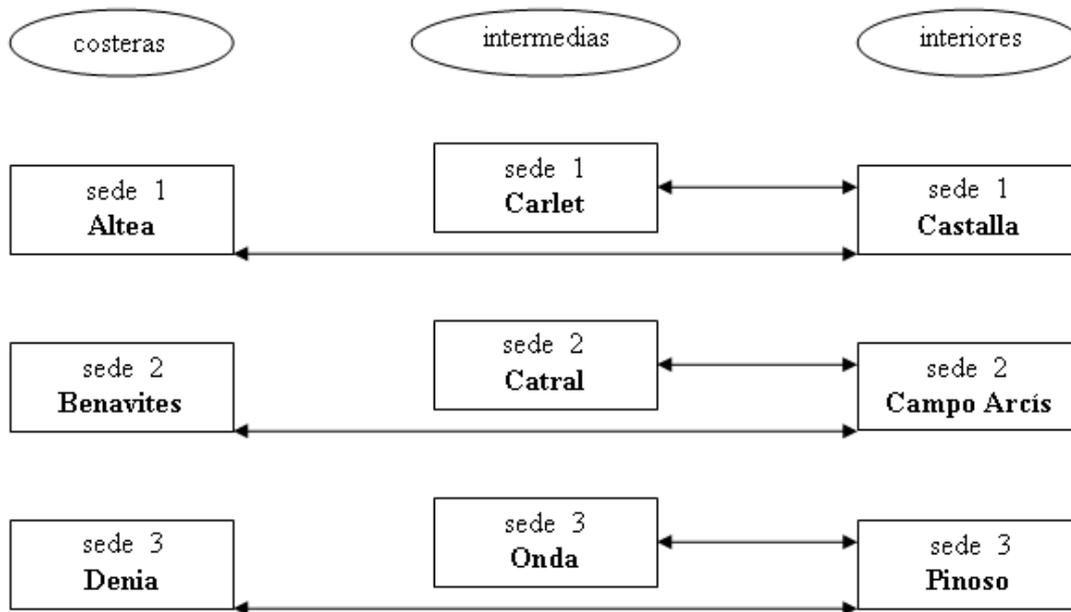
fase de test		
alternativa de test	categoría del modelo preliminar R_s	categoría del modelo preliminar HR
1	estación de test	estación de test
2	estación de test	sustitución directa
3	estación interior	estación de test
4	estación interior	estación interior

Por otra parte, cuando se escoge un modelo de una categoría determinada (costero, intermedio o interior) se plantea el problema de seleccionar una de sus tres sedes. Por ello, a efectos de implementar el programa, se ha fijado una correspondencia fija entre sedes, que se esquematiza en la figura 4.6.

A modo de aclaración, en la alternativa de test número 4, si el modelo de ET_0 ha sido entrenado en la estación Benavites, cuando vaya a ser testado, se utilizarán modelos preliminares de R_s y HR entrenados en Campo Arcís. De la misma manera, en la

alternativa de test 1, si el modelo ha sido entrenado en Castalla, los modelos preliminares de R_s y HR habrán sido entrenados en Castalla cuando se testen estaciones de interior, en Carlet cuando se testen estaciones intermedias y en Altea cuando se testen estaciones costeras.

Figura 4.6. Correspondencia entre sedes para selección de modelos preliminares



Finalmente, en el **segundo caso**, pensando en un posible régimen específico de humedad en las estaciones costeras, las series de humedad en la fase de test del modelo de ET_0 han sido sustituidas directamente por las de una estación con índice de continentalidad similar. El modelo de radiación solar se escogió como en la alternativa 1. Se da la casualidad de que los casos 0 y 1 contemplados en la tabla 4.2, al diferenciarse únicamente en el modelo preliminar de HR, son, al aplicar la alternativa de test 4, iguales en la práctica, excluyendo las diferencias que pudieran derivar de la asignación inicial aleatoria que sufren los pesos en el proceso de aprendizaje.

4.2.5. PROPIEDADES DE LAS REDES NEURONALES UTILIZADAS

Las propiedades de las redes neuronales aplicadas en este capítulo son las mismas que las consideradas en los capítulos 2 y 3. En este caso, todas han sido implementadas exclusivamente con el *Matlab Editor*.

La única diferencia significativa estriba, a raíz de las conclusiones extraídas en el capítulo anterior, en la consideración de un nuevo indicador de calidad del comportamiento de la red, el error relativo absoluto promedio AARE (*average absolute relative error*), definido al final del capítulo 3 (ecuación 3.24).

4.2.6. IMPLEMENTACIÓN EN *MATLAB*

Tal y como se hizo en el programa propuesto en el capítulo anterior, en lugar de seguir la metodología propuesta por Zanetti et al. (2007), donde sólo se tenían en cuenta un pequeño grupo de arquitecturas, se ha desarrollado un programa que selecciona la arquitectura óptima de entre un conjunto donde las ANNs tienen una y dos capas ocultas con una hasta n neuronas, donde las distintas capas ocultas presentan el mismo número de neuronas. Además, cada arquitectura se calcula e veces, siendo almacenados los correspondientes parámetros de cada ANN, para tener en cuenta el efecto derivado de la asignación aleatoria de los pesos de la red cuando se inicia el proceso de entrenamiento. En nuestro caso, tanto n como e volvieron a fijarse en 20.

A diferencia de los capítulos 2 y 3, en lugar del MSE, se utilizó el AARE para seleccionar la arquitectura óptima, siguiendo la misma metodología. Dicho proceso ha sido aplicado por igual a los modelos ANN para predicción de evapotranspiración de referencia, de radiación solar y de humedad relativa.

Como se comentó en el capítulo 3, se ha querido favorecer la selección de arquitecturas con una capa oculta. Así, aunque el mínimo error de verificación correspondiera a una arquitectura con dos capas ocultas, si la diferencia entre dicho error y el mínimo error de validación correspondiente a las arquitecturas con una capa oculta era menor de 0.003, se seleccionaba esta última arquitectura. El valor del rango se ha modificado en relación al capítulo anterior por el uso del AARE.

El programa desarrollado permite establecer el número de estaciones auxiliares que aportan datos exógenos para aplicar el modelo en cada estación de test. Para ello, hay que asignar el valor de la diferencia máxima aceptable entre los valores IC de la estación de test y las estaciones auxiliares que actúan como proveedoras de datos. De esta manera, el programa requiere 3 valores de esas diferencias máximas admisibles de

IC, una por categoría de estación, ya que los órdenes de magnitud de IC varían con la categoría. Cada vez que se va a testar el modelo en una estación, se genera un vector con las diferencias respectivas de IC entre la estación de test y las demás, con lo que se define el valor de la diferencia entre los IC de las dos estaciones, la de test y cada una de las demás. Una vez calculado este vector, sólo las estaciones cuyas diferencias de IC (con respecto a la de test considerada) sean menores que los rangos establecidos para cada tipo de estación serán tenidas en cuenta para calcular la media de los valores auxiliares exógenos. Un análisis de los IC dentro de cada categoría de estaciones permite valorar aproximadamente el número de las mismas que será seleccionado en cada caso para calcular los valores medios. Si el rango establecido es muy grande, todas las estaciones de la categoría contribuyen a calcular los valores medios a exportar. Si este rango es muy pequeño, los inputs exógenos proceden solamente de la estación con IC más similar al de la de test. Finalmente, en un caso intermedio, el número de estaciones que contribuye al valor medio del input exógeno irá variando en función del valor de IC de la estación de test.

Para el caso intermedio (solamente), aunque el programa exige fijar un rango de IC por categoría de estación, la selección de estaciones exógenas que contribuyen al cálculo del valor medio se lleva a cabo considerando las estaciones de todas las categorías, no sólo las del tipo de la estación testada. Esto se debe a que los valores de IC que se han escogido como límite entre las tres categorías son hasta cierto punto arbitrarios. Así, parece apropiado considerar estaciones con categoría distinta a la de test cuando los valores de éstas están próximos al valor límite que separa las distintas categorías. Conviene recordar que las categorías se establecieron pensando en la implementación de los criterios de test en función de los distintos modelos preliminares así como de la evaluación de los rendimientos de los modelos en relación con diferentes rangos continentales.

Para establecer adecuadamente el máximo rango admisible de IC de este caso intermedio se ha implementado otro programa que permite analizar, para una selección dada de dichos rangos, qué estaciones intervendrían en el valor medio exógeno para cada estación de test. Dicho programa, a partir de una matriz con los índices de continentalidad de todas las estaciones y los rangos de IC propuestos, calcula el número medio de estaciones que intervendrían para cada categoría, así como el porcentaje que

éstas suponen dentro del total de estaciones de cada categoría. Así, se buscó una combinación de IC que asegurara un porcentaje medio de 40% de estaciones respecto al total dentro de cada tipo de categoría. Debido a que la distribución de valores de IC dentro de cada categoría de estaciones no es homogénea, si se establece un rango máximo de IC, el número de estaciones que se utilizan para calcular los valores medios exógenos es variable según el valor de IC de la estación testada en relación con el resto. Se podría haber optado por asignar un número fijo de estaciones auxiliares cercanas para cada categoría, pero debido a la distribución de valores de IC, esto habría supuesto, en algunos casos, utilizar para el cálculo de dichos valores medios exógenos estaciones demasiado diferentes de las de test. Esto se hubiera notado especialmente en las estaciones de interior con altos índices de continentalidad, por ejemplo Requena Cerrito y Campo Arcís, con IC muy por encima del resto de las estaciones de su categoría. Por ello, se ha preferido limitar el número de estaciones auxiliares mediante un rango máximo de IC, aunque esto suponga que el número de estaciones auxiliares no siempre sea constante. Así pues, dichos rangos se han escogido de forma que el porcentaje medio de estaciones auxiliares dentro de cada categoría sea de un 40%.

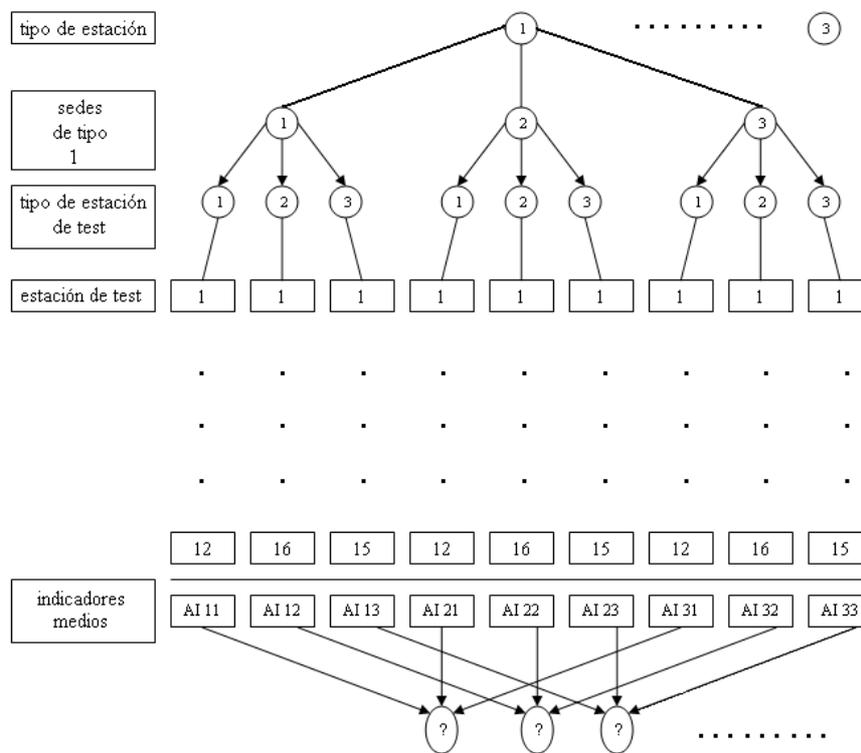
En el caso de selección de sedes secundarias que aportan datos para el aprendizaje del modelo, sólo se utilizó la estación con el IC más parecido al de la sede principal. Ello se justifica por el hecho de que sólo existen tres sedes por categoría. Por ello, de las dos sedes secundarias que hay disponibles cada vez, la menos similar pudiera resultar demasiado diferente.

Finalmente, se ha elaborado otro programa para evaluar la calidad de los distintos modelos de ET_0 entrenados en las 9 sedes. El rendimiento medio de cada sede se evalúa por medio del par MSE-AARE medio obtenido para cada categoría de estaciones de test. De esta manera, se puede caracterizar el rendimiento de cada modelo (sede) en los tres contextos continentales contemplados. A continuación el programa compara los 9 pares de indicadores (uno por sede) correspondientes a cada categoría de test. Es decir, el rendimiento de la sede 1-1 en estaciones de test costeras se compara con el rendimiento medio de las otras 8 sedes en estaciones de test costeras, etc.

El programa selecciona la sede que proporciona los indicadores medios óptimos para cada categoría de estaciones de test. La figura 4.7 representa el proceso de selección

descrito, particularizado para el subcaso de sedes de entrenamiento costeras. De esta manera, faltaría comparar dichos indicadores con los que proporcionan las sedes de entrenamiento intermedias e interiores. El mismo procedimiento se ha aplicado para evaluar el rendimiento de los modelos de 4 inputs (Zanetti et al., 2007), con el que se comparará posteriormente el rendimiento del modelo ANN propuesto de 6 inputs. El modelo de Hargreaves (Hargreaves y Samani, 1985) proporciona una única predicción por estación de test, ya que no contempla el concepto de sede.

Figura 4.7. Proceso de selección de la sede óptima para cada categoría de estación



donde AI hace referencia a indicador medio (*Average Index*)

Las figuras 4.8 y 4.9 representan los procesos implementados en *Matlab* para ejecutar el modelo ANN de 6 inputs. En la primera de ellas se muestran las fases seguidas para crear un modelo genérico ANN (tanto el modelo final para predicción de ET_0 como los modelos preliminares para estimación de R_s y HR).

En la figura 4.9 se resumen las etapas seguidas en la ejecución conjunta de los modelos preliminares y del modelo final. Estas figuras sólo hacen referencia a los procesos fundamentales para no complicar la comprensión del funcionamiento general del

programa. Sin embargo, existen también una serie de programas secundarios de naturaleza puramente *logística* que han sido generados para asegurar la correcta articulación de las operaciones anteriores. Así, el cometido de dichos programas consiste básicamente en armar y acondicionar sistemas de matrices para que puedan ser introducidos en bucles y evitar problemas cuando se les apliquen determinadas funciones.

4.3. Resultados y Discusión

4.3.1. SELECCIÓN DEL RANGO MÁXIMO DE IC. SELECCIÓN DEL MODELO Y DE LA ALTERNATIVA DE TEST ÓPTIMOS

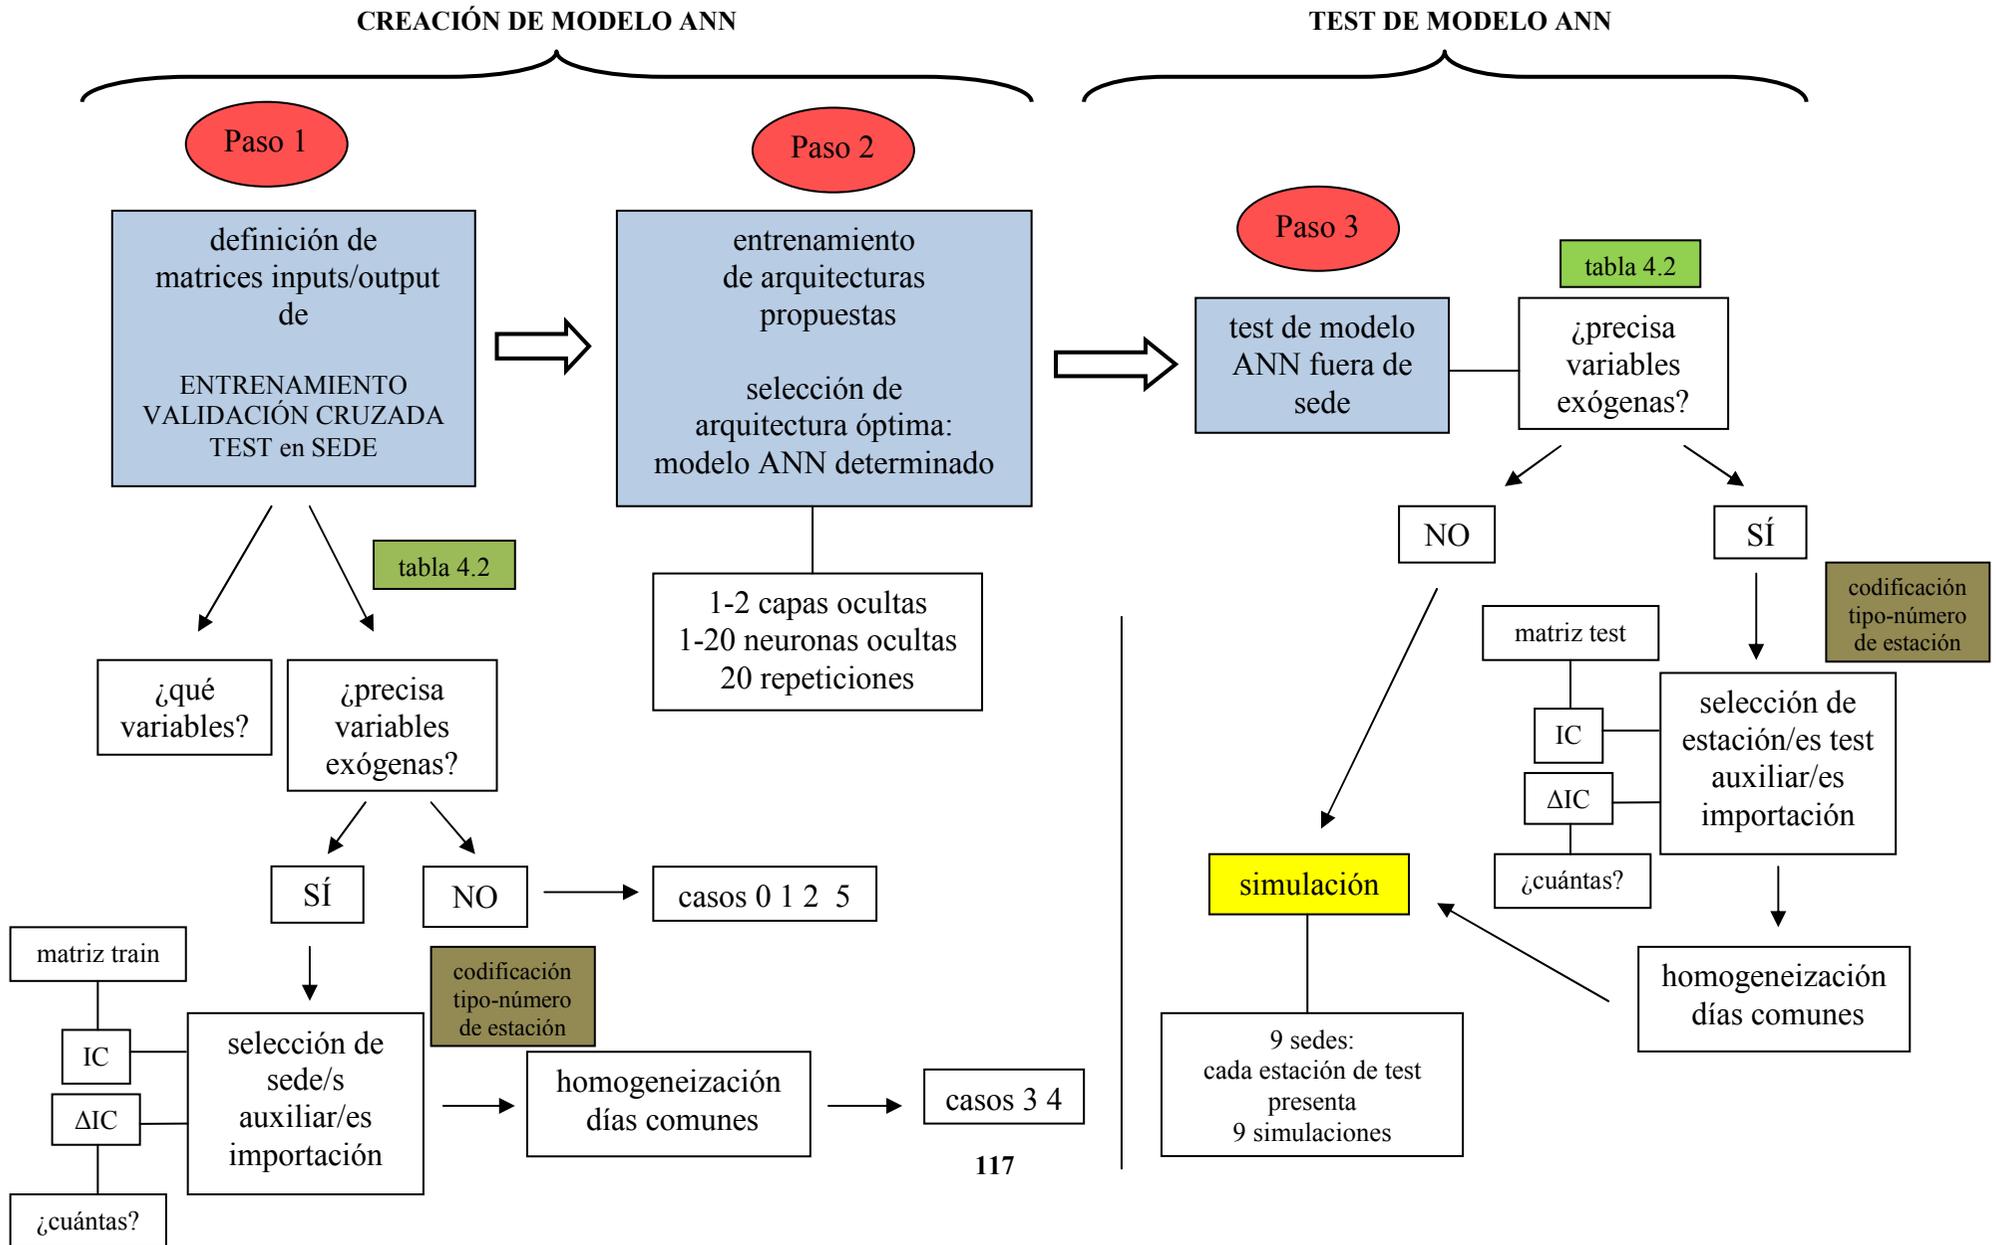
La tabla 4.4 representa los tres casos aludidos anteriormente en relación con la selección de las máximas diferencias admisibles de IC para la selección de estaciones auxiliares.

Tabla 4.4. Selección de máximos rangos admisibles de IC para cálculo de inputs medios exógenos

máximos rangos admisibles de IC			
rango IC	costeras	intermedias	interiores
1	0	0	0
2	1.61	2.65	10.50
3	0.24	0.68	1.40

La primera combinación de rangos corresponde al caso en que la variable importada del exterior corresponde a la estación con IC más parecido a la de test (rangos máximos admisibles de cada tipo de estación igual a 0). El programa contiene un bucle condicional por el que se escoge sólo la estación más parecida cuando el valor del rango es cero. Si se hubieran considerado pocas estaciones auxiliares, se hubiera corrido el riesgo de que esta estación fuera demasiado diferente de la de test. En segundo lugar, se analizan valores de rangos máximos admisibles igual a 1.6059, 2.6467 y 10.4999, respectivamente, según el tipo de estación. Con esta combinación, tal y como está implementado el programa, nos aseguramos que todas las estaciones de un mismo grupo, excepto la de test, contribuyan al valor medio de la variable exógena. Se puede comprobar que dichos valores corresponden a la máxima variación de IC dentro de cada tipo de estación. El tercer caso contempla tres valores establecidos tras varios tanteos y constituye un caso intermedio entre los dos anteriores, donde el porcentaje medio de estaciones utilizadas por categoría es de un 40%, como se comprueba en la tabla 4.5. El número medio de estaciones auxiliares utilizadas varía entre 4.83 y 6.5.

Figura 4.8. Esquema de los procesos implementados en *Matlab* para generar el modelo ANN de 6 inputs 1/2



El desglose de las estaciones auxiliares concretas que intervienen en cada estación de test, así como la diferencia de IC entre cada par se halla recogido en el anejo D (apartado D.1). Conviene destacar el caso de las estaciones costeras 11 y 12. Dichas estaciones, al tener un IC considerablemente mayor que el resto de las costeras, sólo utilizan los datos de una estación auxiliar, que ni siquiera cumple la máxima diferencia exigida de IC. En todo caso, ambas estaciones constituyen una excepción y este hecho no altera el sentido del planteamiento metodológico expuesto.

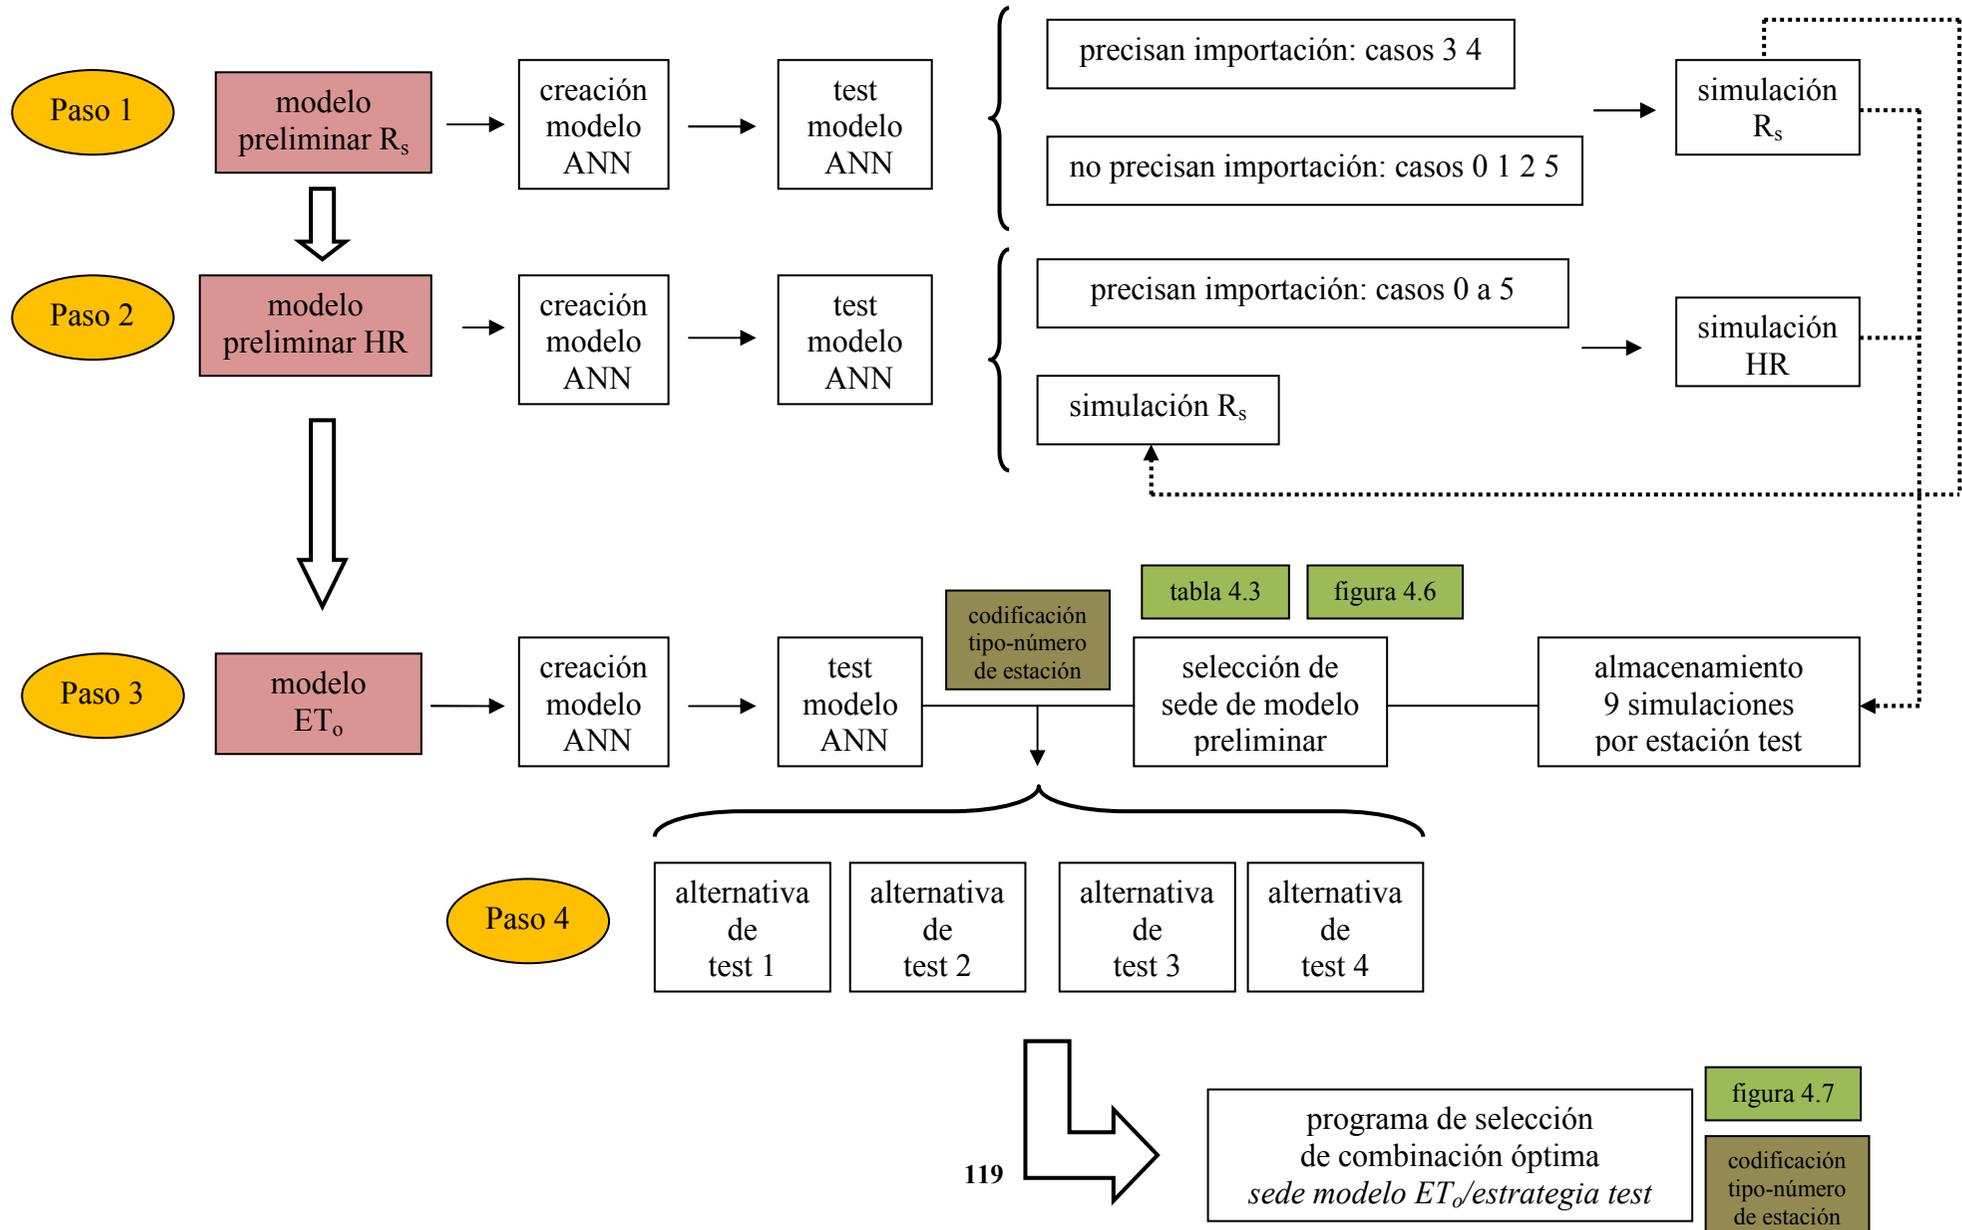
Tabla 4.5. Valores medios de estaciones auxiliares por tipo de estación de test

tipo de estación	número medio de estaciones auxiliares	% medio de estaciones auxiliares
costeras	4.83	40.28
intermedias	6.50	40.63
interiores	6.00	40.00

Acto seguido, se entrenaron todas las redes neuronales contempladas en la tabla 4.2 en las nueve sedes de estudio. Una vez generadas, éstas se testaron de acuerdo con las alternativas de test consideradas en la tabla 4.3. Conviene destacar que cada caso aglutina tres subcasos según los rangos máximos admisibles escogidos para los IC, que determinan el número de estaciones secundarias que contribuyen al valor medio de la variable importada. Las tablas 4.6 a 4.11 presentan un resumen de los errores relativos absolutos promedios obtenidos con el modelo óptimo para cada tipo de estación de test (fruto de aplicar el programa que selecciona la sede con mejores resultados medios por categoría de estación de test) para las tres combinaciones de rangos de IC establecidas.

Dichas tablas resumen para cada combinación de rangos IC, dentro de cada tipo de estación, la mejor alternativa de test. Por ejemplo, para el caso 0 (tabla 4.2), considerando los rangos máximos admisibles 0/0/0, la alternativa de test 1 es la que provee los mejores resultados medios en estaciones de test costeras (contrastar con tabla D.6). Se comprueba que las alternativas de test 1, 3 y 4, por su definición, son coincidentes para estaciones de test interiores. En estas tablas, se selecciona, dentro de cada tipo de estaciones de test, el rango de IC óptimo. Finalmente, se calcula la media de los errores relativos absolutos promedios correspondientes a dichos rangos de IC óptimos para el conjunto de estaciones de test, sin ponderar según el número de estaciones de cada tipo. En el apartado D.2 del anejo D se adjuntan los AARE de todas

Figura 4.9. Esquema de los procesos implementados en *Matlab* para generar el modelo ANN de 6 inputs 2/2



las combinaciones calculadas, de las que han sido extraídas las tablas resumen 4.6 a 4.11.

Tabla 4.6. Resultados óptimos medios por categoría de estación de test y rango IC para caso 0

caso 0				
rango IC	parámetro	costeras	intermedias	interiores
1	sede	13	13	13
	alternativa	1	4	1,3,4
	AARE (-)	0.1319	0.1637	0.1703
2	sede	12	21	32
	alternativa	1	1	1,3,4
	AARE (-)	0.1279	0.1454	0.1583
3	sede	11	21	32
	alternativa	1	1	1,3,4
	AARE (-)	0.1275	0.1480	0.1626
óptima	rango IC	3	2	2
	AARE (-)	0.1275	0.1454	0.1583
media total	AARE (-)	0.1437		

Tabla 4.7. Resultados óptimos medios por categoría de estación de test y rango IC para caso 1

caso 1				
rango IC	parámetro	costeras	intermedias	interiores
1	sede	32	11	13
	alternativa	4	1	2
	AARE (-)	0.1387	0.1673	0.1675
2	sede	11	12	13
	alternativa	2	2	2
	AARE (-)	0.1322	0.1555	0.1618
3	sede	11	12	12
	alternativa	2	2	2
	AARE (-)	0.1358	0.1581	0.1649
óptima	rango IC	2	2	2
	AARE (-)	0.1322	0.1555	0.1618
media total	AARE (-)	0.1498		

Dada la gran cantidad de factores tenidos en cuenta, es complicado extraer las razones que justifican los rendimientos que arrojan los distintos modelos. Así, las causas de los resultados que se generan pueden ser debidas al efecto combinado de distintos elementos/planteamientos, por lo que el efecto individual de cada uno es incierto. En primer lugar, salta a la vista la escasa variabilidad existente entre los resultados medios totales de los casos planteados, con un intervalo del AARE entre 0.1415 (caso 3) y 0.1570 (caso 5). Un análisis específico entre resultados óptimos por categoría de estación de test permite comprobar que el caso 3 presenta los mejores resultados medios

para estaciones costeras e interiores y que el caso 0 presenta los mejores resultados medios para estaciones intermedias, aunque aquí las diferencias de rendimiento entre los casos 0 y 3 sean sólo de 0.0005. Por el contrario, el caso 2 arroja los peores rendimientos para estaciones costeras e intermedias, mientras el caso 5 hace lo propio para estaciones interiores. Se puede afirmar que, analizando los valores óptimos, el caso 3 ofrece el mejor comportamiento global, ya que iguala al caso 0 en estaciones costeras e intermedias, pero lo supera en estaciones interiores. Analizando todos los valores de la tabla, el caso 3 ofrece en conjunto mejores prestaciones que el 0.

Tabla 4.8. Resultados óptimos medios por categoría de estación de test y rango IC para caso 2

caso 2				
rango IC	parámetro	costeras	intermedias	interiores
1	sede	32	32	32
	alternativa	2	4	1,3,4
	AARE (-)	0.1444	0.1719	0.1742
2	sede	32	21	32
	alternativa	2	2	2
	AARE (-)	0.1443	0.1607	0.1657
3	sede	32	21	32
	alternativa	2	2	2
	AARE (-)	0.1436	0.166	0.1657
óptima	rango IC	3	2	3,2
	AARE (-)	0.1436	0.1607	0.1657
media total	AARE (-)	0.1567		

Tabla 4.9. Resultados óptimos medios por categoría de estación de test y rango IC para caso 3

caso 3				
rango IC	parámetro	costeras	intermedias	interiores
1	sede	11	11	13
	alternativa	4	1	1,3,4
	AARE (-)	0.1286	0.1588	0.1651
2	sede	11	31	11
	alternativa	4	1	2
	AARE (-)	0.1270	0.1459	0.1558
3	sede	11	13	13
	alternativa	4	4	1,3,4
	AARE (-)	0.1268	0.1482	0.1519
óptima	rango IC	3	2	3
	AARE (-)	0.1267	0.1459	0.1519
media total	AARE (-)	0.1415		

Asimismo, los resultados óptimos de los casos 0 y 3 van ligados, en general, a las alternativas de test 1 y 4. De igual manera, los resultados de los casos 2 y 5 van asociados, en general, a la alternativa 2, aunque el caso 5 también va asociado a la alternativa 4. Atendiendo a la definición de estos casos y alternativas de test, cabe la posibilidad de atribuir las diferencias encontradas a la combinación de dos hechos. Por una parte, se observa que los modelos preliminares de R_s y HR considerados en los casos 0/3 y 2/5, respectivamente, son bastante similares, sin embargo, los modelos de ET_o de los casos 0 y 3 entrenan con valores locales de HR, mientras que los otros dos utilizan valores exógenos (tabla 4.2). Al mismo tiempo, la alternativa de test 2 no considera modelo preliminar de HR, sino que utiliza sustitución directa de valores auxiliares, frente a las alternativas de test 1 y 4.

Tabla 4.10. Resultados óptimos medios por categoría de estación de test y rango IC para caso 4

caso 4				
rango IC	parámetro	costeras	intermedias	interiores
1	sede	32	21	32
	alternativa	2	1	2
	AARE (-)	0.1357	0.1691	0.1740
2	sede	22	21	22
	alternativa	4	2	1,3,4
	AARE (-)	0.1410	0.1536	0.1681
3	sede	31	31	31
	alternativa	4	1	1,3,4
	AARE (-)	0.1286	0.1525	0.1581
óptima	rango IC	3	2	3
	AARE (-)	0.1286	0.1525	0.1581
media total	AARE (-)	0.1464		

Tabla 4.11. Resultados óptimos medios por categoría de estación de test y rango IC para caso 5

caso 5				
rango IC	parámetro	costeras	intermedias	interiores
1	sede	13	13	13
	alternativa	4	4	2
	AARE (-)	0.1490	0.1675	0.1713
2	sede	13	21	32
	alternativa	4	2	2
	AARE (-)	0.1490	0.1596	0.1705
3	sede	32	13	32
	alternativa	2	4	2
	AARE (-)	0.1433	0.1635	0.1680
óptima	rango IC	3	2	3
	AARE (-)	0.1433	0.1596	0.1680
media total	AARE (-)	0.1570		

Así pues, la combinación de entrenar el modelo de ET_o con valores locales de HR, junto con la consideración de un modelo preliminar de humedad relativa es la que conduce a unos resultados medios óptimos para predecir ET_o .

En cuanto a la combinación óptima de rangos máximos admisibles de IC, parece que la combinación 3 es la más adecuada para estaciones costeras, la 2 es la mejor para estaciones intermedias y en estaciones interiores, según el caso estudiado, la combinación más adecuada es la 2 o la 3. Ello indica que es aconsejable adoptar un valor exógeno medio de varias estaciones similares antes que utilizar sólo el de la estación con IC más parecido. Debido a que se están analizando valores medios correspondientes a categorías de estaciones y a que el número de estaciones auxiliares en la combinación 3 de rangos IC es variable según la estación de test, la determinación del número óptimo de estaciones auxiliares exigiría un estudio detallado más minucioso, con una población de estaciones con distribución más uniforme de valores asociados de IC.

Si analizamos las diferencias entre los rendimientos obtenidos aplicando las combinaciones de rangos 2 y 3 en los casos 0 y 3, los óptimos, se comprueba que éstas son muy pequeñas, lo que justificaría la adopción de la combinación 3 de rangos de IC, pues su aplicación demanda menos datos.

Un análisis de las sedes de entrenamiento óptimas de los casos 0 y 3 indica que las sedes costeras son, en general, más adecuadas para predecir ET_o . La menor variabilidad climática a que están sometidas las localidades costeras podría facilitar la detección del modelo de tendencias más evidentes entre las variables involucradas.

4.3.2. ANÁLISIS DEL MODELO ÓPTIMO

En adelante, se estudiará con más detalle la combinación 3 de rangos máximos admisibles de IC para el caso 3, pues se ha pretendido escoger el modelo que mejores prestaciones ofrece en conjunto, no para cada condición de test concreta. La tabla 4.12 aglutina los valores medios del error medio cuadrático y el error relativo absoluto promedio para cada categoría de estación y alternativa de test. Se incluyen también los resultados correspondientes al modelo ANN de 4 inputs.

Tabla 4.12. Índices medios de rendimiento del caso 3 con la combinación 3 de rango IC

alternativa de test	parámetro de calidad	costeras	intermedias	interiores
1	sede óptima	3-2 Requena C.	1-1 Altea	1-3 Denia
	MSE (mm/día) ²	0.2128	0.3159	0.3982
	AARE (-)	0.1332	0.1503	0.1519
2	sede óptima	1-3 Denia	1-1 Altea	1-3 Denia
	MSE (mm/día) ²	0.2418	0.2827	0.4071
	AARE (-)	0.1285	0.1515	0.1535
3	sede óptima	1-3 Denia	1-1 Altea	1-3 Denia
	MSE (mm/día) ²	0.2374	0.2886	0.3982
	AARE (-)	0.1275	0.1520	0.1519
4	sede óptima	1-1 Altea	1-3 Denia	1-3 Denia
	MSE (mm/día) ²	0.2122	0.3121	0.3982
	AARE (-)	0.1268	0.1482	0.1519
ANN de 4 inputs	sede óptima	1-1 Altea	2-3 Onda	1-2 Benavites
	MSE (mm/día) ²	0.3383	0.7159	0.5674
	AARE (-)	0.1800	0.2085	0.2007
Hargreaves	MSE (mm/día) ²	0.3939	0.6041	0.5575
	AARE (-)	0.2833	0.2694	0.2486

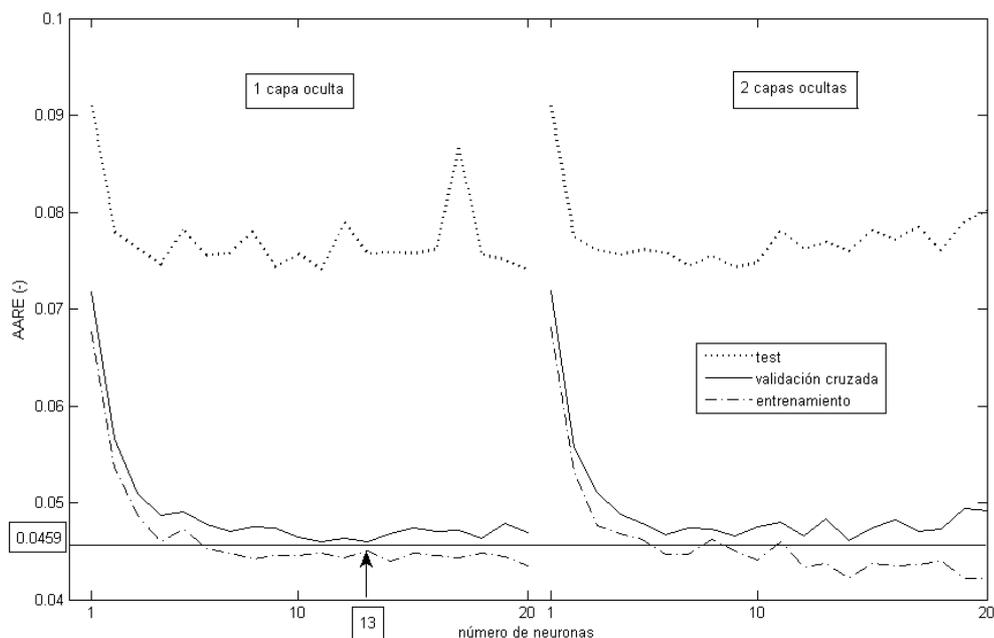
La alternativa de test 4 presenta los errores más bajos, con valores del AARE de 0.1268, 0.1482 y 0.1519 en estaciones costeras, intermedias e interiores, respectivamente, aunque no se han detectado diferencias significativas entre las distintas alternativas de test. Como se ha comentado, este hecho revela que la naturaleza y el origen de los inputs considerados en cada modelo son más determinantes que el tipo de sede utilizado para entrenar los modelos preliminares.

Por otra parte, las sedes óptimas son Altea, para localidades de test costeras, y Denia, para localidades de test intermedias e interiores. De esta manera, los mejores rendimientos se consiguen cuando las ANN son entrenadas en sedes costeras. Atendiendo a la metodología seguida para implementar el programa, las sedes de los respectivos modelos preliminares para predicción de R_s y HR cuando el modelo de ET_o se entrena en Altea (código 1-1) y Denia (código 1-3) son Castalla (código 3-1) y Pinoso (código 3-3), respectivamente, debido a que en esta alternativa de test los modelos preliminares son entrenados en estaciones de interior, existiendo una correspondencia fija entre estaciones de entrenamiento. Por el contrario, el modelo de 4 inputs arroja los mejores resultados medios cuando se entrena en sedes costeras (Altea y Benavites), para localidades de test costeras e interiores, y en sedes intermedias (Onda), para estaciones de test intermedias.

A continuación, se examinará el proceso de selección de la arquitectura óptima de los modelos óptimos para predicción de ET_o , representado en las figuras 4.10 y 4.11, correspondientes a las sedes Altea y Denia, respectivamente.

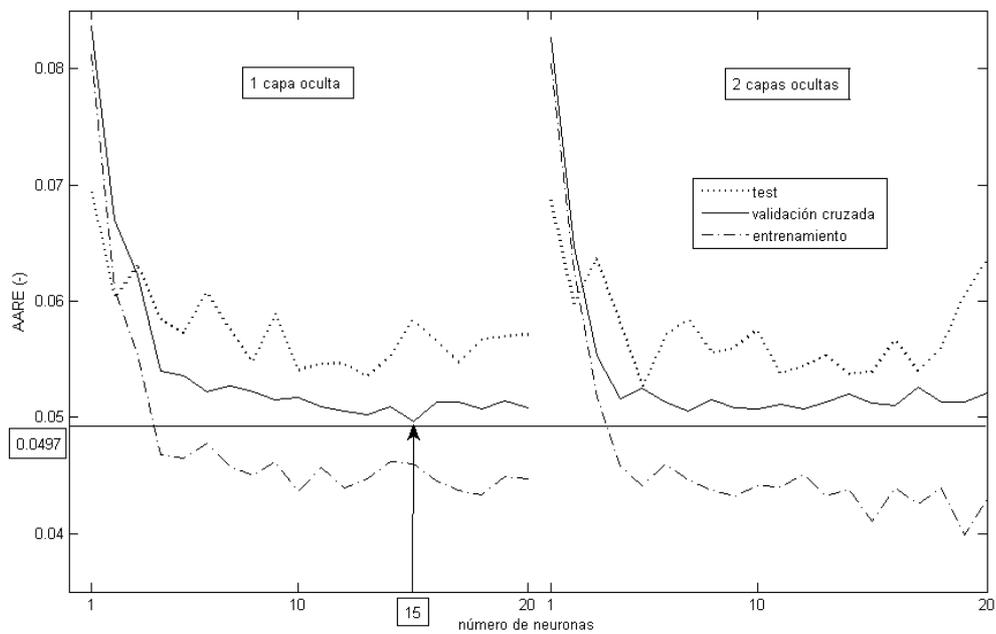
En estas figuras se analiza la relación entre el error relativo absoluto promedio y sus arquitecturas para los subconjuntos de datos de entrenamiento, verificación y test. La línea horizontal representa el mínimo valor del AARE referido al set de validación cruzada, parámetro que fue utilizado para seleccionar la arquitectura óptima. De esta manera, se escogió una red con una capa oculta dotada de 13 neuronas, en Altea. Podría haberse seleccionado otra arquitectura más sencilla, con 11 neuronas, pues ésta presenta un error de verificación muy similar (0.046 vs 0.0459) y un error de test menor (0.0741 vs 0.0757). Lo mismo ocurre en el caso de Denia, donde se selecciona la arquitectura con una capa oculta dotada de 15 neuronas, por ser la de menor error de validación cruzada. Aquí la de 13 neuronas también presenta un error de verificación similar (0.0497 vs 0.0503) y un error de test menor (0.0535 vs 0.0584). Sin embargo, no se escogieron estas alternativas porque no hubieran comportado mejoras significativas en la capacidad de generalización de estos modelos ANN. Además, como se comentó en el capítulo 3, el análisis combinado de los errores de verificación y test constituye un criterio subjetivo difícil de ser implementado en un programa.

Figura 4.10. Número de neuronas vs AARE para los sets de entrenamiento, verificación y test en Altea



De la misma manera, las arquitecturas óptimas de los modelos preliminares de R_s, correspondientes a Castalla y Pinoso constan de una capa oculta con 12 y 14 neuronas, respectivamente, mientras que las arquitecturas óptimas de los modelos preliminares de HR, también de las sedes Castalla y Pinoso, están formadas por una capa oculta con 13 y 9 neuronas, respectivamente. Las figuras que representan dicho proceso de selección se pueden encontrar en el anejo D (apartado D.3). En el caso del modelo HR en Castalla llama la atención la gran separación que existe entre las curvas de error de verificación/entrenamiento y de test, que presenta un error mucho mayor. Esto podría deberse a condiciones anómalas de humedad relativa en el año de test. No obstante, este hecho no afecta a los resultados, ya que el error del subconjunto de test no ha sido tenido en cuenta en la elección de la arquitectura óptima.

Figura 4.11. Número de neuronas vs AARE para los sets de entrenamiento, verificación y test en Denia

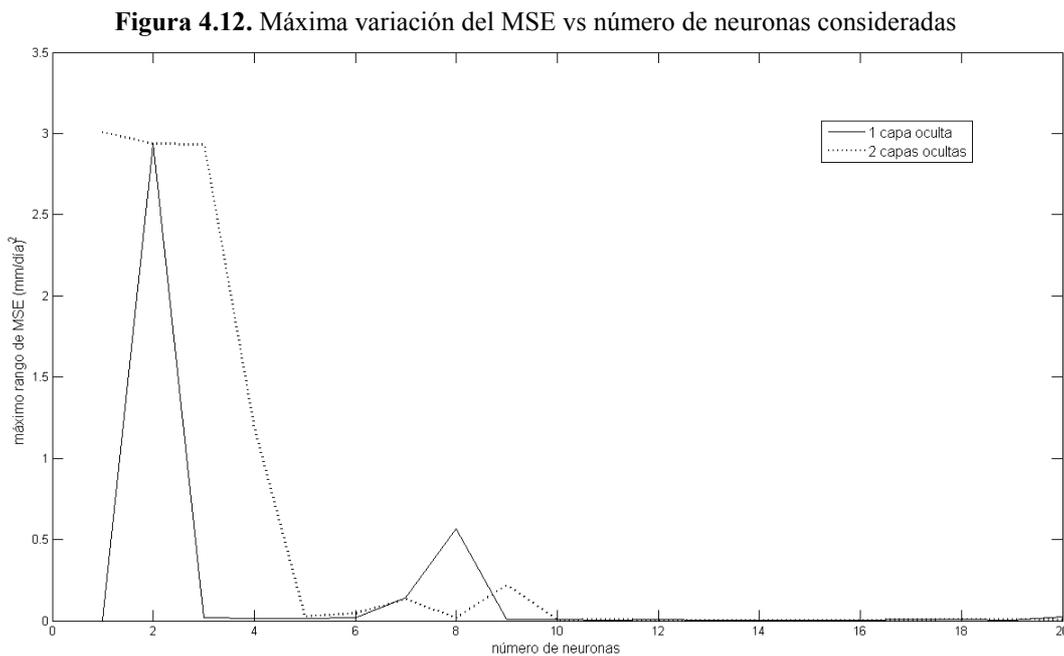


En los apartados D.3.5-D.3.7 del anejo D, se muestra el gráfico de selección de la arquitectura óptima para las tres sedes del modelo de 4 inputs que han resultado arrojar los mejores resultados medios para estaciones costeras, intermedias e interiores: Altea, Onda y Benavites, respectivamente.

En el caso de Altea, se observa que aunque el mínimo error del set de verificación corresponde a la arquitectura 4-7-7-1 (AARE=0.1298), la arquitectura escogida consta de una capa oculta con 11 neuronas (AARE=0.1326). Conforme al criterio establecido

en el apartado de materiales y métodos, al ser poco significativa la diferencia de errores, se elige la de una capa oculta con menor error de verificación, pues se pretende favorecer la selección de arquitecturas con una capa oculta, dotadas de mayor capacidad de generalización. En los casos de Onda y Benavites, se escogieron directamente las arquitecturas con menor AARE en el subconjunto de verificación, con 11 y 5 neuronas en una única capa oculta.

Por otro lado, se ha analizado la oscilación que sufre el MSE, referido al set de entrenamiento, con distintos procesos de aprendizaje de la misma ANN. Es decir se trata de poner en evidencia el efecto derivado de la asignación aleatoria inicial de los pesos cuando empieza la aplicación del algoritmo de aprendizaje. La figura 4.12 representa el rango máximo de oscilación del error medio cuadrático en veinte repeticiones del proceso de entrenamiento frente al número de neuronas considerado cada vez en el modelo ANN para predicción de ET_0 en Altea.



Como puede comprobarse, para un número bajo de neuronas, la asignación aleatoria inicial de los pesos cuando se inicializa el algoritmo de aprendizaje puede tener un efecto importante en las propiedades de la red neuronal creada. Parece que, al aumentar el número de neuronas, este efecto tiende a perder influencia, aunque esto es algo que no se puede generalizar y habría que comprobar cada vez.

Para analizar detalladamente el rendimiento del modelo propuesto conviene desglosar el mismo para cada estación testada, agrupadas por categorías continentales. La comparación de los rendimientos individuales en cada estación de test se presenta en las figuras 4.13 a 4.15. Los valores individuales del MSE, AARE y c se hallan desglosados en el apartado D.4 del anejo D.

Figura 4.13. Código de estación de test vs AARE para modelos ANN de 4 y 6 inputs y ecuación de Hargreaves. Estaciones costeras

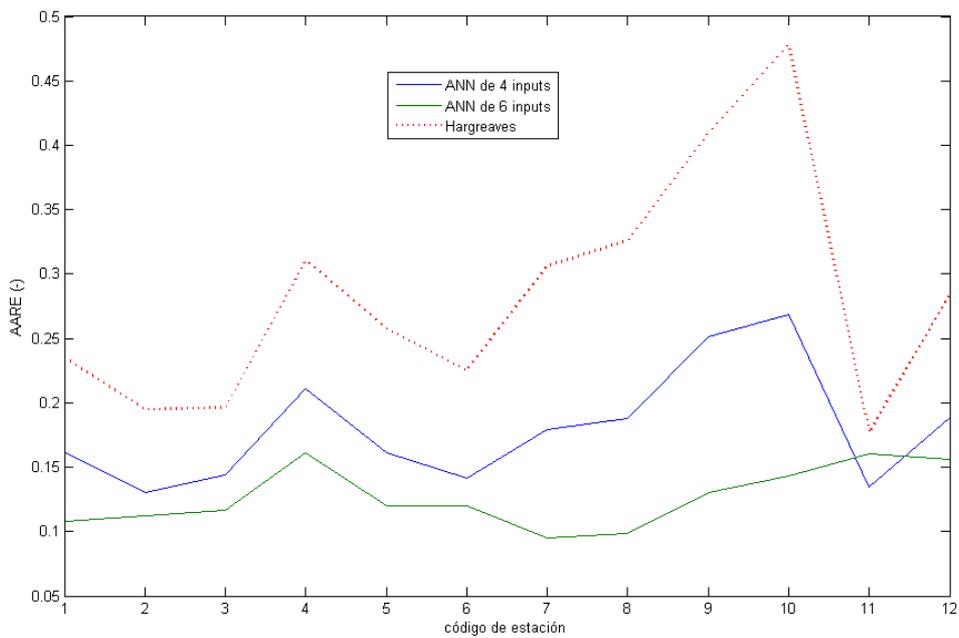


Figura 4.14. Código de estación de test vs AARE para modelos ANN de 4 y 6 inputs y ecuación de Hargreaves. Estaciones intermedias

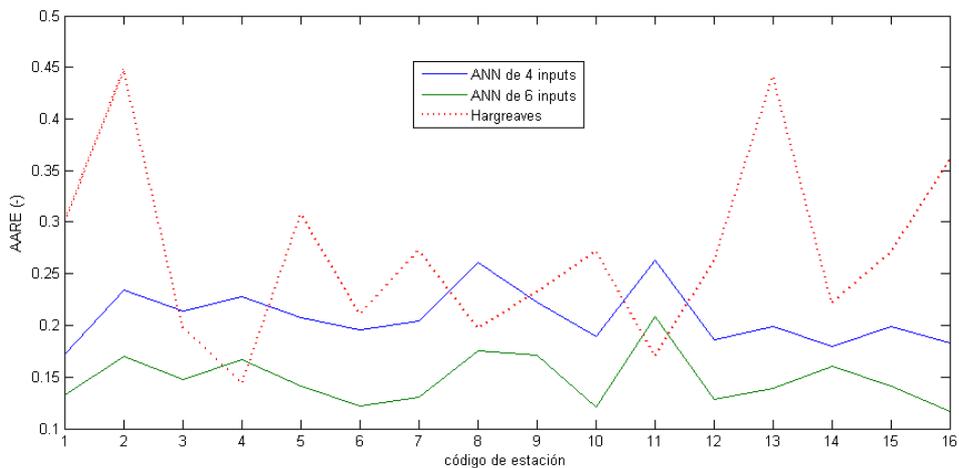
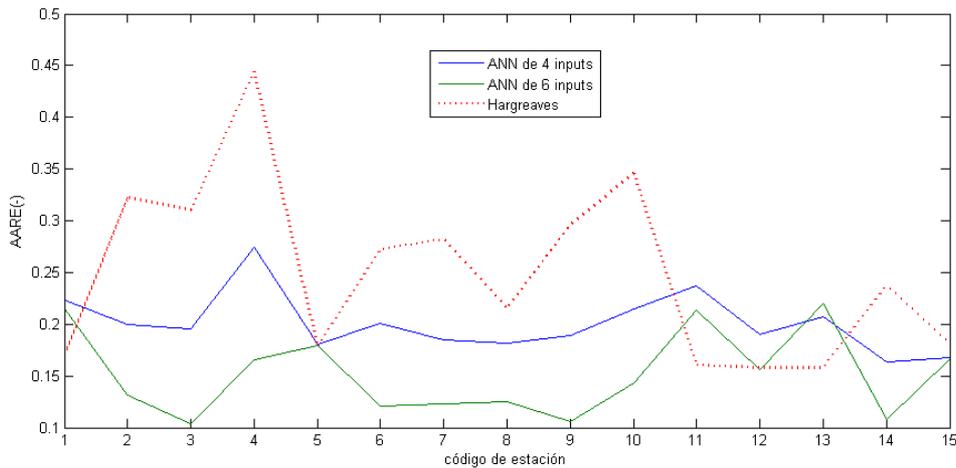


Figura 4.15. Código de estación de test vs AARE para modelos ANN de 4 y 6 inputs y ecuación de Hargreaves. Estaciones interiores



En la determinación del error cuadrático medio y del error relativo absoluto promedio, así como en el *performance index*, influyen decisivamente dos hechos. Por una parte, cuando el error absoluto diario es mayor que 1, el error cuadrático correspondiente aumenta considerablemente su orden de magnitud respecto de los días con error absoluto menor que 1. Por otra parte, cuando el valor de referencia diario es menor que 1, ocurre lo propio con el valor diario del error relativo. Un caso intermedio se produce con el coeficiente de ajuste d que sirve para determinar el índice c . Esto conduce a situaciones donde la comparación entre dos modelos es relativa según el indicador que se escoja como referencia. Así, en la estación costera 1-12, se verifica que el modelo de 4 inputs es más exacto que el de 6 en la escala de MSE (0.2993 vs 0.3205), pero ocurre a la inversa si se atiende a la escala AARE (0.1891 vs 0.1559).

El error relativo permite, en comparación con el MSE, establecer comparaciones entre rendimientos en estaciones distintas y, en comparación con el c , tiene mayor rango de oscilación. Cabe recordar que el MSE no establece relación con el orden de magnitud local de la variable estimada y, por ello, no es válido comparar errores referenciadas a estaciones distintas. Sí tiene sentido, en cambio, comparar los de distintos modelos en una misma estación. Por otra parte, el AARE tiene un rango de oscilación mínimo para una estación de test entre los distintos modelos de un 10-15%, mientras que el *performance index* sólo oscila alrededor de un 5-7%. Por este motivo, se ha fijado el error relativo medio como referencia para comparar los tres modelos.

En estas figuras se comprueba que el modelo de 6 inputs es globalmente más exacto que el de 4 inputs y que el de Hargreaves, aunque existen excepciones donde el modelo de 4 inputs (estaciones 1-11 y 3-13) y Hargreaves (2-4, 2-11, 3-1, 3-11 y 3-13) mejoran el rendimiento del de 6 inputs. La mejora del error relativo medio introducida respecto al modelo existente de 4 inputs es de 5.32%, 6.02% y 4.88% en estaciones costeras, intermedias e interiores, respectivamente, y respecto al modelo de Hargreaves, de 15.65%, 12.11% y 9.67%, respectivamente. Por otra parte, la reducción máxima del AARE medio respecto del que arroja el modelo de 4 inputs alcanza valores de 12.54% (estación 1-10), 8.55% (estación 2-8) y 10.88% (estación 3-4) en cada categoría.

No parece existir una tendencia entre la calidad del rendimiento dentro de cada grupo y el índice de continentalidad, si bien el rendimiento del modelo de 6 inputs se mantiene relativamente constante con el IC en el caso de estaciones intermedias, muy al contrario que en el caso de las estaciones de interior. En los dos casos donde el modelo de 4 inputs mejora las prestaciones del de 6 inputs, las diferencias entre las predicciones de ambos modelos son mínimas. El hecho de que esto sólo se produzca en dos de los cuarenta y tres casos hace pensar en la posibilidad de que exista algún tipo de error en alguno de los conjuntos de datos de entrenamiento y/o test involucrados. Sin embargo, dada la cantidad de variables que influyen en el output del modelo, es difícil atribuir con absoluta certeza las causas de este comportamiento a un factor concreto. La mayor precisión del nuevo modelo de 6 inputs, respecto del de 4 inputs, cabe atribuirlo, casi con total seguridad, a la influencia de la humedad relativa sobre el proceso de evapotranspiración, aspecto que es ignorado en el modelo de 4 inputs.

Los rendimientos del modelo de Hargreaves se podrían haber mejorado aplicando estrategias de calibración local (Allen, 1994; Trajkovic, 2005 y 2007), sin embargo éstas no parecen lógicas si se atiende a las condiciones de disponibilidad de datos que pueden esperarse en las estaciones de test donde la aplicación del modelo que se propone pretende tener sentido. Por ello, no se ha considerado la posibilidad de llevar a cabo dicha calibración.

Se observa que el rendimiento medio del modelo propuesto es mejor en estaciones costeras que en intermedias e interiores (12.48% vs 14.83% y 15.19%), mientras que

esta tendencia se invierte en el caso del modelo de Hargreaves, que funciona, en promedio, mejor en estaciones de interior (28.33% vs 26.94% y 24.86%).

Las figuras 4.16 a 4.18 muestran una comparativa entre las predicciones de los modelos de 6 y 4 inputs en una estación de test de cada categoría, Borriana, Carcaixent y Requena-Cerrito. En ellas se comprueba la mayor dispersión de los puntos correspondientes al modelo de 4 inputs, sin observarse tendencias concretas. Dichas estaciones se han escogido al azar, y sólo pretenden servir ilustrar las diferencias en la dispersión de ambos modelos.

Las tablas del apartado D.5 del anejo D, muestran los AARE y c de los modelos preliminares para predicción de radiación y humedad relativa que fueron utilizados en la alternativa de test escogida y correspondiente al modelo óptimo. De acuerdo con la metodología fijada, estos modelos fueron entrenados en Castalla, para estaciones de test costeras, y en Pinoso, para estaciones de test intermedias e interiores.

Figura 4.16. ET_o PM vs ET_o ANN en Borriana (estación 1-8, IC=0.479)

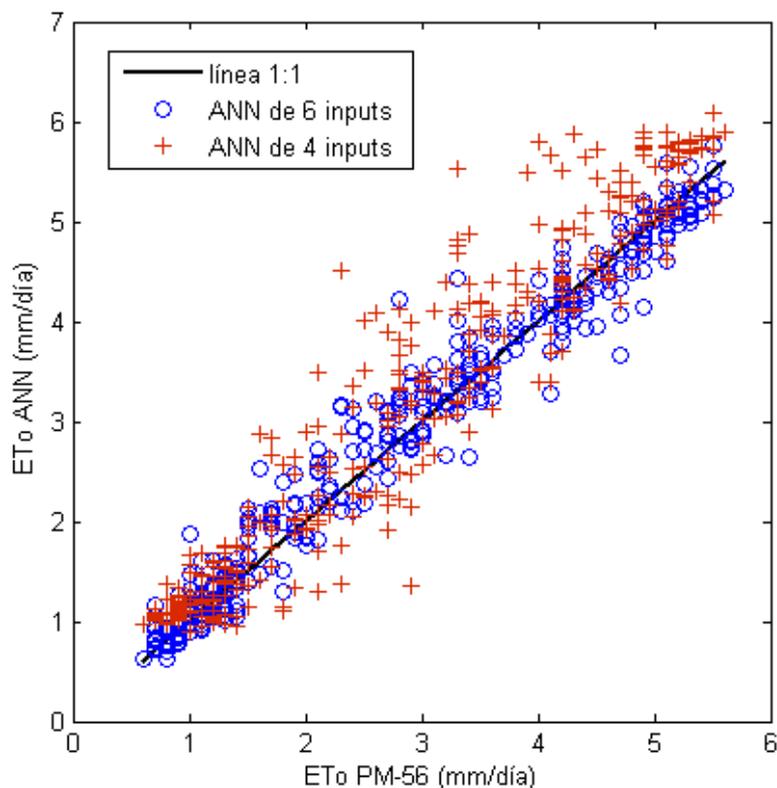


Figura 4.17. ET_o PM vs ET_o ANN en Carcaixent (estación 2-13, IC=4.303)

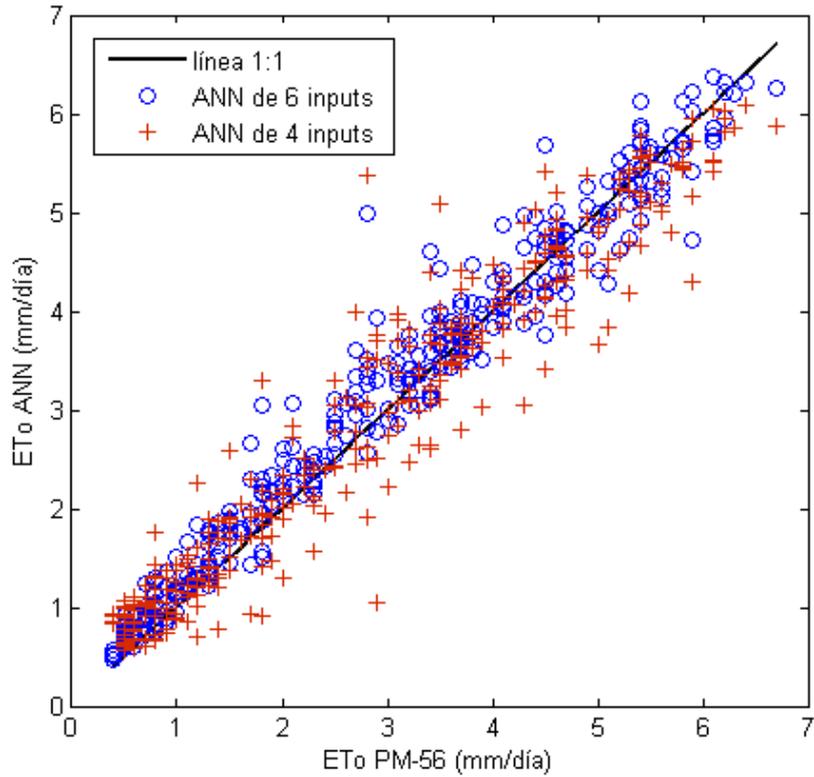
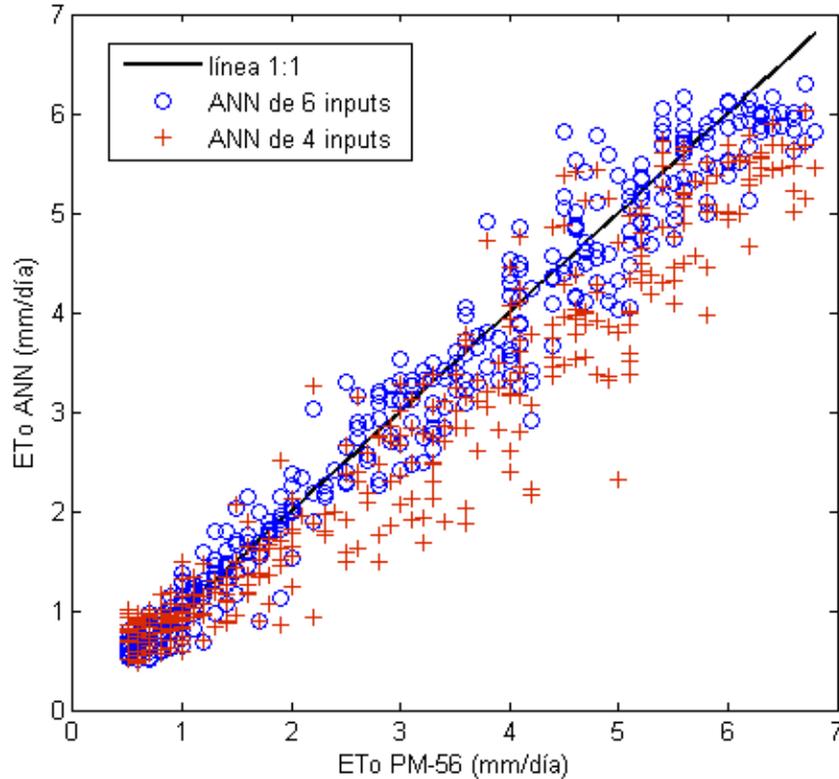


Figura 4.18. ET_o PM vs ET_o ANN en Requena-Cerrito (estación 3-14, IC=14.925)



Aunque las predicciones presentan valores medios de AARE y c por encima de 0.25 y alrededor de 0.8, respectivamente, si se atiende a la mejora experimentada en la predicción posterior de ET_0 , la consideración de estos modelos preliminares parece haber sido determinante, junto con el uso de datos auxiliares de ET_0 procedente de estaciones vecinas.

Los rendimientos del modelo de humedad relativa son relativamente parecidos en todas las estaciones, lo que puede derivarse de la consideración como input de la humedad relativa exógena. Esto explicaría que el modelo presenta la misma exactitud para estaciones costeras y de interior. En cuanto a los modelos de radiación, se observa una ligera mejoría en la calidad media de las predicciones en estaciones de interior respecto a las costeras e intermedias (con un AARE de 0.2518 vs 0.2879 y 0.2858). Sin embargo, todo parece indicar que es preferible utilizar una predicción poco exacta de R_s antes que valores teóricos de radiación extraterrestre, como ocurre en el modelo de 4 inputs.

Para finalizar, se quiere justificar el hecho de no haber analizado en este capítulo, de nuevo, la aplicabilidad del modelo ANN de 4 inputs, cuando se disponía de muchas más estaciones que en el capítulo anterior. Por una parte, las conclusiones relativas a la calidad del modelo de 4 inputs concuerdan con las extraídas por los autores que propusieron el modelo (Zanetti et al., 2007), en tanto que revelan que el modelo precisa modificaciones que mejoren sus prestaciones. Por otra parte, la aportación fundamental que se sugiere en el estudio de su aplicabilidad consiste en la necesidad de vincular la respuesta de estos modelos con algún indicador del contexto continental en que se aplican. Por ello, se ha optado por concentrar el esfuerzo en mejorar dicho modelo y dejar en segundo plano un análisis más amplio de su aplicabilidad, visto su limitado potencial.

4.4. Conclusiones

El modelo ANN óptimo de 6 inputs para predicción de ET_0 considera como variables de entrada: valores diarios locales de temperatura máxima, temperatura máxima y mínima, radiación solar, horas de sol, humedad relativa y valores exógenos de evapotranspiración de referencia. Los valores locales de humedad relativa en las

estaciones de test para ejecutar dicho modelo se generan a partir de un modelo ANN preliminar que demanda valores locales de temperatura máxima, temperatura mínima, radiación solar, número de horas de sol diarias y valores exógenos de humedad relativa y evapotranspiración de referencia. Los valores locales en las estaciones de test de radiación solar para ejecutar estos dos modelos se generan a partir de un modelo ANN preliminar que demanda valores locales de temperatura máxima, temperatura mínima, número de horas de sol diarias, radiación extraterrestre y valores exógenos de evapotranspiración de referencia.

El modelo propuesto requiere la misma cantidad de variables de la estación testada que el modelo precedente de 4 inputs, aunque saca provecho de valores adicionales de humedad relativa y evapotranspiración de referencia procedentes de estaciones auxiliares con IC similar. De esta manera, el modelo propuesto introduce la novedad de suplantar datos no disponibles de variables climáticas de la estación de test con datos correspondientes a una estación secundaria similar desde un punto de vista continental, lo que contribuye a mejorar la capacidad de generalización del modelo.

Los valores medios de MSE, AARE y c que arrojan las predicciones del modelo ANN propuesto para predicción de ET_0 mejoran claramente las de los otros modelos contemplados, el modelo de Hargreaves y el modelo ANN de 4 inputs, en el contexto climático de la Comunidad Valenciana.

La consideración del error relativo absoluto promedio (AARE) como índice de referencia permite comparar rendimientos referidos a estaciones distintas. La interpretación del MSE, sin embargo, es distinta según el orden de magnitud de la ET_0 de cada estación testada.

4.5. Trabajo futuro

En el futuro se estudiará la mejora del modelo propuesto incidiendo en la obtención de modelos preliminares más precisos. Una estrategia razonable consiste en la consideración de valores exógenos de radiación para predecir R_s , al igual que se ha hecho en el modelo ANN para predicción de HR. Asimismo, se contrastará la calidad del modelo en otros contextos de continentalidad, con mayores fluctuaciones climáticas,

y se trazarán nuevas estrategias de valoración de los resultados, introduciendo otros parámetros de caracterización de las estaciones distintos al IC. Por otra parte, podría ser recomendable llevar a cabo un análisis más minucioso y referenciar el AARE a periodos menores al anual debido al acusado carácter estacional de la ET_0 . Esto permitiría valorar el rendimiento de los modelos en cada época del año considerada.

En el mismo sentido que se comentó en el capítulo 2, puede plantearse un análisis de la variación de los resultados en función del número de repeticiones de entrenamiento. Igualmente, pueden estudiarse estrategias de mejora en los procedimientos de selección de la arquitectura óptima, proponiendo nuevos criterios a partir de los errores de los conjuntos de test y verificación en conjunto con el número de neuronas correspondiente. Parece lógica también la posibilidad de recurrir a técnicas de optimización, basadas por ejemplo en algoritmos genéticos, para seleccionar dicha arquitectura.

bibliografía

- ALEXANDRIS, S., KERKIDES, P., y LIAKATAS, A. (2005). "Daily reference evapotranspiration estimates by the 'Copais' approach." *Agricultural Water Management* 82, 371-386.
- ALLEN, J. (1995). *Natural language understanding*. Addison-Wesley Reading, Massachusetts.
- ALLEN, R.G. (1986). "A Penman for all seasons." *Journal of Irrigation and Drainage Engineering* 112(4), 348-368.
- ALLEN, R.G. (1994). "An update for the definition of reference evapotranspiration." *ICID Bulletin* 43(2), 1-34.
- ALLEN, R.G. (1996). "Assessing integrity of weather data for reference evapotranspiration estimation." *Journal of Irrigation and Drainage Engineering* 122(2), 97-106.
- ALLEN, R.G., JENSEN, M.E., WRIGHT, J.L., y BURMAN, R.D. (1989). "Operational estimates of reference evapotranspiration." *Journal of Agronomy* 81, 650-662.
- ALLEN, R.G., PEREIRA, L.S., RAES, D., y SMITH, M. (1998) *Crop evapotranspiration guidelines for computing water requirements*. FAO Irrigation and Drainage paper No 56, Roma.
- AL AMOUD A.I. (1995). "Significance of energy losses due to emitter connections in trickle irrigation lines." *Journal of Agricultural Engineering, Research.*, 60(1), 1-5.
- AQIL BURNEY, S.M., JILANI A. TAHSEEN, y CEMAL ARIL (2004). "A comparative study of first and second order training algorithms for artificial neural networks." *International Journal of computational Intelligence* 1(3), 218-224.
- ARCA, B., BENISCASA, F., y VINCENZI, M. (2004). "Evaluation of neural network techniques for estimating evapotranspiration." National Research Council. Italia.
- ARVIZA, J. (1992). *Pérdidas de carga singulares por la conexión de emisores en laterales de riego localizado*. Tesis doctoral. Universidad Politécnica de Valencia. Valencia.
- ASCE Task Committee on Application on Artificial Neural Networks in Hydrology (2000a). "Artificial neural networks in hydrology. I: Preliminary concepts." *Journal of Hydrologic Engineering* 5(2), 115-123.
- ASCE Task Committee on Application on Artificial Neural Networks in Hydrology (2000b). "Artificial neural networks in hydrology. II: Hydrologic applications." *Journal of Hydrologic Engineering* 5(2), 124-137.
- AZOFF, E.M. (1994). *Neural network time series, forecasting of financial markets*. John Wiley and Sons, Nueva York.
- BALKHAIR, K.S. (2002). "Aquifer parameters determination for large diameter wells using neural network approach." *Journal of Hydrology* 265, 118-128.
- BAGARELLO V., y PUMO D. (1992). "Lateral line hydraulics in drip irrigation systems." *Proc., 16th ICID European Regional Conference*, Budapest.
- BAGARELLO, V., FERRO, V., PROVENZANO, G., y PUMO, D. (1995). "Experimental study on flow-resistance law for small-diameter plastic pipes." *Journal of Irrigation and Drainage Engineering* 121(5), 313-316.
- BAGARELLO, V., FERRO, V., PROVENZANO, G., y PUMO, D. (1997). "Evaluating pressure losses in drip-irrigation lines." *Journal of Irrigation and Drainage Engineering* 123(1), 1-7.
- BARENBLATT, G.I., y MONIN, A.S. (1979). "Similarity laws for turbulent stratified shear flows." *Archive for Rational Mechanics and Analysis* 70(4), 307-317.
- BARRAGÁN, J., y WU, I.P. (2005). "Simple pressure parameters for micro-irrigation design." *Biosystems Engineering* 90(4), 463-475.
- BARRAGÁN, J., BRALTS, V. y WU, I.P. (2006). "Assessment of emission uniformity for micro-irrigation design." *Biosystems Engineering* 93(1), 89-97.

- BERMÚDEZ-CELA, J.L., FERNÁNDEZ DE CASTRO, B.M., y SOUTO-GONZÁLEZ, J.A.** (2002). "Sistemas de control suplementario de la contaminación atmosférica." *Revista Galega de Economía* 11(2), 1-12.
- BHATTACHARYA, A.K.** (1999). "Drainage of agricultural lands" *50 Years of Natural Resource Management Research*. Singh, G.B., Sharma, B.R. (Eds), Division of Natural Resource Management, ICAR, Krishi Bhavan, New Delhi, 347-362.
- BISHOP, C.M.** (1997). *Neural networks for pattern recognition*. Oxford University Press, Oxford.
- BLANEY, H.F., y CRIDDLE, W.D.** (1950). *Determining water requirements in irrigated areas from climatological and irrigation data*. United States Department of Agriculture. Soil Conservation Service Technical Paper No 96, U.S. Department of Agriculture, Washington.
- BOWDEN, G.J., DANDY, G.C., y MAIER, H.R.** (2005). "Input determination for neural network models in water resources applications. Part 1- background and methodology." *Journal of Hydrology* 301, 75-92.
- BRALTS, V.F., WU, I.P., y GITLIN, H.M.** (1981a). "Manufacturing variation and drip irrigation uniformity." *Transactions of the ASAE* 24(1), 113-119.
- BRALTS, V.F., WU, I.P., y GITLIN, H.M.** (1981b). "Drip irrigation uniformity considering emitter plugging." *Transactions of the ASAE* 24(5), 1234-1240.
- BRALTS, V.F., WU, I.P., y GITLIN, H.M.** (1982). "Emitter plugging and drip irrigation lateral line hydraulics." *Transactions of the ASAE* 24(5), 1274-1281.
- BRALTS, V.F., y KESNER, C.D** (1983). "Drip irrigation field uniformity estimation." *Transactions of the ASAE* 26(5), 1369-1374.
- BRALTS, V.F., BARRAGAN, J., y WU, I.P.** (2003). "Irrigation systems." *Encyclopedia of water science* 546-548. Marcel Dekker, Inc., Nueva York.
- CAI, J., LIU, Y., LEI, T., y PEREIRA, L.S.** (2007). "Estimating reference evapotranspiration with the FAO Penman-Monteith equation using daily weather forecast messages." *Agricultural and Forest Meteorology* 145, 22-35.
- CAMARGO, A.P., y SENTELHAS, P.C.** (1997). "Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brazil." *Revista Brasileira de Agrometeorologia* 5(1), 89-97.
- CAMPOLO, M., ANDREUSSI, P., y SODALT, A.** (1999). "River stage forecasting with a neural network model." *Water Resources Research* 35 (4): 1191-1197.
- CANCELLIERE, A., GIUŠIANO, G., ANCARANI, A., y ROSSI, G.** (2002). "A neural networks for deriving irrigation reservoir operating rules." *Water Resources Management* 16, 71-88.
- CASTILLO, E, COBO, A., GUTIÉRREZ, J.M. y PRUNEDA, R.E.** (1999). *Introducción a las redes funcionales con aplicaciones. Un nuevo paradigma neuronal*. Paraninfo, Madrid.
- CECCHETTI, M., CORANI, G., y GUARISO, G.** (2004). "Artificial neural networks prediction of pm10." *IEMSS International Congress: Complexity and Integrated Resources Management*, Osnabruck.
- CHAU, K.W.** (2006). "Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River." *Journal of Hydrology* 329, 363-367.
- CHEN, J., y ADAMS, B.J.** (2006). "Integration of artificial neural Networks with conceptual models in rainfall-runoff modelling." *Journal of Hydrology* 318, 232-249.
- CHIEW, F.H.S., KAMALADASA, N.N., MALANO, H.M., y McMAHON, T.A.** (1995). "Penman-Monteith, FAO-24 reference crop evapotranspiration and class-A pan data in Australia." *Agricultural Water Management* 64, 91-106.
- CHOI, D.J., y PARK, H.** (2001). "A hybrid artificial neural network as a software sensor for optimal control of a wastewater treatment process." *Water Resources* 35(16), 3959-3967.

- CHURCHLAND, P.S., y SEJNOWSKI, T.J.** (1992). *The computational brain*. MIT Press, Cambridge, Massachusetts.
- CICHOCKI, A., UNBEHAUEN, R. y COCHOCKI, A.** (1993). *Neural networks for optimization and signal processing*. John Wiley and Sons. Nueva York.
- CIĞIZOĞLU, H.K.** (2002). "Suspended sediment estimation for rivers using artificial neural networks and Sediment Rating Curves." *Turkish Journal of Engineering and Environmental Sciences*. 26, 27-36.
- CIĞIZOĞLU, H.K.** (2003). "Estimation, forecasting and extrapolation of flow data by artificial neural networks." *Hydrological Sciences Journal* 48(3), 349-361.
- CIĞIZOĞLU, H.K.** (2004). "Estimation and forecasting of daily suspended sediment data by multi layer perceptrons." *Advances in Water Resources* 27, 185-195.
- CIĞIZOĞLU, H.K., y KIŞI, Ö.** (2005). "Flow prediction by three back propagation techniques using k-fold partitioning of neural network training data." *Nordic Hydrology* 36(1), 49-64.
- CONRADS, P.A., y ROEHL, E.A.** (1999). "Comparing Physics-Based and Neural Network Models for Simulating Salinity, Temperature, and Dissolved Oxygen in a Complex, Tidally Affected River Basin." *Proceedings of the South Carolina Environmental Conference*, Myrtle Beach.
- COULIBALY, P., ANCTIL, F., y BOBÉE, B.** (2001). "Multivariate reservoir inflow forecasting using temporal neural networks", *Journal of Hydrologic Engineering*, 6(5), 367-376.
- COULIBALI, P., ANCTIL, F., ARAVENA, R., y BOBÉE, B.** (2001). "Artificial neural network of water table depth fluctuations." *Water Resources Research* 37(4), 885-896.
- COULIBALY, P., HACHÉ, M., FORTIN, V. y BOBÉE, B.** (2005). "Improving daily reservoir inflow forecasts with model combination." *Journal of Hydrologic Engineering*, 10(2), 91-99.
- CYBENKO, G.** (1989). "Approximations by superpositions of sigmoidal functions." *Mathematics of Control, Signals and Systems* 2, 303-314.
- DEDECKER, A.P., GOETHALS, P.L.M., GABRIELS, W. y DE PAUW, N.** (2002). "Optimization of artificial neural network (ANN) model design for prediction of macroinvertebrates in the Zwalm river basin (Flanders, Belgium)." *International Environmental Modelling and Software Society Meeting*, 174(1-2), 161-173.
- DEGHANISANIJ, H., YAMAMOTOA, T. y RASIAH, V.** (2004). "Assessment of evapotranspiration estimation models for use in semi-arid environments." *Agricultural Water Management* 64, 91-106.
- DELGADO, J.A.** *Redes neuronales*. <http://www.monografias.com/trabajos38/redes-neuronales/redes-neuronales.shtml#redesbiolog>. Consulta: abril 2007.
- DEMIR, V., YURDEM, H., y DEGIRMENCIOGLU, A.** (2007). "Development of prediction models for friction losses in drip irrigation laterals equipped with integrated in-line and on-line emitters using dimensional analysis." *Biosystems Engineering*. 96, (4), 617-631.
- DEMUTH, H., y BEALE, M.** (2003). *Neural networks toolbox: for use with MATLAB, Users' manual Version 7.4.0(R2007a)* (2007). The MathWorks Inc, Natick, Massachusetts.
- DE SOUZA, F., y YODER, R.E.** (1994). "ET estimation in the north east of Brazil: Hargreaves or Penman-Monteith equation?" *Proceedings, Technical Paper ASAE International Winter Meeting*, ASAE, St Joseph, Michigan.
- DOLLING, O.R., y VARAS, E.A.** (2002). "Artificial neural networks for streamflow prediction." *Journal of Hydraulic Research* 40(5), 547-554.
- DOORENBOS, J., y PRUITT, W.O.** (1977). *Guidelines for predicting crop water requirements*. Irrigation Drainage Paper No. 24, FAO. Roma.
- ELGAALI, E., y GARCÍA, L.** (2004). "Neural network modeling of climate change impacts on irrigation water supplies in Arkansas River Basin." *Hydrology Days*, Colorado.

- ELSHORBAGY, A., SIMONOVIC, S.P., y PANU, U.S. (2000). "Performance evaluation of artificial neural networks for runoff prediction." *Journal of Hydrologic Engineering* 5(4), 424-427.
- FISZELEW, A., y GARCÍA-MARTÍNEZ, R. Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genéticos. <http://laboratorios.fi.uba.ar/lisi/R-ITBA-26-rnn-ags.pdf>
Consulta: septiembre 2008.
- FLOOD, I., y KARTAM, N. (1994a). "Neural networks in civil engineering. I: Principles and understanding." *Journal of Computing in Civil Engineering* 8(2), 131-148.
- FLOOD, I., y KARTAM, N. (1994b). "Neural networks in civil engineering. II: Systems and application." *Journal of Computing in Civil Engineering* 8(2), 148-165.
- FLOOD, I. (2006). "Next generation artificial neural networks for civil engineering." *Journal of Computing in Civil Engineering* 20(5), 305-307.
- FRENCH, M.N., KRAJEWSKI, W.F., y CUYKENDALL, R.R. (1992). "Rainfall forecasting in space and time using a neural network." *Journal of Hydrology* 137, 1-37.
- FUNAHASHI, K. (1989). "On the approximate realization of continuous mappings by neural networks." *Neural Networks* 2, 183-192.
- FURUNDZIC, D. (1997). "Application example of neural networks for time series analysis: Rainfall-runoff modelling." *Signal Processing* 64, 383-396.
- GAMAL, A., y SMITH, D.W. (2002). "A neural network model to predict the wastewater inflow incorporating rainfall events." *Water Research* 36, 1115-1126.
- GANGULY, A.R., y BRAS, R.L. (2003). "Distributed quantitative precipitation forecasting using information from radar and numerical weather prediction models." *Journal of Hydrometeorology*, 4, 115-123.
- GARCÍA-BARTUAL, R. (2002). "Short term river flow forecasting with neural networks." *Biennial meeting of the International Environmental Modelling and Software Society: Integrated assessment and decision support*, Lugano, 2, 160,165.
- GARCÍA-BARTUAL, R. (2005). *Redes neuronales artificiales en ingeniería hidráulica y medioambiental: Fundamentos*. Apuntes de la asignatura de doctorado con el mismo nombre. Sin publicar.
- GARCÍA, M., RAES, D., ALLEN, R., y HERBAS, C. (2004). "Dynamics of reference evapotranspiration in the Bolivian highlands (Altiplano)." *Agricultural and Forest Meteorology* 125, 67-82.
- GARCÍA, L.A., y SHIGIDI, A. (2006). "Using neural networks for parameter estimation in ground water." *Journal of Hydrology* 318, 215-231.
- GAVILÁN, P., LORITE, I.J., TORNERO, S., y BERENGENA, J. (2006). "Regional calibration of Hargreaves equation for estimating referente ET in a semiarid environment." *Agricultural Water Management* 81, 257-281.
- GOH, A.T.C. (1999). "Soil laboratory data interpretation using generalized regression neural network." *Civil and Environmental Systems Engineering* 16, 175-195.
- HAGAN, M.T., y MENHAJ, M.B (1994). "Training multilayer networks with the Marquardt Algorithm." *IEEE Transactions on Neural Networks* 5 (6), 989-993.
- HAGAN, M.T., DEMUTH, H., y BEALE, M. (1996). *Neural Network Design*. PWS Publishing, Boston.
- HARGREAVES, G.H., y SAMANI, Z.A., (1985) "Reference crop evapotranspiration from temperature." *Applied Engineering in Agriculture* 1(2), 96-99.
- HAYKIN, S. (1999). *Neural networks. A comprehensive foundation*. Prentice Hall International Inc., New Jersey.

- HEBB, D.O. (1949).** *The organization of behaviour*. John Wiley and Sons. Nueva York.
- HILERA, J.R., y MARTÍNEZ, V.J., (1995).** *Redes neuronales artificiales: Fundamentos, modelos y aplicaciones*. RA-MA. Madrid.
- HONG, Y.S., ROSEN, M.R. y REEVES, R.R. (2002).** “Dynamic fuzzy modelling of storm water infiltration in urban fractured aquifers.” *Journal of Hydrologic Engineering* 7(5), 380-391.
- HORNIK, K., STINCHCOMBE, M., y WHITE, H. (1989).** “Multilayer feedforward networks are universal approximators.” *Neural Networks* 2, 359-366.
- HOWELL, T.A., y HILLER, E.A. (1974).** “Trickle irrigation lateral design.” *Transactions of the ASAE* 17(5), 902-908.
- HOWELL, T.A., y BARINAS, F.A. (1980).** “Pressure losses across trickle irrigation fittings and emitters.” *Transactions of the ASAE* 23(4), 928-933.
- HSU, K., GUPTA, H.V., GAO, X., SOROOSHIAN, S., e IMAM, B. (2002).** “Self-organizing linear output map (SOLO): An artificial neural network suitable for hydrologic modelling and analysis.” *Water Resources Research* 38(12), 1-17.
- HUPET, F., y VANCLOOSTER, M. (2001).** “Effect of the sampling frequency of meteorological variables on the estimation of the reference evapotranspiration.” *Journal of Hydrology* 243, 192-204.
- IMRIE, C.E., DURUCAN, S., y KORRE, A. (2000).** “River flow prediction using artificial neural networks: generalisation beyond the calibration.” *Journal of Hydrology* 233, 138-153.
- IRIE, B., y MIYAKE, S. (1988).** “Capabilities of three-layered perceptrons.” *IEEE International Conference on Neural Networks* 1: 641-648.
- IRIONDO, A., y MOTA, J. (2004).** “Desarrollo de una red neuronal para estimar el oxígeno disuelto en el agua a partir de instrumentación de E.D.A.R.” *XXV Jornadas de Automática*, Ciudad Real.
- IRMAK, S., PAYERO, J., MARTIN, D., IRMAK, A., y HOWELL, T.A., (2006)** “Sensitivity analyses and sensitivity coefficients of standardized daily ASCE-Penman-Monteith equation.” *Journal of Irrigation and Drainage Engineering* 132(6): 564-578.
- ISASI-VIÑUELA, P., y GALVÁN-LEÓN, I.M. (2004).** *Redes de neuronas artificiales. Un enfoque práctico*. Pearson Prentice Hall. Madrid.
- ISLAM, S., Y KOTHARI, R. (2000).** “Artificial neural networks in remote sensing of hydrologic processes.” *Journal of Hydrologic Engineering* 5(2), 138-144.
- JAIN, S.K., DAS, A., y SRIVASTAVA, D.K. (1999)** “Application of ANN for reservoir inflow prediction and operation.” *Journal of Water Resources Planning and Management* 125(5):263-271.
- JAIN, A. y SRINIVASULU, S. (2006).** “Integrated approach to model decomposed flow hydrograph using artificial neural network and conceptual techniques.” *Journal of Hydrology* 317, 291-306.
- JAYAWARDENA, A.W., y FERNANDO, D.A.K., (1998).** “Use of Radial Basis Function Type Artificial Neural Networks for Runoff Simulation.” *Computer-Aided Civil and Infrastructure Engineering* 13, 91-99.
- JENSEN, M.E., y HAISE, H.R. (1963).** “Estimating evapotranspiration from solar radiation.” *Proceedings of the ASCE. Journal of Irrigation and Drainage Division* 89, 15-41.
- JENSEN, M.E., BURMAN, R.D., y ALLEN, R.G. (1990).** *Evapotranspiration and irrigation water requirements*. ASCE Manuals and Reports on Engineering Practices No 70, ASCE. Nueva York.
- JEPPSON R.W. (1982).** *Analysis of flow in pipe networks*. Ann Arbor Science Publishers, Inc., Ann Arbor, Michigan.
- JIA, Y., Y CULVER, T.B. (2006).** “Bootstrapped artificial neural networks for synthetic flow generation with a small data sample.” *Journal of Hydrology* 331, 580-590.

- JUANA L., RODRÍGUEZ-SINOBAS L. y LOSADA A.** (2002a). "Determining minor head losses in drip irrigation laterals. I: Methodology." *Journal of Irrigation and Drainage Engineering* 128 (6), 376-384.
- JUANA L., RODRÍGUEZ-SINOBAS L. y LOSADA A.** (2002b). "Determining minor head losses in drip irrigation laterals. II: Experimental study and validation." *Journal of Irrigation and Drainage Engineering* 128 (6), 385-396.
- JUANA L., LOSADA A., RODRÍGUEZ-SINOBAS L. y SÁNCHEZ, R.** (2004). "Analytical relationships for designing rectangular drip irrigation units." *Journal of Irrigation and Drainage Engineering* 130 (1), 47-59.
- KARMELLI, D., y KELLER, J.** (1975). *Trickle irrigation design*. Rain bird sprinkler manufacturing corporation. Glendora. California.
- KIM, T.W., y VALDÉS, J.B.** (2003). "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks." *Journal of Hydrologic Engineering* 8(6), 319-328.
- KIŞI, Ö.** (2004). "River flow modelling using artificial neural networks." *Journal of Hydrologic Engineering* 9(1), 60-63.
- KIŞI, Ö.** (2005). "Suspended sediment estimation using neurofuzzy and neural network approaches." *Hydrological Sciences Journal* 50(4), 683-696.
- KIŞI, Ö.** (2006). "Evapotranspiration estimation using feed.forward neural networks." *Nordic Hydrology* 37(3), 247-260.
- KIŞI, Ö., y ÖZTÜRK, Ö** (2007). "Adaptive neurofuzzy computing technique for evapotranspiration estimation." *Journal of Irrigation and Drainage Engineering* 133 (4): 368-379.
- KNUTTI, R., STOCKER, T.F., JOOS, F., y PLATTNER, G.K.** (2003). "Probabilistic climate change projections using neural networks." *Climate Dynamics* 21, 257-272.
- KOHOHEN, T.** (1997). *Self-organizing maps*. Springer-Verlag. Heidelberg.
- KUMAR M., RAGHUWANSHI, N.S., SINGH R., WALLENDER W.W. y PRUITT W.O.** (2002). "Estimating evapotranspiration using artificial neural network." *Journal of Irrigation and Drainage Engineering* 128 (4): 224-233.
- KUMAR, M., BANDYOPADHYAY, A., RAGHUWANSHI, N.S., SINGH,R.** (2008). "Comparative study of conventional and artificial neural network-based ETo estimation models." *Irrigation Science* 26, 531-545.
- LACHTERMACHER, G., y FULLER, J.D.** (1994). "Backpropagation in hydrological time series forecasting. K.W. Hipel et al. (eds). *Stochastic and Statistical Methods in Hydrology and Environmental Engineering* 3, 229-242.
- LEY, T.W., HILL, R.W., y JENSEN, D.T.** (1994). "Errors in Penman-Wright alfalfa reference evapotranspiration estimates II: Effects of weather sensor measurement variability." *Transactions of the ASAE* 37(6), 1863-1870.
- LIMA, J.E.F., FERREIRA, R.S.A. y CHRISTOFIDIS, D.** (1999). "O uso da irrigação no Brazil." *O Estado das Aguas no Brazil, Perspectivas de gestão e informação de recursos hídricos*. Agência Nacional de Energia Eléctrica, World Meteorological Organization, Brasilia.
- LIN, G.F., y CHEN, G.R.** (2006). "An improved neural network approach to the determination of aquifer parameters." *Journal of Hydrology* 316, 281-289.
- LÓPEZ-URREA, R., MARTÍN DE SANTA OLALLA, F., FABEIRO, C., y MORATALLA, A.** (2006). "Testing evapotranspiration equations using lysimeters observations in a semiarid climate." *Agricultural Water Management* 85, 15-26.
- MARTÍNEZ-COB, A., y TEJERO-JUSTE, M.** (2004). "A wind-based qualitative calibration of the Hargreaves ETo estimation equation in semiarid regions." *Agricultural Water Management* 64, 251-264.

- McCULLOCH, W.S., y PITTS, W.A.** (1943). "A logical calculus of the ideas immanent in nervous activity". *Boullletin of mathematics and biophysics* 5, 115-133.
- McNAUGHTON, K.G. y JARVIS, P.G.** (1984). "Using the Penman-Monteith equation predictively." *Agricultural Water Management* 8, 263-278.
- MILLER, W.T., SUTTON, R.S., y WERBOS, P.J.,** Eds. (1991). *Neural networks for control (neural network modelling and connectionism*. MIT Press. Massachusetts.
- MINNES, A.W., y HALL, M.J.,** (1996). "Artificial neural networks as rainfall-runoff models." *Hydrological Sciences Journal* 41(3):399-416.
- MINSKY, M., y PAPER, S.** (1969). *Perceptrons*. MIT Press. Massachusetts.
- MOHAN, S., y ARUMUGAM, N.,** (1996) "Relative importance of meteorological variables in evapotranspiration: Factor analysis approach." *Water Resources Management* 10, 1-20.
- MONTANA, D., Y DAVIS, L.** (1989). "Training feed-forward networks using genetic algorithms." *International Joint Conference on Artificial Intelligence*. Morgan Kaufmann.
- MORADKHANI, H., HSU, K., GUPTA, H.V., y SOROOSHIAN, S.** (2004). "Improved streamflow forecasting using self-organizing radial basis function artificial neural networks." *Journal of Hydrology* 295, 246-262.
- MORSHER, J., y KALACHURCHI, J.J.** (1998). "Application of artificial neural network and genetic algorithm in flow and transport simulations." *Advances in Water Resources* 22(2), 145-158.
- MYERS, C. E.** (1992). *Delay learning in artificial neural networks*. Chapman and Hall. Londres.
- NAGY, H.M., WATANABE, K., Y HIRANO, M.** (2002). "Prediction of sediment load concentration in rivers using artificial neural network model." *Journal of Hydraulic Engineering* 128(6), 588-595.
- NAOUM, S., y TSANIS, I.K.** (2003). "Hydroinformatics in evapotranspiration estimation." *Environmental Modelling and Software* 18, 261-271.
- OLDEN, J.D., y JACKSON, D.A.** (2001). "Fish-habitat relationships in lakes: Gaining predictive and explanatory insight by using artificial neural networks." *Transactions of the American Fisheries Society* 130, 878-897.
- OLSSON, J., UVO, C.B., JINNO, K., KAWAMURA, A., NISHIYAMA, N., KOREEDA, N., NAKASHIMA, T., y MORITA, O.** (2004). "Neural networks for rainfall forecasting by atmospheric downscaling." *Journal of Hydrologic Engineering* 9 (1), 1-12.
- PAISLEY, M.F., WALLEY, W.J., NIKHADE, J. y DILS, R.** (2003). "Identification of the key biological indicators of nutrient enrichment in rivers for use in predictive/diagnostic models." *Diffuse Pollution Conference*, Dublin.
- PALAU-SALVADOR, G., SANCHIS, L.H., GONZÁLEZ-ALTOZANO, P., y ARVIZA-VALVERDE, J.** (2006). "Real Local Losses Estimation for On-Line Emitters Using Empirical and Numerical Procedures." *Journal of Irrigation and Drainage Engineering* 132 (6), 522-530.
- PAN, T., y WANG, R.** (2004). "State space neural networks for short term rainfall-runoff forecasting." *Journal of Hydrology* 297, 34-50.
- PATEL, R.M., PRASHER, S.O., GOEL, P.K., y BASSI, R.** (2002). "Soil salinity prediction using artificial neural networks". *Journal of the American Water Resources Association* 38(1), 91-100.
- PATTERSON, D.W.** (1996). *Artificial neural networks. Theory and applications*. Prentice Hall, Singapore.
- PENMAN, H.L.** (1948). "Natural evaporation from open water, bare soil and grass." *Proceedings of the Royal Society of London* A193, 120-146.
- PEREIRA, A.R., ANGELOCCI, L.R., y SENTELHAS, P.C.** (2002). *Agrometeorologia: fundamentos e aplicações práticas*. Editor Agropecuária. Guaíba, Brasil.

- PEREIRA, A.R., y PRUITT, W.O.** (2004). "Adaptation of the Thornthwaite scheme for estimating daily referente evapotranspiration." *Agricultural Water Management* 66, 251-257.
- PÉREZ-CUEVA, A.J.** (1994). *Atlas climàtic de la Comunitat Valenciana (1961-1990)*. Conselleria d'Obres Públiques, Urbanisme i Transports. Sèrie Publicacions de Divulgació Tècnica. Col.lecció Territori 4. Valencia.
- PIJANOWSKI, B.C., BROWN, D.G., SHELLITO, B.A., y MANIC, G.A.** (2002). "Using neural nets and GIS to forecast land use changes: A land transformation model." *Computers, Environment and Urban Systems* 26(6), 553-557.
- PIPER, B.S.** (1989). "Sensitivity of Penman estimates of evaporation to errors in input data." *Agricultural Water Management* 15, 279-300.
- PIZARRO, F.** (1987). *Riegos localizados de alta frecuencia*. Editorial Mundi-Prensa. Madrid.
- PRICE, R.K., SAMEDOV, J.N., y SOLOMATINE, D.P.** (1998). "An artificial neural network model of a generalised channel network." *Proceedings of the 3rd International Conference on Hydroinformatics*, 813-818. Copenhagen.
- PRIESTLEY, C.H.B., Y TAYLOR, R.J.** (1972). "On the assessment of surface heat flux and evaporation using large-scale parameters." *Monthly Weather Review* 100, 81-82.
- PROVENZANO G., PUMO D., y DI DIO P.** (2003). "Valutazione delle perdite di carico nelle linee gocciolanti integrali." *Rivista di Ingegneria Agraria* 4, 55-62.
- PROVENZANO G., y PUMO D.** (2004). "Experimental analysis of local pressure losses for micro irrigation laterals." *Journal of Irrigation and Drainage Engineering* 130 (4), 318-324.
- PROVENZANO G., PUMO D., y DI DIO, P.** (2005). "Simplified procedure to evaluate head losses in drip irrigation laterals." *Journal of Irrigation and Drainage Engineering* 131 (6), 525-532.
- PROVENZANO G., DI DIO, P., y PALAU-SALVADOR, G.** (2007). "New computational fluid dynamic procedure to estimate friction and local losses in coextruded drip laterals." *Journal of Irrigation and Drainage Engineering* 133 (6), 520-527.
- RAGHUWANSHI, N.S., SINGH, R., y REDDY, L.S.** (2006). "Runoff and sediment yield modelling using artificial neural networks: Upper Siwane River, India." *Journal of Hydrologic Engineering* 11(1), 71-79.
- RAHIMI, A.** (2008). "Comparative study if Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment." *Irrigation Science* 26: 253-259.
- RAJANAYAKA, C., SAMARASINGHE, S. y KULASIRI, D.** (2002). "Solving the inverse problem in stochastic groundwater modelling with artificial neural networks." *Proceedings of the Biennial Congress of the International Environmental Modelling and Software Society*, 154-159.
- RANA, G., y KATERJI, N.** (1998). "A measurement based sensitivity analysis of the Penman-Monteith actual evapotranspiration model for crops of different height and in contrasting water status." *Theoretical and Applied Climatology* 60, 141-149.
- RIPLEY, B. D.** (1996). *Pattern recognition and neural networks*. Cambridge University Press, Cambridge.
- RODRIGO, J., HERNÁNDEZ, J.M., PÉREZ, A., y GONZÁLEZ, J.F.** (1997). *Riego localizado*. Ediciones Mundi Prensa. Madrid.
- ROSENBLATT, F.** (1957). "The perceptron: a probabilistic model for information storage and organization in the brain." *Psychological review* 65, 386-408.
- RUMELHART, D., HINTON, G., y WILLIAMS, R.,** (1986). "Learning representations by back-propagating errors." *Nature* 323, 533-536.
- SAJIKUMAR, N., y THANDAVESWARA, B.S.** (1999). "A non-linear rainfall-runoff model using an artificial neural network." *Journal of Hydrology* 216, 32-55.

- SÁNCHEZ-FERNANDES, L.F., y HAIE, N. (2004). "Modelo de red neuronal para simulación de hidrogramas en cuencas hidrográficas." *Ingeniería Hidráulica en México* 19(2), 17-29.
- SAXTON, K.E. (1975). "Sensitivity analyses of the combination evapotranspiration equation." *Agricultural Meteorology* 15, 343-353.
- SCHLICHTING, H. (1979). *Boundary-Layer theory*. McGraw-Hill. Nueva York.
- SHAMSELDIN, A.Y. (1997). "Application of a neural network technique to rainfall runoff modelling." *Journal of Hydrology* 199, 272-294.
- SAHOO, G.B., RAY, C., y DE CARLO, E.H. (2006). "Use of neural network to predict flash flood and attendant water qualities of a mountainous stream on Oahu, Hawai." *Journal of Hydrology* 327, 525-538.
- SINGH, M., BHATTACHARYA, A.K., NAIR, T.V.R. y SINGH, A.K. (2002a). "Nitrogen losses through subsurface drainage effluent in coastal rice fields from India." *Agricultural Water Management*, 52, 249-260.
- SINGH, M., BHATTACHARYA, A.K., SINGH, A.K. y SINGH, A. (2002b). "Application of SALTMOD in coastal clay soils in India" *Irrigation Drainage Systems* 16, 213-231.
- SKRZYPEK, J., y KARPLUS, W., Editors. (1992). *Neural networks in vision and pattern recognition*. World Scientific Series in Machine Perception and Artificial Intelligence. Los Angeles.
- SMAJSTRLA, A.G., ZAZUETA, F.S., y SCHMIDT, G.M. (1987). "Sensitivity of potential evapotranspiration to four climatic variables in Florida." *Soil and Crop Science Society of Florida* 46, 21-26.
- SMITH, M., ALLEN, R., y PEREIRA, L. (1997). *Revised FAO methodology for crop water requirements*, Land and Water Development Division, FAO. Roma.
- SOBRINO, J.A., GÓMEZ, M., JIMÉNEZ-MUÑOZ, J.C., OLIOSO, A., CHEHBOUNI, G. (2005). "A simple algorithm to estimate evapotranspiration from DAIS data: Application to the DAISEX campaigns." *Journal of Hydrology* 315, 117-125.
- SOHRABI, T.M., BUSCH, J.R., y WRIGHT, J.L. (1988). *Sensitivity and uncertainty analyses of Wright-1982 Penman ET and crop water-use model*. Paper No 88-2527, American Society of Agricultural Engineers, St. Joseph, Michigan.
- SOLIS, F., y WETS, J. (1981). "Minimization by random search techniques." *Mathematics of operations research* 6, 19-30.
- SOUSA, E.F., BERNARDO, S., AZEVEDO, H.J., BERBERT, P.A., y VIANA, A.P. (2002). "Estimativa da demanda hídrica provável na região norte fluminense." *Engenharia Agrícola* 22(3), 322-331.
- STUDZINSKI, J. (2002). "Computer aided management of water & wastewater systems in municipal waterworks." *Proceedings 14th European Simulation Symposium*, Dresden.
- SUDHEER, K.P., GOSAIN, A.K., y RAMASASTRI, K.S. (2003). "Estimating actual evapotranspiration from limited climatic data using neural computing technique." *Journal of Irrigation and Drainage Engineering* 129 (3), 214-218.
- SUDHEER, K.P., y JAIN, A. (2004). "Explaining the internal behaviour of artificial neural network river flow models." *Hydrological Processes* 18, 833-844.
- SHUKLA, M.B., KOK, R., PRASHER, S.O., CLARK, G., y LACROIX, R. (1996). "Use of artificial neural network in transient drainage design." *Transactions of the ASAE* 39(1):119-124.
- TAYFUR, G. (2002). "Artificial neural networks for sheet sediment transport." *Hydrological Sciences Journal* 47(6), 879-892.
- THIRUMALAIAN, K., y DEO, M.C. (1998). "River stage forecasting using artificial neural networks." *Journal of Hydrologic Engineering* 3(1), 26-32.

- THORNTHWAITE, C.W.** (1948). "An approach toward a rational classification of climate." *Geographical Review* 38, 35.
- TOTH, E., BRATH, A., y MONTANARI, A.** (2000) "Comparison of short-term rainfall prediction models for real-time flood forecasting". *Journal of Hydrology*, 239, 132-147.
- TRAJKOVIC S., TODOROVIC B., y STANKOVIC M.** (2003). "Forecasting of reference evapotranspiration by artificial neural networks." *Journal of Irrigation and Drainage Engineering* 129 (6), 454-457.
- TRAJKOVIC. S.** (2005). "Temperature based approaches for estimating reference evapotranspiration." *Journal of Irrigation and Drainage Engineering* 131(4), 316-323.
- TRAJKOVIC. S.** (2007). "Hargreaves versus Penman-Monteith under humid conditions." *Journal of Irrigation and Drainage Engineering* 133(1), 38-42.
- TURNER, J.E., DOOGE, J.C.I., y BREE, T.** (2001). "Discussion of 'Single Storm Runoff Analysis Using Z-Transform.'" *Journal of Hydrologic Engineering* 6(2), 173-174.
- VALENÇA, M., y LUDEMIR, T.** (1998). "Self-organizing modelling in forecasting daily river flows." *Proceedings of the 5th Brazilian Symposium on Neural Networks*, 210-214.
- VALENTIN, N., DENOEU, T., y FOTOOHI, F.** (1999). "Modelling of coagulant dosage in a water treatment plant." *Engineering Applications of Neural Networks. Proceedings of the 5th International Conference on Engineering Applications of Neural Networks (EANN'99)*, Tarun.
- VALLESQUINO P., y LUQUE-ESCAMILLA P.L.** (2001) ".New algorithm for hydraulic calculation in irrigation laterals." *Journal of Irrigation and Drainage Engineering* 127(4), 254-260.
- VILLALOBOS, F.J., MATEOS, L., ORGAZ, F., y FERERES, E.** (2002). *Fitotecnia. Bases y tecnologías de la producción agrícola*. Editorial Mundi-Prensa. Madrid.
- VON BERNUTH, R.D., y WILSON, T.** (1989). "Friction factors for small diameter plastic pipes." *Journal of Hydraulic Engineering* 115(2), 183-192.
- VON BERNUTH, R.D.** (1990). "Simple and accurate friction loss equation for plastic pipe." *Journal of Irrigation and Drainage Engineering* 116(2), 294-298.
- WATTERS, G.Z., y KELLER, J.** (1978). "Trickle irrigation tubing hydraulics." *ASAE paper* 78-2015, 15. ASAE, St. Joseph, Michigan.
- WIDROW, B. y HOFF, M.** (1960). "Adaptative switching circuits." *IREWESCON Convention Record* 4, 96-104.
- WILLMOTT, C.J.** (1981). "On the validation model." *Physical geography* 2(2),184-194.
- WOINAROSCHY, A., y VIDRIGHIN, M.** (1999). "Neural networks simulation and optimization of waste water treatment." *Second European Congress of Chemical Engineering.*, Montpellier.
- WU, J.S., HAN, J., ANNAMBHOTLA, S., y BRYANT, S.** (2005). "Artificial neural networks for forecasting watershed runoff and stream flows." *Journal of Hydrologic Engineering* 10(3), 216-222.
- YANG, C.C., PRASHER, S.O., y LACROIX, R.** (1996). "Application of artificial neural network to land drainage engineering." *Transactions of the ASAE* 39(2), 525-533.
- ZANETTI S.S., SOUSA E.F., OLIVEIRA V.P.S., ALMEIDA F.T. y BERNARDO S.** (2007). "Estimating evapotranspiration using artificial neural network and minimum climatological data." *Journal of Irrigation and Drainage Engineering* 133 (2), 83-89.
- ZANG, G, EDDY, B. y HU, M.Y.** (1998). "Forecasting with artificial neural networks: The state of the art." *International Journal of Forecasting* 14, 35-62.

anejo A

nociones sobre ANNs. El MLP

A.1. CARACTERIZACIÓN DE UNA RED NEURONAL	153
A.1.1. NODOS O NEURONAS	153
A.1.2. COMBINACIÓN DE SEÑALES DE ENTRADA A UN NODO. POST SYNAPTIC POTENTIAL	154
A.1.3. FUNCIÓN DE ACTIVACIÓN	155
A.1.4. PATRÓN DE CONECTIVIDAD	156
A.1.5. REGLA DE PROPAGACIÓN DE LAS SEÑALES A TRAVÉS DE LA RED	156
A.1.6. REGLA DE ENTRENAMIENTO	157
A.2. TOPOLOGÍA DE LAS REDES NEURONALES	157
A.3. EL PERCEPTRON FRENTE AL PERCEPTRON MULTICAPA O MULTINIVEL	158
A.4. EL PROCESO DE APRENDIZAJE	159
A.4.1. TIPOLOGÍA	159
A.4.2. ERROR BACKPROPAGATION LEARNING ALGORITHM	161
A.4.2.1. <i>Fundamentos del método</i>	161
A.4.2.2. <i>Implementación del EBLA</i>	163
A.4.3. CRITERIOS DE PARADA.	164
A.4.4. INICIALIZACIÓN DE PESOS	164
A.5. ALGORITMOS DE ENTRENAMIENTO AVANZADOS	165
A.5.1. TÉCNICA DEL GRADIENTE CONJUGADO (CGD)	165
A.5.2. MÉTODO QUASI-NEWTON (QN)	165
A.5.3. ALGORITMO DE LEVENBERG-MARQUARDT (LM)	166
A.6. MANEJO DEL SISTEMA DE DATOS. CAPACIDAD DE GENERALIZACIÓN DE LA RED	167

A.1. Caracterización de una red neuronal

En este apartado se presentan los parámetros básicos que caracterizan una red neuronal (ANN). Se trata de los componentes que deben ser definidos necesariamente para que esta red neuronal pueda funcionar correctamente, recibiendo información del entorno, procesándola dentro de su estructura y devolviendo la información procesada al exterior.

Podemos encontrar un sinnúmero de tipologías de redes neuronales artificiales, pero a efectos prácticos, se pueden establecer seis aspectos que deben ser definidos para la aplicación de las mismas en la práctica: 1) unidades de proceso o nodos, 2) regla de combinación de señales de entrada a un nodo, 3) regla para calcular la señal de salida o activación de un nodo, 4) patrón de conectividad, 5) regla de propagación de las señales a través de la red y 6) regla de entrenamiento para adaptar los pesos.

Una elección adecuada de sus características, más una estructura conveniente, es el procedimiento convencional utilizado para construir redes capaces de realizar una determinada tarea.

A.1.1. NODOS O NEURONAS

Un nodo o neurona es una unidad que recibe señales desde otros nodos, que procesa siguiendo una regla de combinación de señales y una regla de activación. Como resultado, el nodo produce una señal de salida que se transmite mediante conexiones sinápticas a otros nodos.

Generalmente, se pueden encontrar tres tipos de neuronas:

- Aquellas que reciben estímulos externos, que tomarán la información de entrada.
- Dicha información se transmite a ciertos elementos internos que se ocupan de su procesamiento. Es en las sinapsis y neuronas de este segundo nivel donde se genera cualquier tipo de representación interna de la información. Puesto que no tienen relación directa con la información de entrada ni con la de salida, estos nodos se denominan unidades ocultas.

- Tras finalizar el procesado, la información llega a las neuronas de salida, que generan la respuesta del sistema.

Los nodos de entrada son unidades esencialmente pasivas, pues no modifican la señal recibida. Su función consiste en presentar a la red los datos de entrada procedentes del entorno. Estos datos de entrada pueden ser datos brutos recogidos por sensores, aparatos de medición o cualquier tipo de dispositivo. Los nodos ocultos no tienen comunicación directa con el entorno. El número de nodos ocultos determina el grado de adaptabilidad y potencialidad de la red para captar y reproducir relaciones no lineales complejas entre los inputs y los outputs.

Se denomina capa o nivel a un conjunto de neuronas cuyas entradas provienen de la misma fuente y cuyas salidas se dirigen al mismo destino.

A.1.2. COMBINACIÓN DE SEÑALES DE ENTRADA A UN NODO. POST SYNAPTIC POTENTIAL

Se trata de la operación mediante la cual se combinan todas las señales que alcanzan un nodo. Consiste en una combinación lineal de dichas señales, que son ponderadas (atenuadas o amplificadas) a través de un parámetro, denominado peso, asociado a la sinapsis correspondiente. Estas señales de entrada pueden excitar a la neurona (peso positivo) o inhibirla (peso negativo). Si la suma es igual o mayor que el umbral o bias de la neurona, entonces la neurona se activa.

La operación PSP (post synaptic potential) igualada a cero representa geoméricamente un hiperplano en el espacio R^n de los inputs o espacio de patrones. Esta regla está separando geoméricamente dos regiones del espacio R^n . Una variante para la representación formal del potencial post sináptico consiste en añadir una conexión ficticia con peso w_{0k} y valor de entrada $x=1$, de modo que podamos prescindir del umbral.

En otro tipo de redes, las RBF (radial basis function), el PSP se define como el cuadrado de la distancia euclídea entre dos puntos del espacio de patrones. Además, dicha distancia sufre un escalamiento mediante los valores b_k . Estas PSP generan valores idénticos en hiperesferas del espacio de patrones.

A.1.3. FUNCIÓN DE ACTIVACIÓN

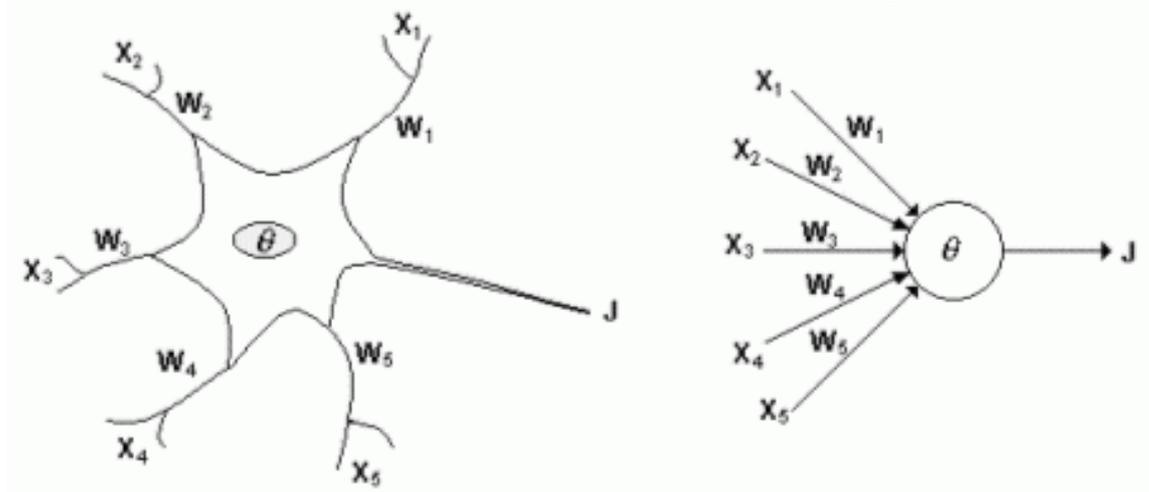
Las funciones de activación se ejecutan en el nodo a continuación de la operación PSP. Consiste en una función continua real de variable real y representa una operación en virtud de la cual se calcula la señal de salida de un nodo determinado. La señal de salida producida será transmitida a otros nodos a través de las conexiones de la red. En la práctica, se escoge la misma función de activación para todos los nodos de una misma capa. Las funciones de activación más empleados son:

- Las funciones *escalón* y variantes. Dicha función se asocia a neuronas binarias en las que, cuando la suma de las entradas es mayor o igual que el umbral de la neurona, la activación es 1; y si es menor, la activación es 0 ó -1. La función rampa se obtiene planteando una función escalón de transición lineal entre el cero y la unidad. La función identidad caracteriza siempre a los nodos de la capa de entrada. Al ser no acotada, se usa frecuentemente en los nodos de salida, para evitar una salida conjunta de la red forzosamente truncada, por el uso de funciones de activación acotadas.
- Las funciones *sigmoidales*. Son curvas con forma de S con dos asíntotas, que definen salidas acotadas al intervalo $[0;1]$ o $[-1;1]$. Para la mayoría de los valores del estímulo de entrada, el valor dado por la función es cercano a uno de los valores asintóticos. Esto hace que, en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o baja del sigmoideo. La importancia de esta función proviene del hecho de que su derivada es siempre positiva y cercana a cero para los valores grandes positivos o negativos. Esto desempeña un papel relevante en los métodos de aprendizaje donde se usan derivadas. Puede establecerse la pendiente de la curva y, consecuentemente, la transición del mínimo al máximo o intervalo de sensibilidad.
- La función gaussiana. Los centros y la anchura de ésta pueden ser adaptados, lo cual las hace más adaptativas que las funciones sigmoidales.
- También son aplicadas otras funciones, entre las que pueden mencionarse la función seno, la raíz cuadrada o las funciones polinómicas, entre otras.

La figura A.1 representa la analogía entre el modelo biológico y su simplificación artificial. Las sinapsis aíslan o amplifican a conveniencia las señales recibidas de otras

neuronas, lo que se traduce en una serie de pesos w_i en el modelo artificial. Las señales son ponderadas mediante dichos pesos y se calcula el PSP, θ en la figura, sobre el que se ejecuta la función de activación, que produce como resultado una señal transmitida J .

Figura A.1. Correspondencia entre modelos biológico y artificial (Delgado, 2007)



A.1.4. PATRÓN DE CONECTIVIDAD

Para diseñar una red neuronal es necesario también establecer la disposición de las conexiones entre nodos. En la mayoría de aplicaciones en ingeniería, se usan las redes con conectividad completa, donde cada nodo oculto está conectado con la totalidad de los nodos existentes en la capa anterior y posterior, mientras que los nodos de la capa de entrada lo están con los de la segunda capa, y los de salida, con todos los de la capa anterior. Sin embargo, los nodos de una capa pueden estar total o parcialmente conectados entre sí. Las conexiones entre capas consecutivas pueden ser también sólo parciales. Además, las redes pueden ser recurrentes, en cuyo caso las salidas de ciertos nodos pueden retroalimentar la red, incorporándose de nuevo en los cálculos como señales de entrada que vuelven a alimentar a nodos de capas anteriores.

A.1.5. REGLA DE PROPAGACIÓN DE LAS SEÑALES A TRAVÉS DE LA RED

Una vez establecida la topología de la red, debe definirse la dirección de propagación de la información. Esto es: cuándo se ejecuta la activación de qué nodos, en qué orden y a qué nodos se dirige la señal de salida.

Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como de propagación hacia delante. Cuando las salidas pueden ser conectadas como entradas de neuronas de niveles previos o del mismo nivel, incluyéndose ellas mismas, la red es de propagación hacia atrás. Las redes de propagación hacia atrás que tienen lazos cerrados son sistemas recurrentes.

A.1.6. REGLA DE ENTRENAMIENTO

Las redes deben pasar por un proceso de entrenamiento para que puedan acabar realizando una tarea concreta o representar un modelo de utilidad con propósitos diversos. En este proceso, se pretende que la red capte las relaciones, los patrones, las tendencias o las propiedades más características de los datos suministrados, de modo que pueda ser capaz de generalizar posteriormente. Durante dicho proceso, los pesos van modificando los valores y se van adaptando según el algoritmo que se escoja hasta que se cumpla un criterio de convergencia determinado. Finalmente, el conocimiento adquirido permanece almacenado en los pesos de las conexiones. Para Isasi-Viñuela y Galván-León (2004), el esquema de aprendizaje de una red es lo que determina el tipo de problemas que será capaz de resolver. Asimismo, el conjunto de aprendizaje debe cumplir los siguientes requisitos: ser significativo y ser representativo.

A.2. Topología de las redes neuronales

Los aspectos fundamentales para establecer la topología o arquitectura de una red son: 1) el número de capas, 2) el número de neuronas por capa, 3) el grado de conectividad y 4) el tipo de conexiones entre neuronas. Cuando se realiza una clasificación de las redes en términos topológicos, se suele distinguir entre: a) redes con una sola capa, b) redes con múltiples capas y redes recurrentes (Haykin, 1999).

En las redes monocapa se establecen conexiones laterales entre las neuronas que pertenecen a la única capa que constituye la red. Estas redes se utilizan generalmente en tareas relacionadas con la autoasociación, por ejemplo, regenerar informaciones de entrada que se presentan a la red incompletas o distorsionadas.

Las redes multicapa son aquellas que disponen de conjuntos de neuronas agrupadas en varios niveles o capas. Se caracterizan por la presencia de, al menos, una capa oculta. Normalmente, estas redes poseen conexiones hacia adelante o feedforward. Sin embargo, en un gran número de estas redes también existe la posibilidad de conectar las salidas de las neuronas de capas posteriores a las entradas de las capas anteriores. Estas conexiones se denominan hacia atrás o feedback. Haciendo una lectura laxa, la red adquiere una perspectiva global, a pesar de su conectividad local, debido a la cantidad extra de conexiones sinápticas y a la dimensión extra de las interacciones neuronales (Churchland y Sejnowski, 1992). La habilidad de las neuronas ocultas para extraer relaciones de orden superior es particularmente valiosa cuando el tamaño de la capa de entrada es grande (Haykin, 1999). Las redes recurrentes se diferencian de las redes feedforward por el hecho de que presentan, al menos, un bucle feedback. La consideración de este bucle feedback tiene un profundo impacto en la capacidad de aprendizaje de la red. Además, estos bucles implican el uso de ramificaciones particulares compuestas de elementos de retraso unitario, que conducen a un comportamiento no lineal dinámico, si se supone que la red contiene unidades no lineales (Haykin, 1999).

A.3. El perceptron frente al perceptron multicapa o multinivel

El perceptron (Rosenblatt, 1957), que está formado por varias neuronas lineales que reciben las entradas y una neurona de salida, es capaz de decidir cuándo una entrada presentada a la red pertenece a una de las dos clases que es capaz de reconocer. El perceptron separa las dos regiones por un hiperplano cuya ecuación queda determinada por los pesos de las conexiones y el valor umbral de función de activación de la neurona. Sin embargo, al constar sólo de una capa de entrada y otra de salida con una única neurona, tiene una capacidad de representación bastante limitada y sólo es capaz de discriminar patrones muy sencillos, linealmente separables. Así, la separabilidad lineal limita a las redes con dos capas a la resolución de problemas en los que el conjunto de puntos sean separables geoméricamente.

Un perceptron multicapa o MLP (multilayer perceptron) se define generalmente como una red multinivel feedforward totalmente conectada y sujeta a un entrenamiento supervisado con un algoritmo de retropropagación del error. El MLP es una

generalización del perceptron simple y surge como consecuencia de las limitaciones derivadas del problema de la separabilidad no lineal. Cuando se establece la manera de retropropagar los errores medidos en la salida de la red hacia las neuronas ocultas, dando lugar a la llamada regla delta generalizada (Rumelhart et al., 1986), se crea una herramienta muy potente, capaz de abordar multitud de problemas reales. El perceptron multicapa, al considerar como mínimo una capa oculta, permite establecer regiones de decisión mucho más complejas que las de dos semiplanos. Diferentes autores (Cybenko, 1989; Hornik et al., 1989) han demostrado independientemente que el perceptron multicapa es un aproximador universal, en el sentido de que cualquier función continua sobre un compacto de R^n puede aproximarse con un perceptron multicapa, con dos capas ocultas de neuronas (cuando la función es continua, una única capa es suficiente). Esto sitúa al perceptron multicapa como una nueva clase de funciones para aproximar o interpolar relaciones no lineales entre datos de entrada y salida.

Uno de los principales defectos de los MLP consiste en la falta de una metodología clara para el diseño de una estructura de red apropiada para un problema dado, que permita ajustar un modelo evitando el problema de sobreajuste. Actualmente, la solución a este problema pasa por seguir un procedimiento de prueba y error (Patterson, 1996).

A.4. El proceso de aprendizaje

A.4.1. TIPOLOGÍA

Los diferentes métodos de aprendizaje se pueden clasificar en dos categorías, dependiendo de la información disponible (Castillo et al., 1999):

- *Aprendizaje supervisado.* En este caso los patrones para el aprendizaje están formados por parejas que constan de un vector de variables de entrada junto con las salidas correspondientes. Así, cada valor de salida es la respuesta deseada a las señales de entrada. Es decir, existe un agente externo que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor comprueba la salida de la red y en el caso de que ésta no coincida con

la deseada, se procederá a modificar los pesos de las conexiones. En este caso, los pesos se obtienen minimizando alguna función de error que mide la diferencia entre los valores de salida deseados y los calculados por la red. Hilera y Martínez (1995) distinguen asimismo entre:

- Aprendizaje por corrección de error. Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red.
 - Aprendizaje por refuerzo. Se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, sino de indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada y, en función de ello, se ajustan los pesos basándose en un mecanismo de probabilidades.
 - Aprendizaje estocástico. Consiste en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.
- *Aprendizaje no supervisado.* En este caso, los datos se presentan a la red sin información externa y la red tiene que descubrir por sí misma patrones o categorías. Este tipo de aprendizaje se encuadra dentro de las técnicas autoorganizativas, o técnicas automáticas para descubrir la estructura de los datos. Algunos métodos de aprendizaje no supervisados son:
 - Aprendizaje Hebbiano, que consiste en modificar los pesos de acuerdo con algún criterio de correlación entre las actividades neuronales (Hebb, 1949).
 - Aprendizaje competitivo, donde las neuronas diferentes se conectan con pesos negativos que fuerzan una competición para ganar la actividad neuronal.
 - Representación de características (feature mapping), que concierne a la ordenación geométrica de los vectores peso de las unidades competitivas (Kohonen, 1997).

A.4.2. ERROR BACKPROPAGATION LEARNING ALGORITHM

A.4.2.1. Fundamentos del método

Dentro de los algoritmos de aprendizaje, el algoritmo de retropropagación del error EBLA (Rumelhart et al., 1986) es el más importante para el entrenamiento supervisado de redes MLP de alimentación hacia adelante. El nombre del algoritmo proviene de la forma en que los errores a la salida de la red son propagados hacia atrás atravesando en sentido inverso las distintas capas de la red.

Para cada uno de los ejemplares presentados a la red, ésta generará unos valores output, los cuales podremos comparar con los valores objetivo y estimar así el error de entrenamiento. El objetivo del algoritmo consiste en ir modificando adecuadamente en sucesivas iteraciones los pesos de la red para reducir el error. En concreto, se efectúa la búsqueda del mínimo de una función de error apropiada. Para ello, es preciso definir una función de error. La elección habitual suele ser la suma de las diferencias al cuadrado o mean square error (MSE). Existen otras funciones de error, como la suma de errores absolutos o mean absolute error (MAE).

Si W es el número de pesos en la red, la función de error define una hiper-superficie en un espacio $W+1$ dimensional, la superficie de error. Para cada configuración de pesos, se tiene un valor de la función de error. El proceso de entrenamiento puede visualizarse como una búsqueda del mínimo en la superficie de error. Por otra parte, cabe destacar la complejidad de este proceso debido a la presencia de obstáculos de distinta índole en la superficie de error, mínimos locales, zonas planas, etc., que son desconocidos a priori. La estrategia de búsqueda del EBLA se basa en el método del gradiente, utilizando como función de error el MSE. Así, para unos valores iniciales de los pesos, la iteración de cálculo examina la pendiente de la superficie en las distintas direcciones de los ejes del espacio de ejes. Los pesos se modifican siguiendo la máxima pendiente, con incrementos proporcionales y de sentido contrario a las derivadas parciales del error respecto de los pesos. No obstante, se han desarrollado también métodos de búsqueda aleatoria para localizar el mínimo de dicha función (Solis y Wets, 1981) y métodos basados en técnicas evolutivas (Montana y Davis, 1989), en los que la búsqueda está guiada por una función de adecuación.

El proceso consta de dos etapas: en la primera, hacia adelante, se realizan los cálculos de la red para generar los outputs a partir de los inputs; en la segunda, hacia atrás, el error encontrado en la última capa se propaga hacia los nodos de las capas internas en sentido inverso y se modifican los pesos.

Aunque el aprendizaje de la red debe realizarse para minimizar el error total, el procedimiento más utilizado está basado en métodos del gradiente estocástico, que consisten en una sucesiva minimización de los errores para cada patrón, en lugar de minimizar el error total. Llamando w_{ij} al peso asociado a la conexión de la señal x_i de la neurona i hacia la neurona j , en la capa de salida. La variación del error E respecto de este peso w_{ij} viene dada por la derivada parcial

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial PSP_j} \frac{\partial PSP_j}{\partial w_{ij}} = \frac{\partial E}{\partial \sigma_j} \frac{\partial \sigma_j}{\partial PSP_j} \frac{\partial PSP_j}{\partial w_{ij}} = -\delta_j \frac{\partial PSP_j}{\partial w_{ij}} \quad (\text{A.1})$$

como

$$E = \frac{1}{2} \sum (\sigma_k - t_k)^2 \rightarrow \frac{\partial E}{\partial \sigma_j} = (\sigma_j - t_j) \quad (\text{A.2})$$

$$PSP_j = \sum_{i=0} x_i w_{ij} \rightarrow \frac{\partial PSP_j}{\partial w_{ij}} = x_i \quad (\text{A.3})$$

$$\frac{\partial \sigma_j}{\partial PSP_j} = \phi'(PSP_j) \quad (\text{A.4})$$

donde σ_j y t_j son los valores calculados y deseados, respectivamente. Así es sencillo comprobar que

$$\frac{\partial E}{\partial w_{ij}} = (\sigma_j - t_j) \phi'(PSP_j) x_i = -\delta_j x_i \quad (\text{A.5})$$

Siguiendo el criterio del gradiente, se adopta un cambio en el peso w_{ij} dado por

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = -\eta \cdot (\sigma_j - t_j) \phi'(PSP_j) x_i = \eta \delta_j x_i \quad (\text{A.6})$$

donde η se define como tasa de aprendizaje (*learning rate*) y determina la magnitud del incremento. Un valor pequeño de este parámetro supone una aproximación lenta hacia el mínimo, mientras que un valor grande acelera el proceso, con el riesgo de perder precisión en la determinación del mínimo por fluctuaciones alrededor de él, o incluso el salto a otro valle de la topografía de la superficie del error más allá de la zona donde se sitúa el mínimo buscado.

El procedimiento a seguir para fijar los pesos consiste en determinar la contribución del nodo oculto i al error de salida. Esta contribución depende, fundamentalmente, de la intensidad de las conexiones entre el nodo i y los nodos de la capa oculta, y del error de cada nodo de salida (δ_j). Así,

$$\delta_i = \left[\sum_j \delta_j w_{ij} \right] \phi'(PSP_i) \quad (A.7)$$

donde el subíndice j hace referencia a los nodos de la capa de salida y el subíndice i indexa el nodo de la capa oculta. Este procedimiento se aplica a las sucesivas capas en sentido inverso al de la operación normal de la red. Los valores de la derivada de la función de activación ϕ' dependerán de la función de activación escogida para cada nodo. La fórmula que usa el EBLA incluye un segundo sumando que permite ponderar favorablemente una inercia en la búsqueda del mínimo, mediante el uso del parámetro ϕ , llamado *momentum*. Con ello, se reduce la probabilidad de que Δw_{ij} presente excesivas oscilaciones. Así,

$$\Delta w_{ij}^{n+1} = \eta \delta_j x_i + \phi \Delta w_{ij}^n \quad (A.8)$$

Los patrones de entrada y salida pueden estar normalizados o escalados mediante una transformación lineal en los intervalos $[0;1]$ o $[-1;1]$; sin embargo, los datos pueden presentarse a la red sin sufrir dicha normalización. Sólo será necesario tener en cuenta que, en este caso, la función de activación de las neuronas de salida de la red debe ser la identidad.

A.4.2.2. Implementación del EBLA

El algoritmo de entrenamiento puede implementarse de dos formas: a) con el modo secuencial y b) con el modo batch o por bloques. En el primero, la función de error se calcula tras la presentación de cada patrón. Así, los errores se propagan a través de la red y se modifican los pesos antes de la presentación del siguiente patrón. Con los pesos ya actualizados, se calcula la respuesta de la red para un nuevo patrón de entrenamiento y el proceso continúa hasta que todos los patrones han sido presentados a la red. En la implementación tipo batch, el error se calcula para cada patrón, pero los pesos sólo se modifican cuando han sido presentados todos los patrones. La función de error se calcula como el promedio de los errores cuadráticos de cada patrón. A partir de ésta, los pesos se modifican antes de la siguiente iteración.

A.4.3. CRITERIOS DE PARADA.

Los posibles criterios que puedes establecerse son básicamente cuatro:

- Cuando se alcance una configuración de pesos tal que todos los patrones de entrenamiento presenten un error menor a un umbral determinado.
- Imponer la condición de error promedio, evaluado sobre la totalidad del conjunto de ejemplares de entrenamiento, inferior a un valor a establecer.
- Detener los cálculos cuando la mejora en el error quede por debajo de un valor predefinido, es decir, cuando la mejoría del entrenamiento es prácticamente insignificante.
- Establecer un número máximo de ciclos.

A.4.4. INICIALIZACIÓN DE PESOS

Para empezar a aplicar el algoritmo de aprendizaje es necesario definir el punto del espacio de pesos desde donde va a dar comienzo la búsqueda del mínimo de la función de error. Puesto que a priori no se conoce la forma de la superficie de error, lo más frecuente consiste en asignar un conjunto de pesos aleatoriamente siguiendo una distribución estadística común para iniciar el proceso (García-Bartual, 2005). Un conjunto de pesos idénticos dificultaría el arranque de las iteraciones. Esto se debe a que el error es propagado hacia atrás de forma proporcional a los pesos. De esta manera, en la primera iteración, todos los nodos ocultos conectados a la capa de salida obtendrían idénticas señales de error y lo mismo ocurriría con sus actualizaciones de pesos. Este problema de rotura de simetría se soluciona con una inicialización aleatoria. Por otra parte, no conviene que los pesos iniciales se distribuyan en intervalos grandes o adopten valores elevados, pues se produciría una saturación prematura. La solución más corriente pasa por establecer pesos iniciales distribuidos uniformemente alrededor del cero en un intervalo pequeño, favoreciendo que las funciones de activación operen inicialmente en la zona central, con pendientes importantes.

A.5. Algoritmos de entrenamiento avanzados

La determinación de pesos en una red neuronal, en el caso de entrenamiento supervisado, es un problema de optimización que admite una variedad de procedimientos y algoritmos. El problema de localización del mínimo dependerá de la dimensión del espacio de pesos y la forma y características de la superficie de error, desconocida a priori. Este desconocimiento justifica que no exista un método de entrenamiento más idóneo que otro a la hora de empezar. El EBLA suele ser lento aunque bastante estable y de avance seguro hacia el mínimo. Así, es bastante indicado para iniciar los tanteos y explorar la superficie de error con distintas inicializaciones de pesos. En una segunda fase del entrenamiento, se puede acudir a métodos más refinados de convergencia rápida (García-Bartual, 2005). Básicamente, estos métodos son la técnica del gradiente conjugado (*Conjugate Gradient Descent* CGD), el método Quasi-Newton (QN) y el algoritmo Levenberg-Marquardt (LM)

A.5.1. TÉCNICA DEL GRADIENTE CONJUGADO (CGD)

Se trata de una técnica de entrenamiento tipo batch, donde los valores de los pesos resultan de un algoritmo de búsqueda unidimensional de mínimo de la función de error, en una dirección predeterminada. La aplicación del procedimiento exige un criterio de selección de la dirección de búsqueda en cada iteración. En la iteración inicial, esta dirección se puede tomar siguiendo el criterio de máxima pendiente. Después no se toma simplemente un paso en esa dirección función de una tasa de aprendizaje, sino que se obtiene el mínimo en dicha dirección. Cada nuevo gradiente de búsqueda es ortogonal a la dirección de búsqueda anterior, de ahí el nombre del método. Las sucesivas direcciones de búsqueda se eligen de modo que garanticen que, sobre las direcciones previas, la situación no empeore. Este proceso no va a coincidir en general con el criterio de seguir en cada iteración estrictamente la pendiente máxima. Los detalles de la formulación del algoritmo puede encontrarse en Aqil Burney et al. (2004).

A.5.2. MÉTODO QUASI-NEWTON (QN)

Se trata también de un procedimiento de entrenamiento tipo batch. El algoritmo hace uso de la propiedad de que en la hipótesis de superficie de error cuadrática, conocido el Hessiano, un solo paso de cálculo permite alcanzar el mínimo. En las proximidades del

mínimo, tanto más cuanto menor sea el recinto, la función error se aproxima a una cuadrática. Por otra parte, el Hessiano es computacionalmente costoso de calcular, de modo que el método QN aproxima numéricamente su inversa, garantizando que sea una matriz definida positiva, lo que asegura siempre un movimiento en dirección descendente sobre la superficie de error. En la primera iteración, el paso de cálculo se da en la dirección de máxima pendiente. A partir de la segunda, el Hessiano se estima mediante la aproximación de Broydon-Fletcher-Goldfab-Sahnno (BFGS). En la práctica, este método es eficaz en las fases finales del entrenamiento cuando no se está demasiado alejado del mínimo.

A.5.3. ALGORITMO DE LEVENBERG-MARQUARDT (LM)

Se trata de un algoritmo de linealización, de modo que se construye sobre la hipótesis de que la función multivariada, representada globalmente por la operación de la red, es lineal (García-Bartual, 2005). El mínimo puede ser hallado en una sola iteración de cálculo. Éste se comprueba y, si el error ha disminuido, se procede a la actualización de los pesos. Si no es el caso, se adopta un incremento de compromiso entre el resultado del algoritmo y la dirección de máxima pendiente. Cuanto mejor funciona la hipótesis lineal, más se refuerza esta opción en sucesivas iteraciones; y al revés. Asimismo, existe un parámetro de control que va variando a lo largo de las iteraciones, y determina la importancia de cada uno de los dos componentes. En cada paso de cálculo donde nos aproximemos al mínimo con la hipótesis lineal, el valor del parámetro de control disminuye, de manera que en la siguiente iteración se refuerza el avance basado en la hipótesis de linealidad.

La representación de la evolución del error en el proceso de entrenamiento LM suele presentar oscilaciones. Dichas fluctuaciones son resultado natural de los pasos de cálculo con la hipótesis lineal, los cuales inmediatamente son descartados y sustituidos por pasos de cálculo menores apoyados en la componente de descenso de gradiente.

Tanto el método QN como el LM son los de convergencia más rápida en la mayoría de casos, aunque con la limitación computacional de unas necesidades de memoria proporcionales al cuadrado del número de pesos.

A.6. Manejo del sistema de datos. Capacidad de generalización de la red

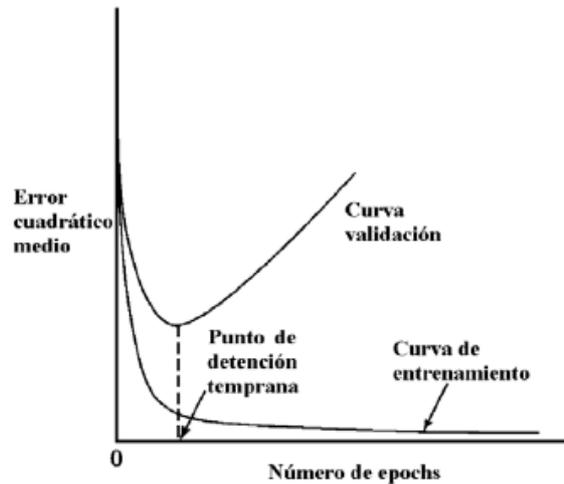
En el momento de valorar el comportamiento de una red neuronal ante una aplicación concreta, conviene verificar que la red ha aprendido los patrones utilizados en la fase de aprendizaje, pero también conocer el comportamiento de la red ante patrones que no se han utilizado en el entrenamiento. Para asegurar un correcto funcionamiento es necesario que durante el proceso de aprendizaje la red extraiga las características de las muestras para ser capaz de responder correctamente a patrones diferentes. Este aspecto se conoce como capacidad de la red para generalizar. Como consecuencia, esto exige separar un subconjunto de la muestra de datos original, reservado para la validación final. Este subconjunto recibe el nombre de subconjunto de test. El conjunto de datos restante, reservado en el proceso de entrenamiento para la aplicación del algoritmo elegido, se denomina subconjunto de entrenamiento. Hilera y Martínez (1995) sugieren que es conveniente que la separación de estos subconjuntos sea aleatoria, con el fin de obtener conjuntos lo más representativos posible.

Por otra parte, un entrenamiento exhaustivo podría anular la capacidad de generalización de la red. Por este motivo, puede ser conveniente exigir un menor aprendizaje de la red con el objetivo de obtener mejores propiedades de generalización. Para este fin se crea un tercer subconjunto de datos, el subconjunto de verificación o validación cruzada (cross-validation). Se trata de un conjunto de datos independiente de los anteriores que no se emplea en la aplicación del algoritmo de entrenamiento, sino en la evaluación de la evolución del error. En general, el error, medido respecto a un conjunto de datos independiente, desciende al principio y crece a continuación cuando la red empieza a sobreajustar (Bishop, 1997). De esta manera, puede establecerse el momento en que es conveniente terminar el entrenamiento ante el riesgo de que la red incurra en un sobreajuste del conjunto de entrenamiento. Este criterio de parada recibe el nombre de early stopping (detención adelantada o temprana) y se esquematiza en la figura A.2.

El sobreaprendizaje ocurre, por tanto, cuando la red ha aproximado correctamente los patrones de aprendizaje, pero no es capaz de responder adecuadamente ante los patrones de validación o test. Este hecho puede ser debido a un número elevado de ciclos de aprendizaje o por la utilización de un número excesivo de neuronas ocultas. En

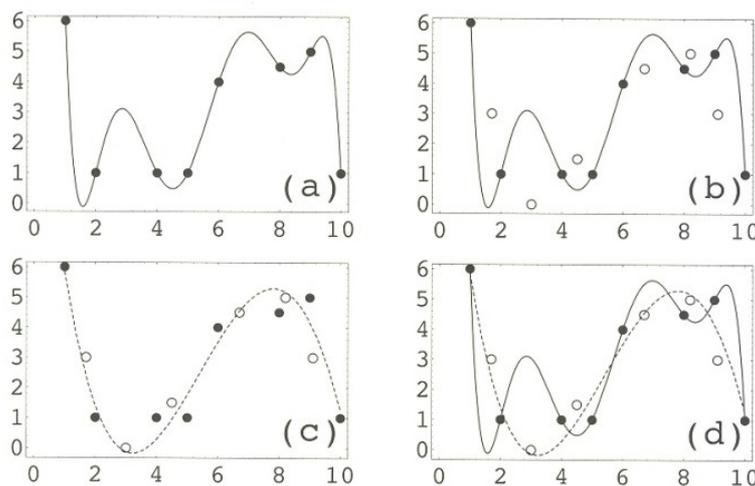
problemas en los que las muestras poseen ruido, el uso de muchas neuronas ocultas hace que la red se ajuste al ruido de los patrones.

Figura A.2. Ejemplo de entrenamiento con early stopping (Fiszelew y García, 2008)



La figura A.3 ilustra el problema del sobreajuste. En el gráfico a), se ha generado un modelo con demasiados parámetros para ajustar los datos de entrenamiento; en el b), con este modelo se ha obtenido un error grande sobre un conjunto de datos de comprobación; en el c), se genera un modelo con menos parámetros que ajusta por igual los parámetros de entrenamiento y comprobación; y en d), se comparan ambos modelos.

Figura A.3. Ejemplo de sobreajuste de puntos (Castillo et al., 1999)



Ante los casos de escasez de información, para satisfacer el requisito de que el set de entrenamiento sea significativo (Isasi-Viñuela y Galván-León, 2004), puede recurrirse a la generación sintética mediante modelos estocásticos que conserven las propiedades estadísticas de las series originales (Lachtemacher y Fuller, 1994; García-Bartual, 2002).

anejo B

predicción de pérdidas de carga localizadas en
emisores integrados con ANNs

B.1. SELECCIÓN DE LA ARQUITECTURA ÓPTIMA PARA DIFERENTES COMBINACIONES INPUT-OUTPUT. REPETICIÓN ÓPTIMA	173
B.1.1. H_L COMO OUTPUT	173
B.1.2. ALFA COMO OUTPUT	175
B.2. SELECCIÓN DE LA ARQUITECTURA ÓPTIMA PARA DIFERENTES COMBINACIONES DE VALIDACIÓN-TEST. REPETICIÓN ÓPTIMA	178
B.3. ERRORES ASOCIADOS A LOS PROCESOS ‘LEAVE ONE OUT’	185
B.3.1. RENDIMIENTOS DESGLOSADOS POR EMISOR DE TEST PARA LAS COMBINACIONES DE VERIFICACIÓN NBE, NBH, ABE, BCDE Y GBHI. REPETICIÓN ÓPTIMA	185
B.3.2. PREDICCIONES FINALES ASOCIADAS A LAS COMBINACIONES DE VERIFICACIÓN NBH, ABE, BCDE Y GBHI. REPETICIÓN Y ARQUITECTURA ÓPTIMAS	188
B.3.3. ERRORES ASOCIADOS A LAS FASES DE ENTRENAMIENTO, VALIDACIÓN-CRUZADA Y TEST DE CADA ETAPA DE LOS PROCESOS ‘LEAVE ONE OUT’. REPETICIÓN ÓPTIMA	192

B.1. Selección de la arquitectura óptima para diferentes combinaciones input-output. Repetición óptima

En gris se indica el menor error de validación cruzada.

B.1.1. H_L COMO OUTPUT

Tabla B.1. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e y D_t y el output h_l

D _e D _t	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n ^o neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	3.7517E-04	9.4712E-04	4.3526E-04	3.7232E-04	9.5098E-04	4.2104E-04
5	3.6782E-04	9.5537E-04	4.1558E-04	3.1302E-04	9.1949E-04	3.7893E-04
10	3.1926E-04	9.2761E-04	3.4039E-04	2.9697E-04	9.2834E-04	3.8418E-04
15	3.3127E-04	9.2346E-04	3.9980E-04	2.9885E-04	9.2729E-04	4.2658E-04
20	3.2244E-04	9.2925E-04	3.7695E-04	3.0782E-04	9.2325E-04	3.7653E-04
25	3.1644E-04	9.2513E-04	4.0192E-04	2.9614E-04	9.2943E-04	4.4325E-04
30	2.9311E-04	9.3001E-04	4.2852E-04	2.9079E-04	9.3534E-04	4.3223E-04
50	2.9129E-04	9.3485E-04	4.2851E-04	2.9080E-04	9.3467E-04	4.3256E-04

Tabla B.2. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e, D_t y L_e y el output h_l

D _e D _t L _e	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n ^o neuronas	Entrenamiento	verificación	test	entrenamiento	verificación	test
1	4.6996E-04	1.0187E-03	5.2306E-04	4.7230E-04	1.0408E-03	5.1658E-04
5	3.3122E-04	9.1677E-04	3.3857E-04	3.0698E-04	9.2104E-04	3.7045E-04
10	3.0523E-04	9.1391E-04	4.0402E-04	2.9228E-04	9.3245E-04	4.3764E-04
15	2.9194E-04	9.3392E-04	4.3179E-04	2.9085E-04	9.3452E-04	4.3223E-04
20	2.9101E-04	9.3365E-04	4.3279E-04	2.9079E-04	9.3529E-04	4.3178E-04
25	2.9095E-04	9.3416E-04	4.2849E-04	2.9079E-04	9.3531E-04	4.3230E-04
30	2.9102E-04	9.3342E-04	4.3320E-04	2.9082E-04	9.3431E-04	4.3249E-04
50	2.9518E-04	9.2577E-04	4.3840E-04	2.9079E-04	9.3536E-04	4.3224E-04

Tabla B.3. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e, D_t, L_e y Re_t y el output h_l

Re _t D _e D _t L _e	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n ^o neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.4447E-04	2.1463E-04	1.6555E-04	4.6661E-04	6.1150E-04	5.0824E-04
5	1.9062E-04	3.2677E-04	2.3570E-04	5.0453E-06	2.3958E-05	8.6022E-06
10	1.5125E-04	2.2463E-04	1.6695E-04	4.8349E-07	5.7523E-06	2.0009E-06
15	1.0323E-04	1.5841E-04	1.1298E-04	4.3159E-07	5.3123E-06	1.7569E-06
20	3.8021E-05	1.5841E-04	5.5522E-05	5.7993E-07	1.2759E-05	2.9319E-06
25	4.3823E-05	1.1109E-04	7.1288E-05	3.4180E-07	6.9027E-05	6.9790E-06
30	4.1403E-05	1.3163E-04	5.8458E-05	4.1677E-07	2.5433E-05	1.1089E-05
50	5.4818E-06	2.7153E-04	1.9904E-05	2.8655E-07	3.9416E-04	1.3675E-04

Tabla B.4. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y Q_t y el output h_1

$Q_t D_e D_t L_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	9.7491E-05	1.4334E-04	1.1778E-04	3.0690E-04	4.7347E-04	3.8470E-04
5	5.6687E-05	8.8399E-05	7.1270E-05	2.9719E-06	1.3300E-05	5.6581E-06
10	4.4929E-05	8.8307E-05	3.9479E-05	1.4662E-07	1.8209E-06	1.8652E-07
15	4.5529E-05	8.3014E-05	5.4949E-05	9.1407E-08	2.8450E-06	3.0770E-07
20	8.5852E-05	2.0398E-04	9.3680E-05	7.9367E-08	2.3299E-06	1.8070E-07
25	1.3129E-05	7.5414E-05	1.6658E-05	3.8910E-08	2.6183E-05	4.6318E-06
30	3.4556E-06	4.2268E-05	3.8983E-06	7.5953E-08	3.8681E-05	1.5113E-06
50	2.3737E-06	4.0577E-05	3.1399E-06	2.9954E-08	3.7117E-04	2.0453E-05

Tabla B.5. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , S_e y Q_t y el output h_1

$Q_t D_e D_t S_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	4.2780E-05	8.8137E-05	4.7220E-05	3.4993E-04	4.3471E-04	3.9000E-04
5	8.8384E-05	1.2367E-04	1.0076E-04	1.9086E-06	3.7272E-06	2.5421E-06
10	1.7575E-05	5.5666E-05	2.8518E-05	1.0856E-06	5.2057E-06	2.1436E-06
15	2.1139E-05	6.7088E-05	2.9649E-05	1.1270E-07	1.5943E-06	2.5900E-07
20	2.8227E-06	1.8170E-05	3.3306E-06	7.4640E-08	8.4365E-06	1.2815E-06
25	7.5257E-06	4.2514E-05	6.3535E-06	4.9003E-08	1.7370E-05	9.7583E-07
30	7.1526E-06	4.5354E-05	8.8821E-06	4.0648E-08	3.1075E-05	4.5173E-06
50	3.4574E-06	4.1867E-05	1.3589E-05	4.7355E-08	1.9970E-04	7.3119E-06

Tabla B.6. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y S_e y output h_1

$D_e D_t S_e L_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	3.4683E-04	9.1141E-04	3.9585E-04	4.5296E-04	1.0093E-03	5.7936E-04
5	3.1621E-04	9.0993E-04	3.9498E-04	3.3503E-04	9.1668E-04	4.1809E-04
10	2.9313E-04	9.3232E-04	4.1059E-04	2.9682E-04	9.2982E-04	4.1063E-04
15	2.9404E-04	9.3031E-04	4.3423E-04	3.0565E-04	9.2720E-04	4.5446E-04
20	2.9081E-04	9.3495E-04	4.3263E-04	2.9103E-04	9.3146E-04	4.3174E-04
25	2.9197E-04	9.2986E-04	4.3596E-04	2.9079E-04	9.3520E-04	4.3204E-04
30	2.9341E-04	9.3320E-04	4.4616E-04	3.1185E-04	9.2290E-04	4.2898E-04
50	2.9100E-04	9.3490E-04	4.2973E-04	2.9079E-04	9.3527E-04	4.3227E-04

Tabla B.7. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e , S_e y Q_t y el output h_t

$Q_t D_e D_t L_e S_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	6.3808E-05	1.3130E-04	8.2604E-05	2.1365E-04	3.4291E-04	2.3419E-04
5	2.9635E-05	4.8181E-05	3.6071E-05	8.2599E-07	5.9216E-06	3.4203E-06
10	1.1183E-04	9.9813E-05	1.0454E-04	3.9597E-07	4.5148E-06	2.4533E-06
15	2.3781E-05	5.7210E-05	2.2122E-05	4.1337E-07	1.0413E-05	3.8438E-06
20	2.1587E-05	7.0430E-05	2.4364E-05	6.8949E-07	7.5118E-06	3.0259E-06
25	4.8013E-06	2.8988E-05	5.3033E-06	4.3759E-07	1.0231E-05	2.4550E-06
30	2.7036E-05	5.9924E-05	2.9524E-05	4.4072E-07	9.0661E-05	4.9195E-06
50	8.8620E-06	5.1030E-05	9.7976E-06	4.5199E-07	7.4445E-05	8.1256E-06

Tabla B.8. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e , S_e y Re_t y el output h_t

$Re_t D_e D_t L_e S_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	3.7171E-05	7.8532E-05	4.3813E-05	5.3466E-05	1.0436E-04	5.6990E-05
5	6.2216E-06	1.3442E-05	5.5164E-06	9.2353E-07	7.6486E-06	3.6182E-06
10	2.8458E-05	7.5240E-05	2.3044E-05	1.0994E-07	1.5932E-06	2.2675E-07
15	3.1012E-06	1.1273E-05	4.2008E-06	1.3979E-07	2.2385E-06	2.7221E-07
20	2.6081E-06	7.4730E-06	2.8371E-06	3.1434E-06	7.0873E-06	3.9830E-06
25	5.0937E-06	2.6484E-05	3.6130E-06	9.1731E-08	1.0148E-05	3.9253E-07
30	2.5914E-07	2.7090E-06	5.1238E-07	5.6582E-08	1.1552E-05	1.4646E-06
50	6.9410E-07	3.0425E-05	3.0935E-06	5.2940E-06	4.2169E-04	5.6488E-05

B.1.2. α COMO OUTPUT

Tabla B.9. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e y D_t y el output α

$D_e D_t$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.4530E-02	5.3383E-02	1.2533E-02	1.1553E-02	4.5043E-02	7.5740E-03
5	1.6613E-02	4.8643E-02	1.4914E-02	4.1930E-03	3.7866E-02	2.4307E-03
10	5.2925E-03	4.1650E-02	4.7904E-03	4.0491E-03	3.7559E-02	2.9451E-03
15	4.6489E-03	3.9595E-02	4.0749E-03	4.2580E-03	3.7201E-02	3.3135E-03
20	4.2584E-03	3.7574E-02	3.0729E-03	9.6306E-03	2.9516E-02	8.4273E-03
25	4.0481E-03	3.7659E-02	2.9001E-03	7.9519E-03	3.4715E-02	5.6160E-03
30	5.2268E-03	3.4809E-02	4.2853E-03	4.2090E-03	3.7319E-02	3.2796E-03
50	5.8692E-03	3.3193E-02	4.3411E-03	4.2848E-03	3.5847E-02	2.9610E-03

Tabla B.10. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t y L_e y el output α

$D_e D_t L_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.0560E-02	4.5729E-02	6.4542E-03	7.2547E-02	1.3114E-01	7.0184E-02
5	4.8108E-03	3.8573E-02	4.4836E-03	6.1460E-03	3.4280E-02	4.5928E-03
10	1.2721E-02	3.5121E-02	1.0691E-02	1.1634E-02	3.1232E-02	1.1001E-02
15	1.7472E-02	3.0211E-02	1.6402E-02	1.1336E-02	2.8296E-02	1.0177E-02
20	4.5922E-03	3.5766E-02	3.2404E-03	1.1082E-02	3.2769E-02	1.0036E-02
25	6.1314E-03	3.5088E-02	4.7853E-03	4.0554E-03	3.7450E-02	2.8563E-03
30	1.8380E-02	3.0778E-02	1.6938E-02	6.3511E-03	3.3670E-02	4.1616E-03
50	4.2483E-03	3.5266E-02	3.1172E-03	9.8774E-03	3.2788E-02	8.5161E-03

Tabla B.11. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y Re_t y el output α

$Re_t D_e D_t L_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.1701E-02	3.8532E-02	9.9652E-03	7.6097E-02	1.2870E-01	7.5551E-02
5	4.9597E-02	9.3455E-02	5.0285E-02	3.4809E-03	1.4887E-02	3.8505E-03
10	2.9249E-02	4.3706E-02	2.9222E-02	1.6457E-05	2.1201E-03	2.7676E-04
15	2.9776E-03	1.5090E-02	2.8761E-03	1.0662E-05	1.4162E-03	9.5512E-05
20	4.3175E-03	1.9406E-02	4.1992E-03	1.1272E-05	2.7142E-03	4.7134E-05
25	1.8151E-03	9.3193E-03	1.3406E-03	1.1918E-04	1.4583E-03	2.3621E-04
30	9.8883E-04	4.7298E-03	1.0217E-03	8.6215E-06	4.3168E-03	1.8990E-04
50	9.6757E-04	1.0352E-02	1.4566E-03	2.1418E-04	4.4611E-03	1.3184E-03

Tabla B.12. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y Q_t y el output α

$Q_t D_e D_t L_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.1277E-02	3.7446E-02	9.3902E-03	1.1799E-02	3.7668E-02	9.9637E-03
5	9.4639E-03	3.7410E-02	6.4899E-03	7.7356E-03	1.1877E-02	6.0413E-03
10	2.4725E-03	1.5479E-02	2.5804E-03	1.1374E-05	1.3892E-03	1.9040E-04
15	2.7918E-04	4.4584E-03	2.9573E-04	4.9041E-06	1.5340E-03	2.8215E-04
20	9.4976E-04	1.4801E-02	8.8782E-04	1.1347E-05	7.6209E-04	7.8422E-05
25	2.9177E-04	5.8112E-03	5.1747E-04	2.4669E-05	1.3932E-03	1.4703E-04
30	1.3667E-03	7.9909E-03	1.7330E-03	9.1989E-06	1.0979E-03	1.0949E-04
50	6.8683E-04	2.2440E-02	1.6996E-03	5.6016E-06	1.9621E-03	1.5870E-03

Tabla B.13. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , S_e y Q_t y el output α

$Q_t D_e D_t S_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	6.7418E-02	1.1660E-01	6.5623E-02	1.0935E-01	1.5860E-01	1.0550E-01
5	3.7452E-03	1.9451E-02	2.4050E-03	4.3941E-02	8.9802E-02	4.9717E-02
10	2.6669E-03	1.2664E-02	3.1524E-03	1.2588E-02	2.6832E-02	1.2639E-02
15	9.0041E-03	2.1563E-02	7.3291E-03	6.8772E-06	2.2317E-03	1.7536E-04
20	4.5410E-04	9.6284E-03	5.2980E-04	5.6024E-06	1.8388E-03	8.2541E-05
25	1.3315E-03	1.3161E-02	1.4868E-03	1.4035E-05	9.4992E-04	2.2799E-04
30	2.3127E-04	6.9642E-03	4.4041E-04	5.2006E-06	2.3177E-03	6.7998E-05
50	1.9666E-03	6.7937E-03	2.9292E-03	1.1270E-03	5.4281E-03	3.5952E-03

Tabla B.14. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e y S_e y el output α

$D_e D_t S_e L_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.1244E-02	4.9632E-02	8.2450E-03	8.8274E-02	1.4214E-01	9.2915E-02
5	6.9672E-03	3.1176E-02	4.9615E-03	5.2155E-03	3.6283E-02	4.4779E-03
10	8.2415E-03	3.1074E-02	8.2487E-03	6.5579E-03	3.4266E-02	5.3009E-03
15	7.0377E-03	3.4626E-02	5.8924E-03	9.4387E-03	2.8938E-02	9.8377E-03
20	4.4432E-03	3.4556E-02	3.4302E-03	1.2233E-02	3.0900E-02	1.2032E-02
25	4.0543E-03	3.7549E-02	2.9045E-03	5.6217E-03	3.3845E-02	4.0089E-03
30	1.0419E-02	3.1115E-02	7.8835E-03	4.0597E-03	3.6934E-02	2.9559E-03
50	3.1784E-02	3.2972E-02	3.0146E-02	4.0767E-03	3.7000E-02	2.9239E-03

Tabla B.15. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e , S_e y Q_t y el output α

$Q_t D_e D_t L_e S_e$	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	4.5259E-02	9.0191E-02	4.3495E-02	4.7006E-02	9.5592E-02	4.5070E-02
5	1.4917E-03	1.3215E-02	7.3847E-04	7.2063E-02	1.4450E-01	7.4278E-02
10	5.7382E-04	7.9671E-03	5.3564E-04	1.7712E-05	1.5204E-03	5.0746E-05
15	3.1464E-04	4.2867E-03	9.7551E-04	7.4979E-06	1.0620E-03	4.3864E-05
20	8.5252E-04	1.0291E-02	1.1292E-03	7.4334E-06	9.3634E-04	1.2500E-04
25	7.4078E-04	4.6465E-03	6.0012E-04	1.1867E-04	1.4161E-03	3.7529E-04
30	5.8352E-05	1.8311E-03	3.9295E-04	1.4989E-05	1.1471E-03	5.6417E-05
50	1.5967E-03	1.3402E-02	2.2683E-03	2.3421E-04	2.6573E-03	2.7438E-04

Tabla B.16. Errores de entrenamiento y test para selección de la arquitectura óptima de una red con los inputs D_e , D_t , L_e , S_e y Re_t y el output α

Re_t , D_e , D_t , L_e , S_e	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
	n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación
1	6.7048E-03	2.6691E-02	5.2373E-03	8.2903E-03	2.5882E-02	6.5127E-03
5	2.5302E-03	1.9307E-02	1.4974E-03	2.6850E-04	2.3443E-03	4.0645E-04
10	8.6550E-04	7.7612E-03	5.7780E-04	1.1910E-05	1.4258E-03	1.0712E-04
15	1.2374E-03	1.3657E-02	1.0883E-03	1.5133E-05	1.1599E-03	1.4362E-04
20	8.2416E-04	5.7024E-03	7.4513E-04	1.0268E-05	8.9309E-04	1.3050E-04
25	9.6587E-04	8.3467E-03	1.1531E-03	1.2386E-05	1.1800E-03	1.1088E-04
30	4.1061E-04	4.3016E-03	7.1821E-04	6.5200E-05	1.6376E-03	1.6808E-04
50	3.2194E-04	2.6750E-03	7.8438E-04	6.8904E-06	1.3989E-03	1.0592E-04

B.2. Selección de la arquitectura óptima para diferentes combinaciones de validación-test. Repetición óptima

En gris se indica el menor error de verificación.

Tabla B.17. Errores de entrenamiento y test de una red con el entrenamiento 2

entrenamiento 2	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
	n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación
1	2.675E-05	6.170E-05	4.164E-04	2.249E-05	6.432E-05	5.680E-04
5	1.214E-05	4.046E-05	1.789E-04	1.499E-06	4.651E-06	8.058E-04
10	3.065E-05	8.205E-05	8.927E-04	1.014E-07	8.198E-07	2.820E-02
15	8.142E-06	3.339E-05	4.640E-03	8.968E-08	1.729E-06	1.074E-02
20	1.296E-06	9.135E-06	1.286E-02	8.603E-08	1.577E-06	5.249E-02
25	1.898E-06	9.355E-06	5.085E-03	1.828E-07	2.248E-06	2.554E-01
30	2.458E-06	1.188E-05	2.612E-02	7.008E-08	8.684E-06	3.598E-02
50	2.251E-06	4.569E-05	7.135E-03	1.260E-06	5.690E-05	4.540E-01

Tabla B.18. Errores de entrenamiento y test de una red con el entrenamiento 3

entrenamiento 3	MSE (m^2)					
	1 capa oculta			2 capas ocultas		
	n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación
1	3.265E-05	9.433E-05	1.231E-04	1.104E-04	3.027E-04	1.159E-03
5	2.416E-05	6.710E-05	8.138E-05	9.280E-06	1.069E-04	8.617E-04
10	1.355E-04	5.784E-05	2.976E-05	3.528E-06	4.575E-05	9.141E-05
15	5.503E-06	3.284E-05	1.839E-02	5.747E-04	2.414E-04	1.412E-02
20	3.906E-05	5.368E-05	1.556E-02	6.693E-03	2.035E-03	3.742E-03
25	1.802E-03	5.056E-04	1.975E-03	6.108E-03	8.476E-03	6.972E-02
30	4.041E-05	4.066E-05	2.491E-04	8.721E-03	2.322E-02	9.282E-02
50	7.129E-04	3.472E-04	3.911E-02	2.343E-01	2.425E-01	5.364E+00

Tabla B.19. Errores de entrenamiento y test de una red con el entrenamiento 4

entrenamiento 4	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n ^o neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	9.543E-05	2.762E-05	2.247E-03	1.718E-04	2.080E-05	6.674E-04
5	8.288E-05	1.129E-05	2.757E-03	3.469E-04	2.109E-05	3.683E-04
10	1.743E-04	8.749E-05	3.871E-04	2.563E-05	4.783E-05	4.802E-02
15	1.394E-02	1.316E-04	2.734E-02	2.086E-03	2.973E-03	6.300E-03
20	2.624E-04	8.611E-05	1.695E-04	3.613E-03	1.142E-02	5.794E-03
25	2.551E-05	3.694E-05	6.111E-06	1.542E-01	5.303E-03	1.141E-01
30	1.592E-04	8.545E-04	4.281E-04	5.833E-02	1.334E-01	2.095E+00
50	8.265E-02	6.079E-03	4.275E-01	2.804E-01	1.778E-01	1.395E+00

Tabla B.20. Errores de entrenamiento y test de una red con el entrenamiento 5

entrenamiento 5	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n ^o neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	2.018E-04	3.097E-05	2.277E-04	6.408E-04	1.014E-04	2.374E-04
5	2.626E-04	2.257E-05	1.739E-04	4.181E-04	6.874E-05	2.306E-04
10	3.699E-04	1.274E-04	8.339E-05	3.801E-04	8.786E-05	2.141E-04
15	4.546E-04	1.808E-05	4.321E-04	6.308E-04	5.069E-04	4.235E-03
20	1.095E-05	1.821E-05	1.184E-03	2.543E-04	5.232E-03	7.611E-02
25	6.353E-05	9.016E-04	1.053E-02	6.288E-04	7.627E-03	8.559E-02
30	2.716E-04	2.465E-04	1.046E-03	8.136E-08	2.511E-02	1.538E+00
50	3.026E-02	9.584E-04	3.765E-01	1.010E-02	8.925E-02	6.327E-01

Tabla B.21. Errores de entrenamiento y test de una red con el entrenamiento 6

entrenamiento 6	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n ^o neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	2.669E-05	5.594E-05	9.291E-05	1.786E-04	3.189E-04	1.924E-04
5	4.912E-05	7.792E-05	2.296E-04	2.894E-05	7.298E-05	2.416E-04
10	9.399E-05	2.819E-04	5.182E-02	3.584E-04	1.120E-04	9.673E-04
15	9.821E-05	1.316E-04	1.523E-04	1.232E-07	1.035E-02	1.698E-03
20	4.579E-05	3.685E-04	1.959E-02	1.100E-03	2.427E-03	1.461E-02
25	7.699E-05	2.518E-04	2.146E-02	1.600E-03	5.244E-03	4.110E-02
30	2.700E-04	3.123E-03	1.446E-02	5.425E-03	7.722E-02	4.517E-01
50	2.259E-03	4.411E-04	4.332E-01	3.868E-02	1.841E-02	8.635E-01

Tabla B.22. Errores de entrenamiento y test de una red con el entrenamiento 7

entrenamiento 7	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	3.183E-05	1.092E-04	1.639E-05	1.774E-04	2.077E-04	1.932E-04
5	9.919E-06	3.682E-05	3.320E-05	8.572E-06	1.224E-05	8.774E-06
10	9.858E-05	2.912E-04	1.740E-04	1.658E-05	2.751E-04	4.489E-03
15	4.007E-05	1.311E-04	1.661E-04	5.465E-04	3.094E-03	1.961E-03
20	4.622E-05	8.490E-05	1.507E-04	1.841E-06	7.890E-03	2.847E-03
25	5.859E-05	1.061E-04	6.667E-03	8.998E-04	5.525E-03	4.972E-01
30	4.169E-04	1.113E-04	1.571E-03	5.743E-04	9.562E-03	1.983E-01
50	3.485E-03	3.712E-03	2.456E-02	4.208E-03	9.969E-02	2.679E-01

Tabla B.23. Errores de entrenamiento y test de una red con el entrenamiento 8

entrenamiento 8	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	3.205E-05	1.039E-04	3.040E-05	1.712E-04	2.762E-04	3.353E-04
5	6.695E-05	1.250E-04	2.376E-04	2.479E-04	6.771E-05	2.200E-04
10	1.551E-05	8.251E-05	1.290E-04	7.678E-05	1.292E-04	5.272E-04
15	3.047E-05	6.208E-05	1.042E-04	9.796E-05	5.528E-04	3.425E-03
20	1.589E-07	1.812E-03	1.370E-04	4.597E-04	2.837E-03	2.231E-03
25	4.543E-05	4.646E-05	4.992E-05	1.795E-03	5.135E-02	5.296E-02
30	4.464E-05	1.481E-04	2.063E-04	4.735E-02	5.567E-02	4.619E-01
50	5.215E-05	2.291E-04	1.887E-04	2.672E-02	1.343E-02	7.503E-01

Tabla B.24. Errores de entrenamiento y test de una red con el entrenamiento 9

entrenamiento 9	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	4.147E-05	1.159E-04	1.199E-05	2.356E-04	4.726E-04	3.998E-04
5	6.625E-05	1.040E-04	5.259E-04	1.550E-07	2.617E-05	7.440E-05
10	3.018E-04	1.523E-04	1.903E-04	1.130E-03	2.172E-04	6.976E-04
15	1.880E-04	1.195E-04	5.993E-05	7.346E-04	5.535E-04	2.181E-03
20	1.192E-06	3.040E-03	8.888E-04	1.536E-05	3.333E-02	7.620E-02
25	1.382E-03	6.728E-04	9.621E-04	9.664E-08	9.654E-03	1.489E-02
30	3.846E-04	1.396E-04	6.479E-05	6.140E-08	1.749E-02	1.752E-01
50	1.063E-03	2.375E-02	8.926E-02	4.719E-01	1.135E-01	1.194E+00

Tabla B.25. Errores de entrenamiento y test de una red con el entrenamiento 10

entrenamiento 10	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	6.728E-05	1.451E-04	9.321E-05	2.303E-04	4.083E-04	3.091E-04
5	1.447E-05	1.260E-04	1.762E-04	1.034E-06	3.559E-05	5.142E-04
10	1.547E-04	1.044E-04	1.402E-04	1.004E-07	2.318E-04	9.368E-04
15	4.026E-05	1.575E-04	8.401E-05	5.714E-07	3.877E-04	9.056E-03
20	1.121E-05	9.112E-05	1.348E-04	1.473E-04	8.912E-03	3.759E-03
25	1.369E-06	3.159E-04	1.075E-03	7.127E-08	6.916E-03	5.316E-02
30	9.068E-05	1.579E-04	4.085E-04	5.966E-08	6.829E-02	4.624E-01
50	8.958E-07	1.546E-04	2.226E-04	4.971E-08	6.989E-02	2.737E-01

Tabla B.26. Errores de entrenamiento y test de una red con el entrenamiento 11

entrenamiento 11	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	3.896E-05	1.246E-04	1.959E-04	2.088E-04	1.941E-04	6.794E-05
5	1.016E-04	2.104E-04	7.150E-04	5.863E-05	3.286E-05	6.892E-05
10	4.559E-05	1.480E-04	1.417E-04	3.751E-04	8.814E-05	6.736E-02
15	5.334E-04	4.846E-04	3.371E-03	2.729E-07	6.137E-03	1.270E-02
20	5.447E-04	6.229E-04	5.333E-02	1.297E-03	1.197E-02	4.074E-02
25	6.793E-05	3.302E-04	1.944E-04	1.086E-03	1.271E-02	2.271E-01
30	6.386E-05	2.395E-04	3.104E-04	8.142E-03	4.141E-02	3.263E-01
50	1.038E-04	1.126E-03	1.318E-02	5.594E-02	7.001E-02	6.090E-01

Tabla B.27. Errores de entrenamiento y test de una red con el entrenamiento 12

entrenamiento 12	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	3.327E-04	5.945E-05	4.350E-04	4.823E-04	6.946E-05	3.631E-04
5	7.275E-04	9.668E-05	1.630E-04	2.882E-05	4.327E-05	1.406E-03
10	1.241E-04	1.981E-04	1.089E-03	1.959E-05	1.103E-03	1.045E-03
15	2.337E-04	2.411E-04	1.640E-03	1.339E-02	1.232E-02	9.515E-02
20	1.343E-03	7.463E-04	5.532E-03	5.712E-04	7.194E-03	4.015E-01
25	2.030E-03	1.186E-02	5.505E-03	1.534E-04	5.488E-02	9.979E-02
30	1.852E-04	2.183E-04	1.130E-03	1.787E-03	8.757E-02	3.366E-01
50	5.283E-04	1.296E-02	5.786E-02	5.273E-05	2.612E-01	8.688E-01

Tabla B.28. Errores de entrenamiento y test de una red con el entrenamiento 13

entrenamiento 13	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	4.937E-05	1.020E-04	1.798E-04	1.054E-04	1.179E-04	2.859E-04
5	1.575E-04	1.126E-04	1.824E-04	7.695E-06	1.149E-04	1.226E-04
10	4.958E-05	3.151E-05	4.965E-04	1.916E-03	1.038E-04	1.909E-03
15	1.737E-04	1.207E-04	4.164E-03	1.299E-03	5.009E-03	1.293E-02
20	5.232E-06	1.651E-04	1.779E-03	7.728E-08	1.379E-02	8.673E-03
25	4.244E-05	2.532E-03	8.296E-03	3.967E-03	9.681E-02	2.789E-01
30	1.538E-05	3.753E-04	1.085E-03	1.777E-03	6.816E-02	5.299E-01
50	9.947E-03	1.004E-02	1.611E-01	3.991E-02	3.445E-01	4.810E-01

Tabla B.29. Errores de entrenamiento y test de una red con el entrenamiento 14

entrenamiento 14	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	2.600E-05	1.370E-05	1.213E-04	1.256E-04	2.895E-04	5.921E-04
5	5.057E-05	8.581E-05	2.999E-04	1.551E-05	8.470E-05	4.678E-04
10	2.494E-05	1.202E-04	5.135E-04	3.892E-05	4.131E-04	1.108E-03
15	2.618E-05	2.115E-04	2.823E-04	3.097E-05	1.839E-04	1.542E-03
20	1.083E-05	1.902E-04	3.987E-04	1.308E-03	1.141E-02	1.171E-01
25	1.173E-05	2.837E-04	2.864E-04	3.816E-03	1.902E-02	1.391E-01
30	1.708E-06	8.052E-04	7.451E-03	8.157E-03	5.726E-02	4.909E-01
50	1.026E-05	7.895E-03	4.539E-03	9.131E-03	6.402E-02	8.459E-02

Tabla B.30. Errores de entrenamiento y test de una red con el entrenamiento 15

entrenamiento 15	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.476E-05	1.683E-04	1.326E-04	1.949E-04	5.712E-04	6.233E-04
5	5.634E-05	1.595E-04	1.938E-04	7.878E-06	2.005E-04	6.202E-05
10	1.781E-04	2.655E-04	3.644E-04	4.551E-05	1.745E-04	2.143E-04
15	3.969E-06	8.197E-05	2.009E-04	8.210E-08	1.195E-04	3.854E-04
20	6.138E-05	5.138E-05	3.315E-04	2.545E-04	4.629E-03	2.763E-02
25	1.962E-04	2.302E-04	7.885E-05	5.551E-08	1.987E-02	9.158E-03
30	1.565E-06	3.514E-04	2.319E-04	3.378E-02	1.538E-02	4.738E-01
50	3.717E-05	4.986E-03	9.613E-04	1.394E-01	8.975E-02	1.930E-01

Tabla B.31. Errores de entrenamiento y test de una red con el entrenamiento 16

entrenamiento 16	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	8.726E-05	2.262E-04	3.183E-05	3.646E-04	5.404E-04	3.528E-04
5	1.820E-04	2.022E-04	3.640E-04	5.900E-03	1.759E-04	1.039E-02
10	2.163E-05	1.519E-04	1.089E-04	1.516E-04	5.534E-04	4.200E-04
15	1.035E-05	2.787E-04	2.900E-03	1.359E-04	1.907E-04	2.973E-03
20	1.354E-04	4.638E-04	3.175E-04	3.476E-04	3.166E-03	4.882E-02
25	3.904E-05	1.722E-04	1.135E-04	5.543E-03	3.940E-02	1.500E-01
30	1.224E-05	8.004E-04	3.129E-04	2.511E-04	2.488E-02	2.241E-01
50	6.166E-06	9.720E-04	4.654E-03	2.829E-01	4.166E-02	1.143E+00

Tabla B.32. Errores de entrenamiento y test para de una red con el entrenamiento 17

entrenamiento 17	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	2.733E-05	1.994E-04	2.280E-05	1.066E-04	4.598E-04	3.762E-04
5	2.529E-05	1.009E-04	3.687E-04	1.785E-04	4.061E-04	2.392E-04
10	9.608E-06	1.903E-04	3.142E-04	1.202E-05	2.007E-04	7.810E-05
15	4.099E-05	9.905E-05	2.803E-04	2.130E-04	4.805E-04	4.617E-03
20	2.061E-05	1.094E-04	4.543E-04	1.550E-03	4.190E-03	3.128E-02
25	1.542E-05	1.883E-04	9.656E-04	5.016E-04	2.675E-02	5.609E-02
30	4.328E-03	2.120E-03	2.423E-03	1.282E-01	5.366E-03	5.675E-03
50	4.472E-04	8.190E-03	7.372E-04	1.988E-04	2.974E-02	1.348E-01

Tabla B.33. Errores de entrenamiento y test de una red con el entrenamiento 18

entrenamiento 18	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.764E-05	2.954E-04	2.161E-05	2.719E-04	6.729E-04	7.951E-04
5	2.090E-05	1.380E-04	1.311E-04	9.501E-05	4.066E-04	2.182E-04
10	5.986E-05	1.872E-04	1.055E-03	2.369E-07	3.036E-04	1.560E-03
15	1.724E-05	2.814E-04	1.087E-04	3.843E-04	1.022E-03	2.985E-03
20	1.756E-04	5.225E-04	1.076E-03	1.753E-07	3.497E-03	6.850E-02
25	7.869E-07	1.262E-04	1.852E-04	7.363E-05	1.320E-02	7.623E-02
30	3.652E-05	3.019E-04	1.517E-04	3.495E-03	9.364E-03	1.421E-01
50	1.205E-05	3.426E-04	9.377E-05	4.437E-04	4.031E-02	2.340E-01

Tabla B.34. Errores de entrenamiento y test de una red con el entrenamiento 19

entrenamiento 19	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	9.997E-06	7.674E-05	1.070E-04	1.283E-04	4.399E-04	2.763E-04
5	5.633E-05	1.324E-04	7.815E-04	4.100E-04	9.364E-05	5.725E-05
10	1.650E-04	1.438E-04	2.307E-04	1.074E-04	8.566E-04	1.084E-04
15	4.905E-05	1.092E-04	2.681E-04	1.121E-03	3.058E-03	2.120E-03
20	2.975E-04	2.235E-04	1.731E-02	1.135E-06	1.225E-02	8.668E-02
25	1.323E-05	1.106E-04	2.065E-05	2.800E-03	8.502E-02	2.959E-01
30	5.247E-05	2.158E-04	2.846E-04	9.911E-04	5.651E-02	9.468E-02
50	1.132E-04	4.939E-04	1.267E-03	5.188E-03	1.087E-01	5.770E-01

Tabla B.35. Errores de entrenamiento y test para de una red con el entrenamiento 20

entrenamiento 20	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	5.820E-04	8.494E-04	6.335E-04	1.075E-03	1.047E-03	8.762E-04
5	2.331E-03	5.218E-04	2.669E-03	1.121E-03	7.611E-04	1.891E-03
10	7.673E-04	3.149E-04	7.186E-04	5.129E-04	5.128E-04	6.758E-03
15	1.675E-03	8.151E-04	4.352E-04	4.193E-04	5.187E-03	3.177E-03
20	4.826E-04	7.083E-04	1.280E-03	4.555E-04	1.346E-02	2.269E-03
25	4.227E-04	1.650E-03	1.048E-03	6.525E-04	2.776E-03	1.128E-03
30	1.306E-03	1.036E-03	1.247E-03	1.084E-03	1.543E-02	2.028E-02
50	4.480E-04	4.723E-03	5.047E-03	2.168E-04	4.492E-02	9.128E-02

Tabla B.36. Errores de entrenamiento y test de una red con el entrenamiento 21

entrenamiento 21	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	9.496E-06	2.422E-04	6.713E-05	7.541E-05	6.569E-04	5.990E-04
5	7.718E-06	3.990E-05	3.988E-05	1.294E-05	1.929E-04	1.010E-04
10	1.018E-03	3.295E-04	2.045E-03	1.922E-06	7.862E-04	3.983E-04
15	3.158E-05	8.378E-04	3.668E-04	8.995E-06	2.031E-03	1.033E-03
20	3.251E-04	4.527E-04	1.655E-04	8.316E-03	2.114E-02	8.850E-03
25	9.706E-05	2.570E-04	2.199E-04	3.584E-03	1.790E-02	5.755E-02
30	1.839E-04	1.389E-03	5.202E-04	6.832E-03	7.462E-02	3.399E-01
50	2.403E-02	2.463E-02	1.041E-02	2.426E-01	9.335E-02	4.988E-01

Tabla B.37. Errores de entrenamiento y test de una red con el entrenamiento 22

entrenamiento 22	MSE (m ²)					
	1 capa oculta			2 capas ocultas		
n° neuronas	entrenamiento	verificación	test	entrenamiento	verificación	test
1	1.401E-04	3.313E-04	2.772E-04	1.447E-04	3.614E-04	2.822E-04
5	5.329E-05	2.564E-04	4.696E-04	1.165E-07	3.487E-04	1.248E-03
10	2.142E-05	4.239E-04	1.629E-04	1.589E-06	1.528E-04	2.439E-04
15	2.728E-05	1.042E-04	3.251E-04	3.316E-04	5.537E-03	1.285E-03
20	2.092E-06	2.770E-03	3.812E-03	3.224E-02	2.358E-02	1.625E-02
25	2.128E-06	2.171E-03	5.269E-03	5.170E-04	1.957E-02	6.995E-02
30	3.340E-05	4.311E-04	2.073E-04	1.473E-04	4.798E-02	2.069E-01
50	1.209E-03	4.369E-03	5.188E-02	9.464E-02	1.428E-01	6.341E-01

B.3. Errores asociados a los procesos ‘leave one out’

B.3.1. RENDIMIENTOS DESGLOSADOS POR EMISOR DE TEST PARA LAS COMBINACIONES DE VERIFICACIÓN NBE, NBH, ABE, BCDE Y GBHI. REPETICIÓN ÓPTIMA

Tabla B.38. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación NBH

set de entrenamiento completo						
emisor de test	A	C	D	E	F	G
arquitectura	4-4-1	4-10-1	4-2-1	4-7-1	4-13-1	4-11-1
c (-)	0.484	0.994	0.945	0.941	0.510	0.507
MSE (m ²)	3.390E-05	5.256E-06	1.589E-04	2.058E-04	2.032E-04	1.517E-04
emisor de test	I	L	M	O	P	Q
arquitectura	4-1-1	4-5-1	4-15-1	4-9-1	4-5-1	4-12-1
c (-)	0.975	0.718	0.970	0.943	0.999	0.249
MSE (m ²)	5.005E-05	1.955E-04	1.732E-05	1.937E-05	1.488E-06	3.969E-03
sin Q						
emisor de test	A	C	D	E	F	G
arquitectura	4-7-1	4-3-1	4-5-1	4-4-1	4-2-1	4-3-1
c (-)	0.788	0.976	0.994	0.850	0.792	0.952
MSE (m ²)	1.034E-05	1.696E-05	2.834E-05	4.840E-04	1.345E-04	5.557E-06
emisor de test	I	L	M	O	P	Q
arquitectura	4-13-1	4-3-1	4-5-1	4-5-1	4-2-1	-
c (-)	0.992	0.981	0.880	0.988	0.998	-
MSE (m ²)	2.086E-05	8.677E-06	6.318E-05	3.570E-06	3.886E-06	-

Tabla B.39. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación ABE

set de entrenamiento completo						
emisor de test	C	D	F	G	H	I
arquitectura	4-2-1	4-2-1	4-11-1	4-3-1	4-5-1	4-13-1
c (-)	0.971	0.985	0.914	0.940	0.762	0.971
MSE (m ²)	2.076E-05	5.068E-05	3.246E-05	3.807E-06	5.792E-04	1.085E-04
emisor de test	L	M	N	O	P	Q
arquitectura	4-4-1	4-3-1	4-8-1	4-5-1	4-3-1	4-6-1
c (-)	0.865	0.976	0.520	0.962	0.990	0.470
MSE (m ²)	2.676E-04	8.307E-06	1.923E-04	1.594E-05	2.082E-05	4.846E-04
sin Q						
emisor de test	C	D	F	G	H	I
arquitectura	4-2-1	4-2-1	4-6-1	4-3-1	4-4-1	4-4-1
c (-)	0.978	0.986	0.685	0.916	0.853	0.968
MSE (m ²)	9.766E-06	5.490E-05	3.597E-04	7.244E-06	2.669E-04	1.455E-04
emisor de test	L	M	N	O	P	Q
arquitectura	4-11-1	4-5-1	4-3-1	4-4-1	4-2-1	-
c (-)	0.870	0.982	0.983	0.997	0.996	-
MSE (m ²)	1.650E-04	7.704E-06	6.025E-06	7.071E-07	7.182E-06	-

Tabla B.40. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación NBE

set de entrenamiento completo						
emisor de test	A	C	D	F	G	H
arquitectura	4-7-1	4-12-1	4-6-1	4-5-1	4-14-1	4-5-1
c (-)	0.232	0.940	0.966	0.831	0.507	0.918
MSE (m ²)	5.069E-04	4.242E-05	9.822E-05	1.328E-04	6.094E-05	2.589E-04
emisor de test	I	L	M	O	P	Q
arquitectura	4-2-1	4-9-1	4-12-1	4-2-1	4-3-1	4-2-1
c (-)	0.983	0.540	0.967	0.980	0.988	0.275
MSE (m ²)	4.806E-05	2.291E-03	1.990E-05	7.906E-06	2.888E-05	3.168E-03
sin Q						
emisor de test	A	C	D	F	G	H
arquitectura	4-4-1	4-5-1	4-3-1	4-4-1	4-4-1	4-3-1
c (-)	0.898	0.992	0.985	0.810	0.827	0.958
MSE (m ²)	2.111E-06	5.666E-06	5.622E-05	1.214E-04	1.344E-05	8.288E-05
emisor de test	I	L	M	O	P	Q
arquitectura	4-7--1	4-4-1	4-7-1	4-2-1	4-4-1	-
c (-)	0.992	0.813	0.976	0.986	0.996	-
MSE (m ²)	2.699E-05	3.902E-04	1.078E-05	4.045E-06	7.134E-06	-

Tabla B.41. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación BCDE

set de entrenamiento completo						
emisor de test	A	F	G	H	I	L
arquitectura	4-2-1	4-3-1	4-5-1	4-2-1	4-3-1	4-8-1
c (-)	0.947	0.805	0.213	0.993	0.998	0.850
MSE (m ²)	1.582E-06	1.306E-04	3.830E-04	7.713E-06	5.299E-06	3.856E-04
emisor de test	M	N	O	P	Q	
arquitectura	4-3-1	4-15-1	4-13-1	4-4-1	4-3-1	
c (-)	0.998	0.868	0.612	0.998	0.948	
MSE (m ²)	9.010E-07	5.958E-05	1.438E-04	5.596E-06	1.698E-05	
sin G						
emisor de test	A	F	G	H	I	L
arquitectura	4-5-1	4-12-1	-	4-6-1	4-12-1	4-5-1
c (-)	0.882	0.314	-	0.959	0.979	0.793
MSE (m ²)	6.916E-06	2.301E-03	-	6.930E-05	6.486E-05	5.073E-04
emisor de test	M	N	O	P	Q	
arquitectura	4-7-1	4-3-1	4-5-1	4-5-1	4-3-1	
c (-)	0.991	0.981	0.666	0.990	0.162	
MSE (m ²)	5.524E-06	6.602E-06	2.528E-04	2.280E-05	9.794E-03	
sin G,Q						
emisor de test	A	F	G	H	I	L
arquitectura	4-4-1	4-5-1	-	4-10-1	4-5-1	4-13-1
c (-)	0.965	0.647	-	0.999	0.983	0.890
MSE (m ²)	9.763E-07	3.545E-04	-	1.371E-06	5.361E-05	2.419E-04
emisor de test	M	N	O	P	Q	
arquitectura	4-7-1	4-7-1	4-5-1	4-9-1	-	
c (-)	0.975	0.871	0.954	0.991	-	
MSE (m ²)	5.867E-06	3.587E-05	1.449E-05	2.160E-05	-	

Tabla B.42. Desglose por emisor de test de los rendimientos de las ANN óptimas logrados con el conjunto de verificación GBHI

set de entrenamiento completo						
emisor de test	A	C	D	E	F	L
arquitectura	4-1-1	4-2-1	4-8-1	4-1-1	4-1-1	4-1-1
c (-)	0.866	0.979	0.993	0.953	0.991	0.797
MSE (m ²)	2.588E-06	1.758E-05	2.779E-05	1.649E-04	2.460E-06	4.149E-04
emisor de test	M	N	O	P	Q	
arquitectura	4-7-1	4-1-1	4-1-1	4-2-1	4-2-1	
c (-)	0.937	0.622	0.934	0.984	0.302	
MSE (m ²)	2.076E-05	1.911E-04	2.428E-05	3.256E-05	2.603E-03	
sin Q						
emisor de test	A	C	D	E	F	L
arquitectura	4-3-1	4-8-1	4-5-1	4-2-1	4-4-1	4-6-1
c (-)	0.715	0.963	0.979	0.962	0.968	0.923
MSE (m ²)	1.533E-05	2.820E-05	7.487E-05	1.378E-04	6.221E-06	1.457E-04
emisor de test	M	N	O	P	Q	
arquitectura	4-4-1	4-3-1	4-4-1	4-2-1	-	
c (-)	0.975	0.728	0.972	0.992	-	
MSE (m ²)	1.110E-05	7.179E-05	9.936E-06	1.937E-05	-	

B.3.2. PREDICIONES FINALES ASOCIADAS A LAS COMBINACIONES DE VERIFICACIÓN NBH, ABE, BCDE Y GBHI. REPETICIÓN Y ARQUITECTURA ÓPTIMAS

Figura B.1. Predicción de h_l en emisores con rangos de α altos, obtenidos con trío de verificación NBH

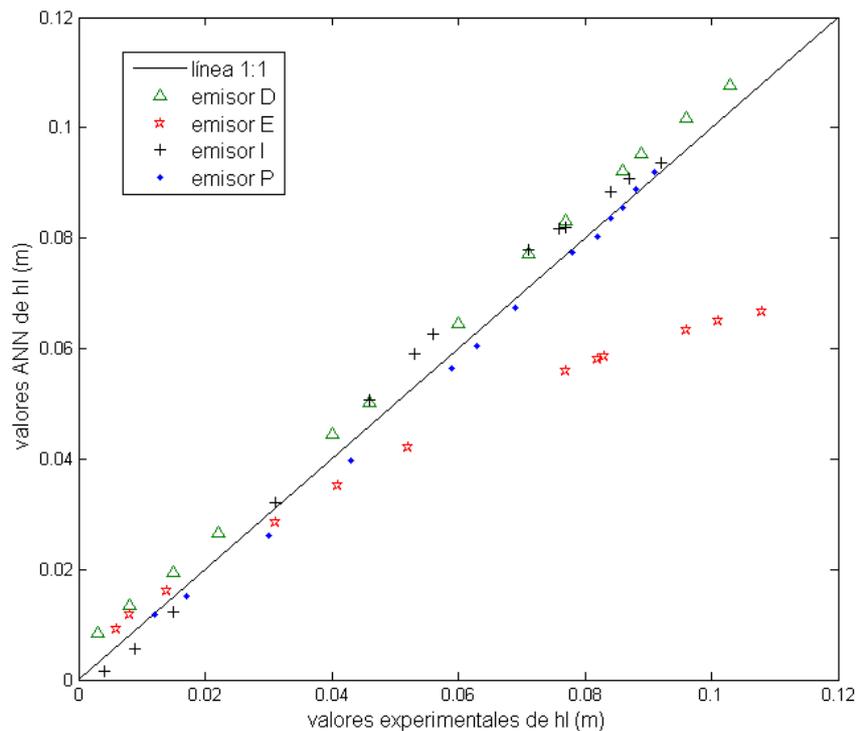


Figura B.2. Predicción de h_i en emisores con rangos de α bajos, obtenidos con trío de verificación NBH

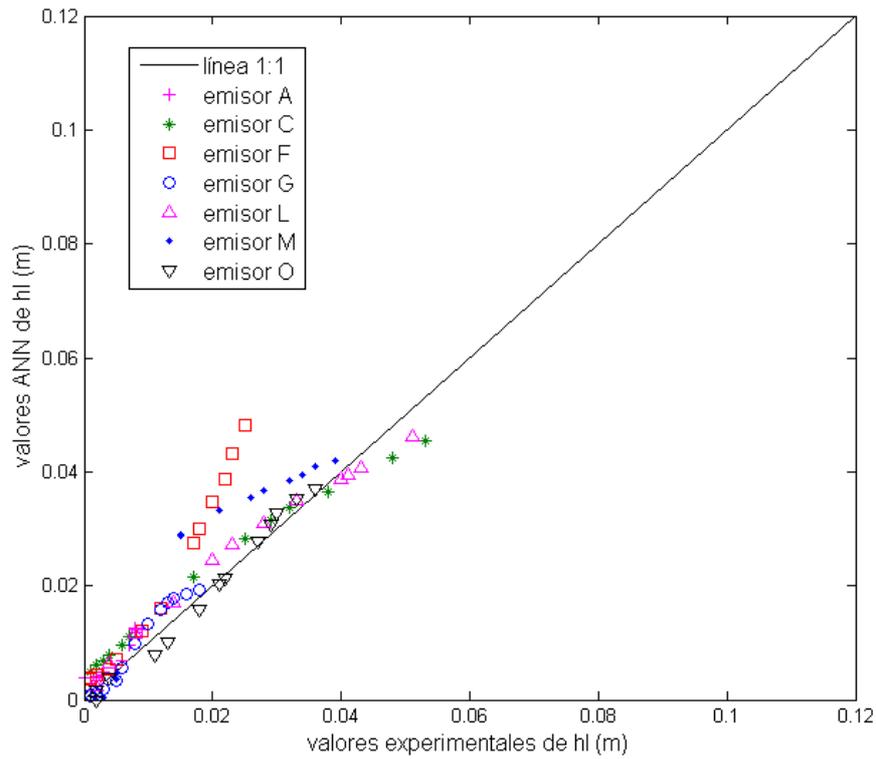


Figura B.3. Predicción de h_i en emisores con rangos de α altos, obtenidos con trío de verificación ABE

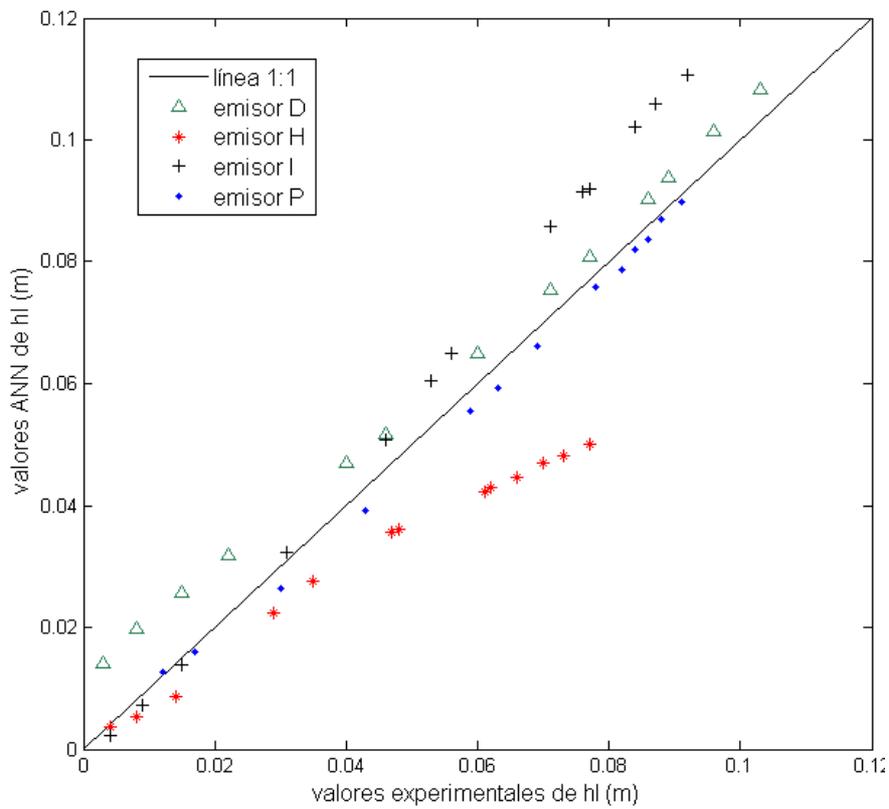


Figura B.4. Predicción de h_l en emisores con rangos de α bajos, obtenidos con trío de verificación ABE

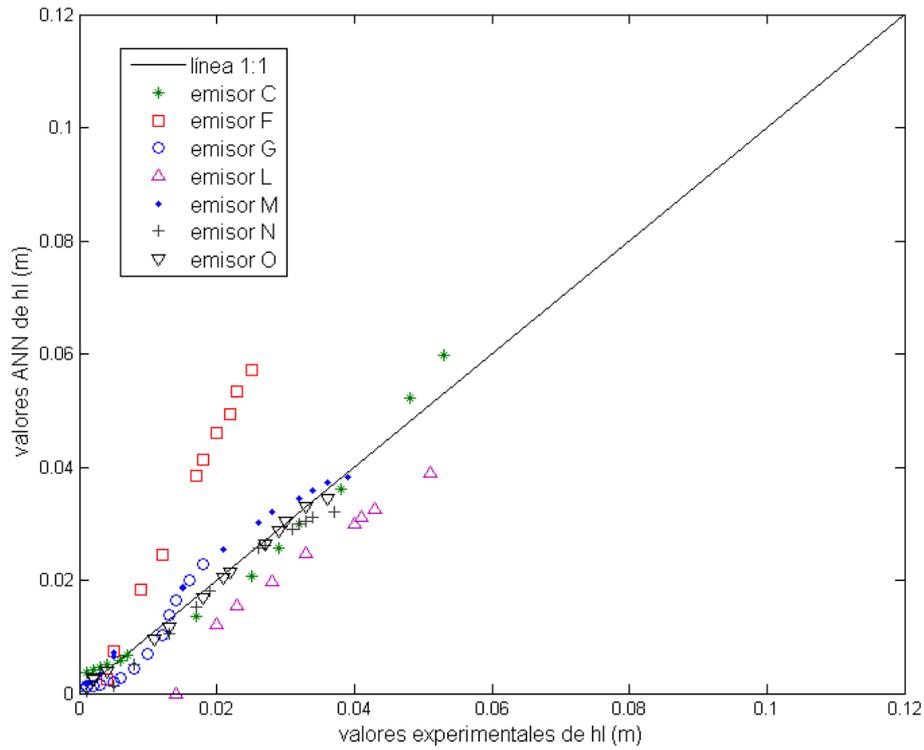


Figura B.5. Predicción de h_l en emisores con rangos de α altos, obtenidos con trío de verificación BCDE

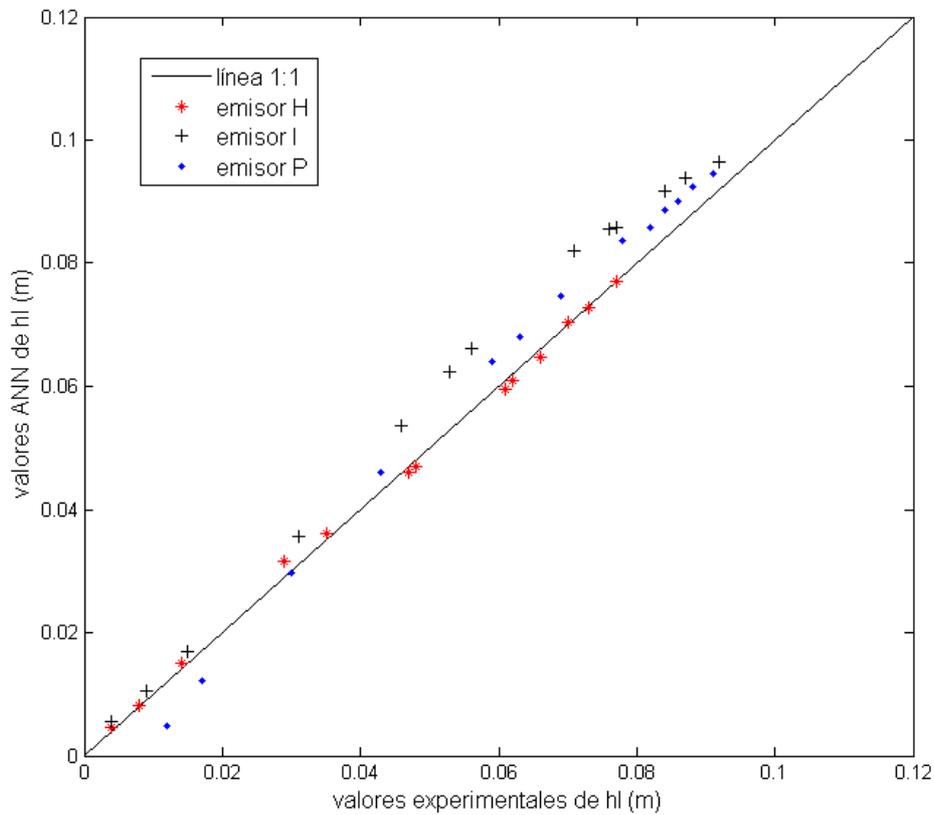


Figura B.6. Predicción de h_1 en emisores con rangos de α bajos, obtenidos con trío de verificación BCDE

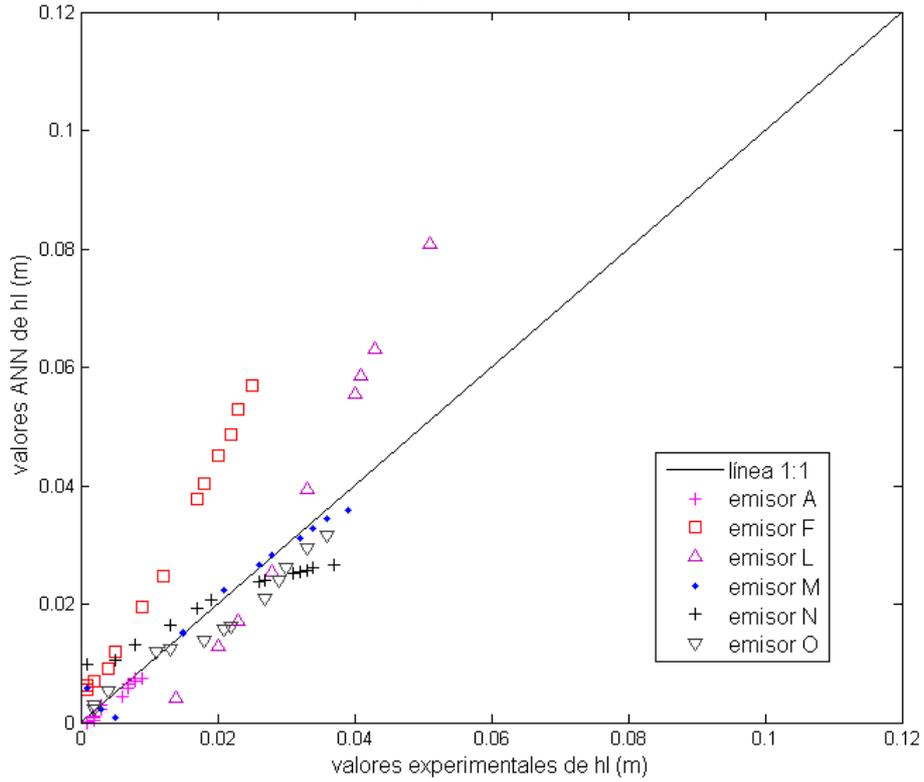


Figura B.7. Predicción de h_1 en emisores con rangos de α altos, obtenidos con trío de verificación GBHI

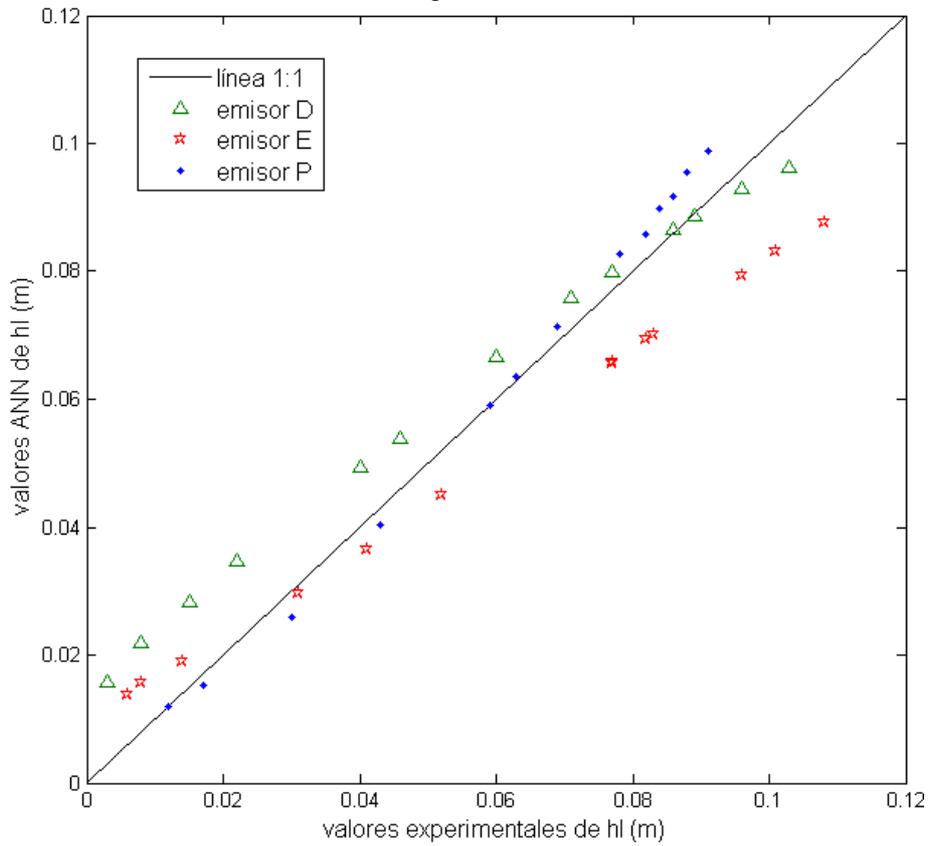
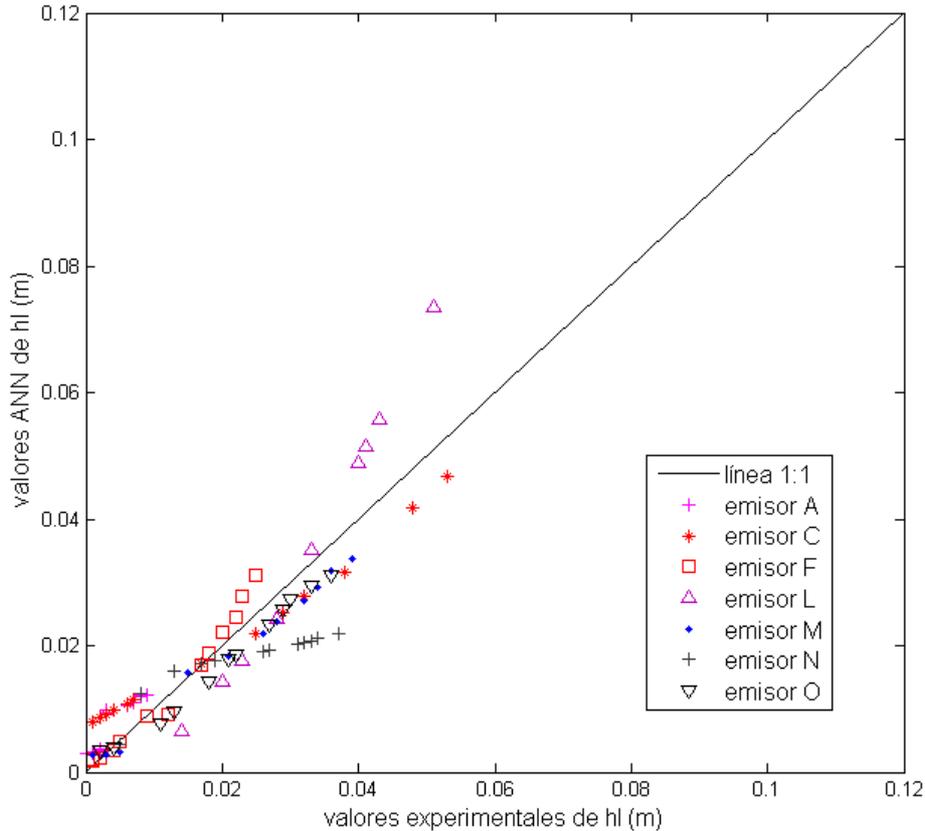


Figura B.8. Predicción de h_l en emisores con rangos de α bajos, obtenidos con trío de verificación GBHI



B.3.3. ERRORES ASOCIADOS A LAS FASES DE ENTRENAMIENTO, VALIDACIÓN-CRUZADA Y TEST DE CADA ETAPA DE LOS PROCESOS ‘LEAVE ONE OUT’. REPETICIÓN ÓPTIMA

En gris se indica el menor error de verificación.

Tabla B.43. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.

A	Verificación con NBE y test con A		
	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	2.2643E-05	1.3349E-04	3.2950E-06
2	1.1719E-04	1.5943E-04	1.5765E-06
3	1.2676E-05	7.7725E-05	2.7037E-04
4	1.0765E-05	8.7801E-05	4.5468E-07
5	1.5384E-05	6.8227E-05	1.5203E-03
6	3.6340E-06	5.2158E-05	1.3469E-05
7	3.0065E-06	4.4614E-05	5.0687E-04
8	2.9707E-05	5.4672E-05	1.0198E-03
9	4.3633E-05	7.7308E-05	8.4458E-04
10	1.5624E-05	6.8472E-05	3.0627E-04
11	1.3552E-05	6.5154E-05	1.9587E-03
12	3.0467E-05	8.1462E-05	1.1272E-04
13	1.3107E-05	7.8999E-05	1.6829E-03
14	7.3724E-06	6.4036E-05	1.4014E-04
15	4.9978E-05	1.1741E-04	4.7678E-05

Tabla B.44. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con C

C	MSE (m ²)		
	entrenamiento	verificación	test
1	1.2507E-04	1.9640E-04	2.4137E-05
2	1.0484E-04	1.4823E-04	1.0743E-04
3	8.0024E-06	5.2770E-05	1.1212E-05
4	6.3787E-05	9.1524E-05	1.0178E-05
5	8.1191E-05	1.2267E-04	2.9471E-05
6	7.5686E-05	1.1124E-04	2.1007E-05
7	9.0454E-05	7.5063E-05	8.0551E-05
8	2.9020E-05	9.4898E-05	2.2820E-06
9	3.9920E-05	8.1492E-05	1.1000E-04
10	9.5630E-05	1.3345E-04	3.7585E-05
11	6.3534E-05	1.0709E-04	2.8959E-05
12	1.0891E-05	5.2348E-05	4.2417E-05
13	6.6306E-05	1.7149E-04	1.3798E-04
14	2.5738E-05	7.4594E-05	9.0058E-06
15	7.5422E-05	1.4093E-04	9.2755E-05

Tabla B.45. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con D

D	MSE (m ²)		
	entrenamiento	verificación	test
1	1.7545E-05	1.5019E-04	6.7773E-05
2	2.3073E-05	1.0995E-04	7.2556E-05
3	1.6855E-04	1.2467E-04	2.3799E-04
4	1.4801E-05	1.4267E-04	6.3695E-05
5	3.0003E-06	5.8300E-05	3.8916E-05
6	1.0385E-05	5.1039E-05	9.8219E-05
7	4.5672E-05	1.0361E-04	1.3478E-04
8	1.7722E-05	9.8808E-05	7.0621E-05
9	3.7597E-05	8.4144E-05	1.1553E-04
10	7.4627E-05	1.3818E-04	7.5755E-05
11	1.5932E-05	1.5131E-04	8.2150E-05
12	3.7970E-05	1.2680E-04	5.2763E-05
13	7.5784E-06	8.0548E-05	3.4974E-05
14	2.1760E-05	1.4034E-04	1.3967E-04
15	2.5837E-05	8.5465E-05	1.7224E-04

Tabla B.46. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con F

F	MSE (m ²)		
	entrenamiento	verificación	test
1	2.4098E-05	1.2917E-04	7.6147E-06
2	2.1963E-05	1.3309E-04	5.7792E-06
3	3.1495E-04	8.9143E-05	2.1511E-04
4	9.5465E-06	5.6766E-05	9.1397E-04
5	2.5805E-06	4.4072E-05	1.3276E-04
6	4.4548E-05	8.7885E-05	4.7240E-04
7	6.1365E-05	1.1402E-04	3.2939E-06
8	1.7385E-05	6.4500E-05	2.1105E-03
9	1.9824E-05	6.6161E-05	2.0332E-03
10	7.1195E-05	1.2658E-04	2.1116E-02
11	3.9435E-06	9.7510E-05	4.8207E-02
12	3.6377E-04	1.1631E-04	1.3558E-03
13	8.8287E-06	7.3035E-05	6.1529E-04
14	8.4661E-06	5.4343E-05	1.2826E-03
15	4.3196E-05	1.3752E-04	1.6268E-04

Tabla B.47. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con G

G	MSE (m ²)		
	entrenamiento	verificación	test
1	6.5710E-05	1.2966E-04	5.3747E-05
2	1.8764E-05	1.1402E-04	1.6868E-05
3	4.5060E-06	4.9749E-05	1.2796E-05
4	1.0270E-04	1.3817E-04	1.1532E-05
5	2.9050E-05	8.8750E-05	3.1873E-04
6	3.3296E-05	6.5047E-05	4.3281E-04
7	4.3362E-05	6.0034E-05	3.0040E-06
8	2.4058E-05	6.3642E-05	7.3503E-04
9	2.9486E-05	9.7755E-05	3.8330E-04
10	4.6173E-05	6.2166E-05	6.0125E-05
11	7.8664E-05	5.8113E-05	2.9245E-04
12	6.7501E-05	9.0469E-05	4.1171E-04
13	6.2155E-05	9.0946E-05	7.3585E-05
14	1.1859E-04	3.3453E-05	6.0943E-05
15	6.6352E-04	1.3369E-04	1.8966E-03

Tabla B.48. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con H

H	MSE (m ²)		
	entrenamiento	verificación	test
1	8.2353E-05	1.3769E-04	5.4089E-05
2	1.0945E-05	1.0545E-04	6.2807E-05
3	3.7819E-05	8.8054E-05	3.3529E-05
4	3.0636E-05	8.4939E-05	2.3525E-04
5	9.7803E-06	3.1323E-05	2.5891E-04
6	3.1196E-05	3.9821E-05	5.3273E-04
7	1.0150E-05	3.5633E-05	7.5965E-06
8	7.6744E-06	4.6038E-05	3.1783E-04
9	6.0178E-05	9.2668E-05	4.3916E-04
10	3.9463E-06	4.0376E-05	2.3843E-05
11	4.9654E-06	9.1244E-05	8.3811E-05
12	4.9852E-05	8.9803E-05	9.8985E-05
13	1.7659E-05	6.9155E-05	1.3575E-04
14	3.3413E-05	4.1595E-05	6.8802E-04
15	9.1806E-06	6.3927E-05	1.1875E-03

Tabla B.49. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con I

I	MSE (m ²)		
	entrenamiento	verificación	test
1	2.6478E-05	1.2282E-04	1.2536E-05
2	6.9201E-06	4.0731E-05	4.8064E-05
3	1.0932E-04	1.2356E-04	8.5949E-05
4	1.2692E-05	6.8634E-05	5.7054E-05
5	3.4325E-05	6.7228E-05	2.9178E-05
6	4.1803E-05	8.5810E-05	2.7253E-05
7	2.4552E-05	5.2602E-05	1.1521E-05
8	3.5802E-05	7.8178E-05	4.7342E-05
9	1.1464E-05	6.9309E-05	4.1500E-05
10	9.4489E-06	7.5363E-05	2.4382E-05
11	2.3093E-06	8.2933E-05	1.0308E-05
12	3.5177E-05	1.0258E-04	1.8172E-04
13	1.1101E-05	6.0743E-05	6.3649E-05
14	4.7032E-05	1.5284E-04	5.7471E-05
15	2.3152E-05	5.2786E-05	9.7439E-05

Tabla B.50. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con L

L	MSE (m ²)		
	entrenamiento	verificación	test
1	2.2124E-05	7.2930E-05	3.9416E-04
2	2.9881E-05	5.5147E-05	5.9346E-04
3	2.1666E-05	8.3821E-05	3.1266E-04
4	8.4907E-06	9.1256E-05	2.3765E-04
5	4.8236E-05	4.3291E-05	1.4511E-03
6	8.2520E-05	1.0837E-04	2.6534E-03
7	2.1576E-05	6.4777E-05	4.8157E-04
8	1.0533E-05	6.5383E-05	4.2670E-05
9	3.2797E-05	3.0658E-05	2.2911E-03
10	6.1611E-06	1.1880E-04	3.5127E-04
11	6.5515E-05	1.3415E-04	1.5829E-04
12	2.9715E-05	9.2147E-05	2.9253E-04
13	5.4167E-05	9.3303E-05	3.5913E-04
14	2.2681E-05	3.3232E-05	1.7963E-03
15	1.8208E-05	6.5196E-05	8.4335E-04

Tabla B.51. Errores de entrenamiento y test para de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con M

M	MSE (m ²)		
	entrenamiento	verificación	test
1	1.6254E-05	1.1034E-04	9.6580E-05
2	4.2625E-06	6.4101E-05	4.5226E-05
3	5.4778E-05	9.3264E-05	9.6272E-05
4	1.0821E-04	1.7807E-04	6.0802E-05
5	5.0158E-06	4.5561E-05	7.8983E-06
6	1.5071E-05	5.5308E-05	1.4641E-05
7	1.4450E-05	7.2384E-05	3.1943E-05
8	5.0778E-05	8.8401E-05	3.9672E-05
9	2.5013E-05	1.1302E-04	8.7875E-04
10	6.6036E-05	1.4314E-04	9.9059E-05
11	1.3861E-05	7.4983E-05	7.2659E-05
12	1.4163E-05	3.0865E-05	1.9899E-05
13	3.4792E-05	6.1913E-05	5.1873E-04
14	7.9824E-06	9.3430E-05	5.6235E-04
15	6.6333E-06	8.0765E-05	1.1397E-04

Tabla B.52. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con O

O	MSE (m ²)		
	entrenamiento	verificación	test
1	6.3179E-05	1.2689E-04	2.3760E-04
2	5.0493E-06	3.7805E-05	7.9055E-06
3	6.9045E-05	1.3668E-04	2.7352E-05
4	6.5650E-06	7.5037E-05	4.0420E-06
5	1.5799E-05	7.7402E-05	6.2067E-05
6	4.9075E-05	7.2285E-05	6.1788E-04
7	6.0705E-06	5.9872E-05	2.6539E-03
8	5.1924E-06	3.9378E-05	1.1370E-05
9	3.5435E-05	4.4176E-05	2.5354E-05
10	8.4786E-05	1.0939E-04	5.3544E-05
11	2.4439E-05	7.2378E-05	1.7601E-04
12	6.4952E-06	5.2710E-05	5.7105E-05
13	1.5771E-05	6.7529E-05	1.7450E-04
14	4.7288E-05	6.4599E-05	3.2201E-04
15	5.9920E-05	1.1995E-04	3.6043E-04

Tabla B.53. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBE y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	2.0520E-05	1.3628E-04	2.7314E-05
2	1.0583E-04	2.5917E-04	2.5664E-04
3	6.7879E-06	2.8388E-05	2.8883E-05
4	1.7303E-05	7.7104E-05	1.9966E-05
5	7.2115E-06	8.6043E-05	7.4703E-06
6	7.7284E-05	1.1519E-04	5.5372E-05
7	2.7766E-05	1.3076E-04	7.0674E-06
8	2.9519E-05	5.8387E-05	2.0209E-05
9	2.2254E-05	6.3549E-05	1.0977E-05
10	4.4044E-05	8.7226E-05	3.6726E-05
11	2.9087E-05	8.0430E-05	3.2282E-05
12	1.4666E-04	6.3589E-05	2.8137E-05
13	1.8837E-05	6.7513E-05	2.8797E-05
14	1.0992E-06	5.2416E-05	3.5754E-05
15	2.9874E-05	4.9353E-05	2.0751E-05

Tabla B.54. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con NBE y test con Q

Q	MSE (m ²)		
	entrenamiento	verificación	test
1	2.0967E-05	1.1362E-04	1.7928E-03
2	3.9849E-06	3.4498E-05	3.1677E-03
3	4.1114E-06	6.2914E-05	6.7759E-03
4	8.2680E-06	6.7084E-05	4.7177E-03
5	1.6342E-05	8.3511E-05	1.4693E-04
6	1.0296E-04	1.2244E-04	1.5668E-03
7	2.5099E-05	7.9183E-05	1.8369E-03
8	2.1147E-05	5.7178E-05	7.5914E-05
9	3.8806E-05	7.5653E-05	9.9564E-05
10	1.0110E-05	4.4457E-05	1.0270E-04
11	3.7413E-05	6.9210E-05	2.9369E-03
12	5.5747E-05	8.1241E-05	9.2282E-05
13	2.9454E-05	6.1600E-05	1.8660E-03
14	3.1852E-05	7.4543E-05	1.5146E-04
15	3.2056E-05	9.8171E-05	1.5996E-04

Tabla B.55. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con A

A	MSE (m ²)		
	entrenamiento	verificación	test
1	4.9099E-05	1.0698E-04	2.5482E-05
2	5.7180E-06	5.5156E-05	5.4907E-07
3	4.4390E-06	3.4599E-05	6.9676E-07
4	3.0661E-06	1.7781E-05	2.1108E-06
5	7.1192E-05	8.9336E-05	6.7022E-05
6	3.1796E-06	2.4411E-05	6.8843E-06
7	4.0887E-05	5.4897E-05	6.3393E-05
8	3.0714E-05	6.4496E-05	7.5547E-05
9	1.8864E-06	3.7543E-05	3.2198E-03
10	1.1056E-04	6.6356E-05	5.6385E-04
11	2.1601E-04	9.9201E-05	5.6952E-04
12	5.0252E-05	2.5050E-04	1.5093E-03
13	3.0987E-05	1.0379E-04	1.7975E-05
14	1.6893E-05	4.1129E-05	3.7029E-04
15	1.6036E-05	7.7670E-05	1.2549E-05

Tabla B.56. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con C

C	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	4.0992E-05	1.3636E-04	4.9033E-05
2	9.5128E-06	7.8412E-05	4.2542E-05
3	9.7453E-06	5.7754E-05	3.5415E-05
4	2.2322E-05	6.5947E-05	5.9728E-05
5	4.1094E-06	4.3505E-05	5.6658E-06
6	9.1876E-05	1.1228E-04	1.3005E-05
7	3.8662E-05	1.5470E-04	2.9609E-05
8	6.0828E-06	9.5413E-05	3.3395E-05
9	2.3739E-04	1.3155E-04	3.7875E-04
10	3.0515E-06	1.6501E-04	4.6236E-05
11	1.6572E-06	6.5682E-05	2.1987E-05
12	4.6063E-05	9.6293E-05	1.3645E-04
13	2.2400E-05	8.1887E-05	3.1670E-05
14	1.0930E-05	8.4488E-05	4.7349E-05
15	8.1422E-05	2.1835E-04	4.4490E-04

Tabla B.57. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con D

D	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	2.1255E-05	1.2871E-04	5.4584E-05
2	2.4929E-06	3.0713E-05	3.6498E-05
3	1.7188E-06	1.9634E-05	5.6222E-05
4	5.5178E-06	5.2142E-05	4.7221E-05
5	1.0111E-05	4.4315E-05	4.4957E-05
6	4.7629E-06	7.3739E-05	2.1800E-05
7	4.3809E-06	8.6722E-05	7.5481E-05
8	8.4286E-05	1.1397E-04	1.4166E-04
9	6.4250E-06	4.2661E-05	2.0370E-05
10	5.3651E-06	4.1247E-05	1.0928E-04
11	1.1598E-05	8.6248E-05	6.8152E-05
12	4.1865E-05	1.4860E-04	1.2513E-04
13	5.5881E-06	7.4977E-05	4.8224E-05
14	2.4348E-06	6.2544E-05	8.6073E-05
15	4.1265E-05	1.2241E-04	1.4920E-04

Tabla B.58. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con F

F	MSE (m ²)		
	entrenamiento	verificación	test
1	7.6180E-05	1.2031E-04	2.7765E-05
2	5.5013E-06	4.7856E-05	3.6952E-04
3	3.6425E-06	4.8698E-05	1.3037E-04
4	9.2671E-06	3.6842E-05	1.2139E-04
5	5.5984E-05	5.5223E-05	1.8937E-03
6	3.1074E-05	6.9994E-05	2.3712E-04
7	1.8833E-04	7.1666E-05	1.9449E-04
8	1.8679E-05	4.1714E-05	2.6270E-05
9	3.0838E-04	7.8109E-05	3.0364E-03
10	8.7917E-06	7.4652E-05	1.5404E-03
11	2.0691E-05	6.3553E-05	4.0170E-03
12	4.6996E-05	8.7026E-05	3.3048E-03
13	5.8339E-05	8.0447E-05	1.5955E-03
14	8.7944E-05	1.9485E-04	4.0529E-03
15	4.1855E-05	1.6237E-04	3.2853E-03

Tabla B.59. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con G

G	MSE (m ²)		
	entrenamiento	verificación	Test
1	3.5498E-05	9.9898E-05	3.7400E-05
2	6.7618E-06	7.2970E-05	9.9416E-06
3	3.4154E-06	3.3238E-05	2.6458E-05
4	9.6441E-06	2.7399E-05	1.3441E-05
5	1.1746E-05	5.0166E-05	7.7867E-05
6	4.5067E-05	7.0741E-05	1.9524E-03
7	3.3769E-05	5.5854E-05	2.7917E-04
8	1.5959E-05	5.0015E-05	1.2072E-02
9	9.0521E-06	6.8794E-05	1.6466E-04
10	1.4655E-04	1.1119E-04	1.5112E-03
11	3.5534E-05	9.2876E-05	6.5081E-05
12	2.0720E-04	1.2599E-04	6.9446E-04
13	1.2626E-04	6.1440E-05	7.9266E-03
14	3.4900E-05	1.2648E-04	8.5850E-05
15	3.0795E-05	1.0973E-04	1.1352E-04

Tabla B.60. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con H

H	MSE (m ²)		
	nº neuronas	entrenamiento	verificación
1	2.1066E-05	1.2241E-04	3.2389E-05
2	3.1227E-06	5.2565E-05	8.8812E-05
3	3.1239E-06	4.7618E-05	8.2884E-05
4	9.5748E-06	6.0872E-05	5.9383E-05
5	1.9195E-05	1.2621E-04	2.7002E-04
6	8.6562E-05	1.0514E-04	1.2517E-04
7	3.3375E-05	6.0689E-05	1.9389E-04
8	1.0558E-03	7.2361E-05	7.9215E-04
9	2.2558E-05	1.0348E-04	5.2169E-04
10	3.8097E-05	7.5272E-05	7.2198E-05
11	1.2444E-03	8.5515E-05	3.1848E-04
12	9.6356E-05	5.7188E-05	1.0718E-03
13	1.5583E-05	9.4235E-05	6.5263E-05
14	3.9620E-04	1.1079E-04	1.6414E-04
15	5.9720E-05	5.1480E-05	6.3155E-04

Tabla B.61. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con I

I	MSE (m ²)		
	nº neuronas	entrenamiento	verificación
1	1.8758E-05	1.2390E-04	2.3149E-05
2	3.8681E-06	3.4835E-05	6.8338E-06
3	4.8233E-06	5.8226E-05	7.2630E-06
4	4.6888E-06	5.1537E-05	1.0849E-05
5	3.8615E-05	4.7240E-05	1.1137E-05
6	8.5315E-06	6.9381E-05	4.3951E-06
7	4.1483E-06	3.4613E-05	2.6992E-05
8	3.0977E-06	3.5907E-05	1.6190E-05
9	4.7651E-05	8.4655E-05	8.1469E-05
10	4.0333E-05	6.9339E-05	1.7872E-05
11	3.9634E-05	9.1064E-05	1.0503E-04
12	2.3809E-05	7.0709E-05	2.6878E-05
13	5.4283E-05	1.2348E-04	8.9921E-05
14	7.9610E-06	5.7801E-05	9.5239E-06
15	8.6669E-05	3.8170E-05	4.9144E-05

Tabla B.62. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con L

L	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	4.0426E-05	8.9552E-05	3.8734E-04
2	1.0210E-05	6.9122E-05	3.2998E-04
3	7.2082E-06	5.0103E-05	1.4492E-04
4	3.5940E-05	2.4696E-05	3.9020E-04
5	1.6967E-05	3.1076E-05	4.5384E-03
6	2.8216E-06	3.2830E-05	2.0386E-06
7	1.0059E-05	8.5156E-05	5.5010E-05
8	2.4581E-05	7.4264E-05	8.6609E-04
9	1.5909E-05	5.0705E-05	1.1430E-04
10	1.0229E-05	1.0339E-04	1.8338E-04
11	1.0539E-05	7.9385E-05	1.0129E-03
12	3.4527E-05	1.1239E-04	2.3130E-04
13	2.4413E-05	1.5803E-04	9.0965E-05
14	6.1341E-06	1.4904E-04	1.6566E-04
15	5.7091E-06	1.0356E-04	5.2601E-03

Tabla B.63. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con M

M	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	3.5782E-05	1.1337E-04	4.9136E-05
2	5.4812E-06	7.1650E-05	1.1432E-05
3	1.3792E-05	5.9847E-05	9.3475E-05
4	1.8992E-05	8.3873E-05	7.4977E-06
5	5.5889E-06	4.7817E-05	1.7445E-05
6	4.6025E-05	6.3650E-05	4.3210E-05
7	5.5835E-06	2.3967E-05	1.0781E-05
8	1.1744E-05	6.1720E-05	6.1515E-05
9	3.1024E-06	5.0640E-05	5.7448E-05
10	6.9322E-05	9.3999E-05	1.1071E-03
11	3.8333E-05	8.1945E-05	1.9990E-04
12	1.1890E-04	8.2605E-05	3.2689E-04
13	5.6645E-06	3.6342E-05	3.8612E-05
14	5.0866E-06	1.4183E-04	7.1091E-05
15	1.5825E-05	6.9504E-05	1.6537E-03

Tabla B.64. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con O

O	MSE (m ²)		
	entrenamiento	verificación	test
1	3.6599E-05	1.1773E-04	1.2085E-05
2	4.0815E-06	3.2541E-05	4.0447E-06
3	1.8049E-05	5.6553E-05	1.5264E-05
4	1.2018E-05	6.2471E-05	2.7820E-05
5	6.2354E-06	4.8802E-05	1.1007E-05
6	7.0610E-05	1.3030E-04	2.8294E-05
7	6.6493E-05	6.2695E-05	2.2704E-04
8	8.8115E-05	1.1804E-04	9.4152E-05
9	1.6067E-05	8.3682E-05	2.8143E-04
10	1.9992E-05	6.0592E-05	3.7030E-05
11	4.9091E-04	6.2886E-05	4.7955E-04
12	2.4281E-05	1.0422E-04	4.4204E-05
13	1.0671E-04	1.5802E-04	6.2487E-05
14	2.4252E-05	1.0051E-04	1.0248E-04
15	6.9851E-05	1.5044E-04	2.7376E-04

Tabla B.65. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBE y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	5.0273E-05	1.3009E-04	8.3366E-05
2	1.7648E-05	5.9942E-05	1.2256E-05
3	2.0256E-05	5.1401E-05	3.8011E-05
4	3.9489E-06	3.4981E-05	7.1338E-06
5	3.9282E-06	3.6958E-05	2.3919E-05
6	3.6313E-06	1.0369E-04	2.4827E-06
7	1.4897E-05	4.5957E-05	3.2944E-06
8	1.5117E-05	4.7700E-05	4.4086E-06
9	6.5763E-05	1.1890E-04	7.0762E-05
10	4.0650E-05	1.7558E-04	3.4105E-05
11	1.6532E-05	6.4342E-05	3.8770E-05
12	6.8233E-05	6.3508E-05	3.3437E-05
13	1.1035E-05	8.1938E-05	7.9807E-05
14	4.9151E-06	3.9322E-05	4.0904E-06
15	5.1181E-05	1.1263E-04	4.5179E-05

Tabla B.66. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con A

A	MSE (m ²)		
	entrenamiento	verificación	test
1	1.4168E-04	2.6960E-05	7.6948E-06
2	9.6774E-05	5.2287E-05	2.1958E-05
3	3.7723E-04	6.0408E-05	3.9803E-04
4	2.1226E-05	1.6896E-05	3.3904E-05
5	1.5472E-04	1.9732E-04	3.0606E-04
6	4.9844E-04	5.1252E-05	1.5743E-03
7	6.1487E-04	7.6838E-05	4.6696E-02
8	5.7372E-04	1.5293E-04	8.9030E-04
9	3.1381E-04	7.7912E-05	9.1990E-04
10	7.1879E-05	3.8131E-05	2.5077E-04
11	3.8445E-05	4.5215E-05	1.3827E-03
12	1.1532E-04	9.6054E-05	3.1349E-04
13	3.7548E-04	1.0004E-04	6.3890E-05
14	3.0373E-05	1.4300E-04	2.1805E-04
15	1.0634E-05	6.2312E-05	1.3004E-04

Tabla B.67. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con C

C	MSE (m ²)		
	entrenamiento	verificación	test
1	9.5122E-05	1.1300E-04	1.4114E-04
2	1.1370E-04	4.3546E-05	1.7659E-05
3	7.1801E-06	1.4034E-04	2.1362E-05
4	3.2647E-04	8.9102E-05	5.2998E-05
5	2.3743E-04	6.9099E-05	2.7438E-04
6	1.5725E-04	7.6655E-05	7.5597E-05
7	1.3643E-05	1.3690E-04	1.2468E-04
8	6.7342E-05	1.5483E-04	5.6880E-05
9	3.0280E-04	6.9494E-05	2.0828E-05
10	5.6320E-06	1.0521E-05	5.2561E-06
11	1.0118E-04	1.0903E-04	1.7574E-04
12	1.6745E-04	1.0261E-04	4.4672E-05
13	9.7535E-05	1.2510E-04	8.6651E-04
14	1.2620E-04	5.4995E-05	1.8319E-04
15	8.2652E-05	1.0109E-04	5.4018E-05

Tabla B.68. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con D

C	MSE (m ²)		
	entrenamiento	verificación	test
1	9.5122E-05	1.1300E-04	1.4114E-04
2	1.1370E-04	4.3546E-05	1.7659E-05
3	7.1801E-06	1.4034E-04	2.1362E-05
4	3.2647E-04	8.9102E-05	5.2998E-05
5	2.3743E-04	6.9099E-05	2.7438E-04
6	1.5725E-04	7.6655E-05	7.5597E-05
7	1.3643E-05	1.3690E-04	1.2468E-04
8	6.7342E-05	1.5483E-04	5.6880E-05
9	3.0280E-04	6.9494E-05	2.0828E-05
10	5.6320E-06	1.0521E-05	5.2561E-06
11	1.0118E-04	1.0903E-04	1.7574E-04
12	1.6745E-04	1.0261E-04	4.4672E-05
13	9.7535E-05	1.2510E-04	8.6651E-04
14	1.2620E-04	5.4995E-05	1.8319E-04
15	8.2652E-05	1.0109E-04	5.4018E-05

Tabla B.69. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con E

E	MSE (m ²)		
	entrenamiento	verificación	test
1	7.8145E-05	4.8541E-05	4.3792E-04
2	1.1551E-04	9.4341E-05	3.4200E-04
3	2.0110E-04	1.5307E-04	8.1061E-04
4	4.2207E-05	3.5300E-05	2.4391E-04
5	1.9802E-04	8.9571E-05	6.7588E-04
6	5.1432E-06	4.5823E-05	1.3857E-04
7	3.8344E-05	2.0740E-05	2.0578E-04
8	3.1972E-05	8.1335E-05	1.5113E-04
9	1.6012E-04	7.7253E-05	6.4430E-04
10	9.1785E-05	1.1717E-04	3.7354E-04
11	3.8860E-06	4.6414E-05	7.4883E-05
12	6.7792E-05	2.9646E-05	1.8618E-04
13	3.9484E-04	9.0102E-05	3.9116E-04
14	4.8245E-05	7.3997E-05	1.4204E-04
15	2.2304E-04	5.6464E-05	2.8439E-04

Tabla B.70. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con F

F	MSE (m ²)		
	entrenamiento	verificación	test
1	8.6356E-05	5.5907E-05	7.0530E-05
2	1.8026E-04	8.2586E-05	1.1119E-04
3	4.2739E-05	1.1645E-04	1.2030E-03
4	3.5660E-05	6.6757E-05	3.5976E-05
5	7.1427E-06	6.3364E-05	1.8688E-03
6	2.6769E-04	6.9407E-05	1.2072E-05
7	2.4611E-04	6.3535E-05	1.2263E-04
8	7.4238E-05	7.9055E-05	3.5068E-04
9	4.9633E-05	4.6034E-05	3.2515E-04
10	2.8378E-05	5.1601E-05	1.6615E-03
11	1.0234E-04	5.4783E-05	1.3541E-04
12	1.0227E-04	8.4063E-05	8.5835E-04
13	3.4605E-05	3.0378E-05	2.0323E-04
14	8.8380E-05	8.0904E-05	1.3926E-03
15	6.3584E-05	1.0373E-04	6.0212E-04

Tabla B.71. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con G

G	MSE (m ²)		
	entrenamiento	verificación	test
1	1.2963E-04	5.6850E-05	1.9586E-05
2	2.0256E-04	5.6788E-05	3.1414E-05
3	1.6012E-04	1.1683E-04	3.2902E-04
4	6.3836E-05	6.0770E-05	4.2961E-05
5	1.0898E-04	6.2657E-05	1.2770E-03
6	2.2541E-04	5.0231E-05	5.2157E-05
7	9.2164E-05	3.7251E-05	1.2151E-04
8	1.1953E-04	3.5714E-05	5.1332E-04
9	1.0432E-05	2.6119E-05	1.2945E-05
10	5.5297E-05	1.2094E-04	1.9503E-04
11	6.3430E-05	1.1908E-05	1.5165E-04
12	1.1338E-04	9.3496E-05	4.4928E-04
13	4.6580E-04	7.6972E-05	1.6496E-04
14	9.0471E-05	1.1911E-04	9.9304E-06
15	3.7194E-04	9.1794E-05	1.0485E-01

Tabla B.72. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con I

I	MSE (m ²)		
	entrenamiento	verificación	test
1	9.5970E-05	3.0154E-05	5.0048E-05
2	1.6904E-04	5.1812E-05	1.6124E-04
3	2.1869E-04	5.4834E-05	1.8331E-04
4	2.4507E-04	1.1892E-04	3.7691E-04
5	1.4176E-04	4.8361E-05	1.5622E-04
6	9.8748E-05	6.7717E-05	3.6672E-05
7	1.8469E-05	4.0664E-05	1.4899E-05
8	6.0959E-05	7.2261E-05	5.9724E-05
9	1.3090E-05	4.4252E-05	3.2249E-05
10	2.0271E-04	6.2324E-05	5.7389E-05
11	1.2059E-04	9.9385E-05	1.6425E-04
12	8.3243E-05	7.0204E-05	8.8594E-05
13	2.2723E-05	8.6714E-05	5.7407E-05
14	2.7900E-05	9.3953E-05	7.0796E-05
15	1.1465E-05	4.6739E-05	2.3700E-05

Tabla B.73. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con L

L	MSE (m ²)		
	entrenamiento	verificación	test
1	3.0029E-05	4.1295E-05	4.4647E-04
2	2.7011E-04	9.0396E-05	2.3227E-04
3	6.4667E-05	1.1735E-04	2.2458E-04
4	1.5844E-04	5.2261E-05	8.6191E-05
5	1.4695E-04	2.5405E-05	1.9551E-04
6	4.5097E-05	7.3576E-05	3.9018E-04
7	2.0578E-04	4.4687E-05	3.1916E-04
8	7.9497E-05	9.3029E-05	1.0185E-04
9	9.8299E-05	6.9871E-05	2.0846E-04
10	5.1761E-04	8.3037E-05	8.1918E-05
11	5.3437E-05	7.7322E-05	5.3042E-04
12	3.1427E-04	7.8592E-05	1.0576E-04
13	2.2157E-04	3.6394E-05	1.7735E-03
14	1.8121E-05	4.2438E-05	1.5054E-04
15	2.7655E-05	4.4357E-05	2.3748E-04

Tabla B.74. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con M

M	MSE (m ²)		
	nº neuronas	entrenamiento	verificación
1	1.6058E-04	4.3002E-05	3.4458E-05
2	7.4483E-05	7.5590E-05	1.8963E-04
3	6.8896E-05	5.7641E-05	5.0548E-05
4	3.6540E-04	5.9708E-05	2.2924E-04
5	6.1784E-05	7.1521E-05	1.6522E-04
6	1.0020E-04	6.1537E-05	2.5283E-04
7	1.6837E-04	7.4465E-05	3.6383E-05
8	1.3648E-04	1.5533E-04	2.9851E-05
9	8.8228E-05	8.2840E-05	4.4428E-04
10	7.1336E-05	4.7732E-05	8.5311E-05
11	2.0897E-05	1.4070E-04	7.2024E-05
12	3.6953E-04	9.7868E-05	2.7397E-04
13	1.3037E-05	1.3249E-04	2.2550E-03
14	9.4074E-05	8.4236E-05	3.8972E-04
15	1.5134E-05	2.5336E-05	1.7322E-05

Tabla B.75. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con O

O	MSE (m ²)		
	nº neuronas	entrenamiento	verificación
1	9.8694E-05	2.5234E-05	3.9113E-04
2	8.2424E-05	6.0078E-05	3.0465E-04
3	1.2719E-04	4.8038E-05	2.0389E-05
4	5.3996E-05	4.9623E-05	8.1753E-05
5	5.0493E-05	2.8227E-05	6.3322E-05
6	1.1364E-05	4.2578E-05	5.9581E-05
7	1.8597E-04	3.0942E-05	6.1510E-04
8	1.3622E-05	1.1063E-04	2.5002E-04
9	1.4347E-05	2.4053E-05	1.9368E-05
10	1.3966E-04	4.9966E-05	2.1761E-04
11	4.6927E-05	3.5829E-05	7.7219E-05
12	1.0329E-04	7.6127E-05	5.1525E-05
13	1.0241E-04	2.7782E-05	4.8752E-04
14	9.9642E-05	6.0782E-05	2.0258E-04
15	6.0875E-05	1.7126E-04	6.3831E-05

Tabla B.76. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con P

P	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	9.0923E-05	3.7497E-05	8.7745E-05
2	1.1568E-04	5.5436E-05	2.6984E-04
3	2.7814E-05	9.4378E-05	4.7358E-05
4	2.1005E-04	5.7055E-05	2.6189E-04
5	1.8437E-05	2.4655E-05	1.4875E-06
6	6.1216E-05	8.4128E-05	4.5586E-05
7	2.7497E-04	3.7099E-05	1.3287E-04
8	1.0572E-04	4.4621E-05	9.3397E-05
9	1.4799E-04	7.0460E-05	4.4151E-05
10	1.1793E-04	4.3252E-05	2.0891E-04
11	6.7396E-05	8.7203E-05	2.0124E-04
12	1.1059E-04	1.2615E-04	7.1767E-05
13	2.8203E-05	7.2605E-05	8.1339E-06
14	4.9829E-06	4.1637E-05	5.0928E-06
15	7.1586E-05	1.0714E-04	6.7263E-05

Tabla B.77. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con NBH y test con Q

Q	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	1.1235E-04	7.2759E-05	3.1541E-03
2	6.4524E-05	7.7594E-05	2.3594E-03
3	9.2993E-06	1.6790E-05	3.0612E-03
4	2.8530E-04	7.6710E-05	9.6357E-05
5	1.3234E-04	6.7135E-05	6.0655E-04
6	1.5319E-04	2.5331E-05	2.1770E-03
7	9.5271E-05	9.8100E-05	1.1532E-04
8	3.2590E-05	8.2460E-05	3.4555E-03
9	1.3281E-04	5.0875E-05	2.5045E-03
10	1.0868E-05	1.0021E-05	2.7125E-03
11	3.3119E-05	6.1867E-05	1.7846E-04
12	1.8783E-05	4.5720E-06	3.9686E-03
13	1.7252E-04	5.1750E-05	3.1712E-04
14	6.1501E-05	5.9293E-05	3.3592E-05
15	1.9800E-04	7.3383E-05	3.2939E-03

Tabla B.78. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con A

A	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	5.4046E-05	5.2895E-05	1.1419E-05
2	1.2801E-05	4.0239E-05	1.5054E-05
3	1.7546E-04	4.2061E-05	1.4290E-04
4	2.0260E-05	5.9302E-05	6.3866E-06
5	2.1262E-04	4.4208E-05	1.6750E-04
6	2.9520E-04	1.1536E-04	1.7689E-05
7	1.3140E-05	2.6164E-05	1.0338E-05
8	1.8606E-04	5.5981E-05	2.9681E-04
9	2.0550E-04	4.6452E-05	1.5926E-04
10	1.0876E-04	7.4207E-05	2.4584E-04
11	1.1792E-04	5.6330E-05	3.2373E-04
12	1.3760E-04	1.5075E-04	3.4431E-04
13	8.9250E-05	1.2525E-04	2.1233E-03
14	5.5762E-05	1.2148E-04	8.4289E-04
15	2.1743E-04	2.0759E-04	8.4755E-04

Tabla B.79. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con C

C	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	1.9064E-04	6.6363E-05	6.0850E-05
2	2.8054E-05	6.2481E-05	4.1627E-05
3	7.2789E-06	2.2802E-05	1.6960E-05
4	1.4200E-05	3.9168E-05	7.2728E-05
5	1.3867E-04	6.8249E-05	6.3021E-05
6	1.1022E-03	8.3708E-05	2.3524E-04
7	1.1294E-04	7.2582E-05	2.2391E-05
8	8.4867E-05	9.2957E-05	1.4273E-04
9	7.0442E-04	1.2394E-04	1.6464E-04
10	3.4922E-05	5.6867E-05	7.7302E-05
11	7.1415E-04	1.2334E-04	1.6310E-04
12	1.0777E-04	9.2987E-05	4.6415E-05
13	2.8812E-04	1.0777E-04	9.5375E-05
14	7.5652E-05	1.1156E-04	3.0962E-04
15	3.7129E-05	6.4004E-05	9.9372E-05

Tabla B.80. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con D

D	MSE (m ²)			
	n° neuronas	entrenamiento	verificación	test
1		2.8721E-05	6.9464E-05	5.4692E-05
2		2.8291E-05	3.6763E-05	4.5065E-05
3		1.0110E-04	1.2293E-04	2.4573E-04
4		9.2458E-05	6.9756E-05	1.9700E-04
5		6.6954E-06	2.5167E-05	2.8339E-05
6		4.2213E-05	6.6038E-05	2.8318E-05
7		1.0168E-04	5.3194E-05	1.5328E-04
8		4.0509E-05	9.8653E-05	5.3819E-05
9		3.8143E-04	6.3061E-05	3.9352E-04
10		1.3526E-04	8.2971E-05	2.2498E-04
11		3.5584E-04	1.3436E-04	6.2210E-04
12		5.0154E-05	1.3358E-04	1.2725E-04
13		2.8759E-04	9.9256E-05	3.4257E-04
14		1.3011E-04	1.0533E-04	3.6343E-04
15		7.7055E-05	1.2149E-04	1.5721E-04

Tabla B.81. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con E

E	MSE (m ²)			
	n° neuronas	entrenamiento	verificación	test
1		1.4116E-04	5.8239E-05	5.5356E-04
2		5.5527E-06	4.0574E-05	1.2358E-04
3		2.0820E-05	5.9364E-05	1.9441E-04
4		1.5263E-04	1.0813E-05	4.8396E-04
5		9.1624E-06	1.4850E-05	1.4968E-04
6		9.1228E-06	1.5491E-05	1.3489E-04
7		1.0590E-04	2.8466E-05	5.7134E-04
8		9.5532E-05	7.1711E-05	4.1170E-04
9		2.1264E-04	8.6709E-05	6.2627E-04
10		5.5556E-06	5.8477E-05	8.6387E-05
11		2.2508E-05	1.1364E-04	1.2877E-04
12		1.2435E-04	5.3132E-05	5.4257E-04
13		9.3580E-06	1.5479E-04	1.2432E-04
14		1.4146E-04	8.8158E-05	4.5541E-04
15		2.2987E-05	6.7854E-05	1.1309E-04

Tabla B.82. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con F

F	MSE (m ²)		
	entrenamiento	verificación	test
1	1.2961E-04	6.6446E-05	7.6277E-05
2	1.0285E-05	1.3849E-05	1.3450E-04
3	1.8472E-04	5.7792E-05	2.6671E-05
4	3.8125E-04	7.0289E-05	1.7690E-03
5	2.3117E-04	7.5305E-05	1.6497E-03
6	2.6240E-05	1.4767E-05	2.2460E-04
7	3.0908E-05	3.4686E-05	1.2119E-04
8	1.0936E-04	6.4129E-05	6.6160E-04
9	2.1835E-05	2.0084E-04	7.4020E-05
10	2.8760E-04	1.0920E-04	8.6856E-05
11	3.4382E-05	7.5123E-05	7.4908E-04
12	8.6825E-06	5.3217E-05	1.2361E-04
13	1.2613E-05	1.5931E-05	1.7888E-04
14	8.8823E-05	9.6259E-05	8.4124E-05
15	2.8376E-05	1.0522E-04	4.4602E-03

Tabla B.83. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con G

G	MSE (m ²)		
	entrenamiento	verificación	test
1	3.0480E-05	7.6548E-05	3.5343E-05
2	1.3426E-04	8.1131E-05	1.3963E-05
3	8.5733E-06	4.4921E-05	5.5572E-06
4	4.3708E-04	7.6278E-05	5.5341E-04
5	1.5981E-04	6.9711E-05	2.3317E-04
6	1.6970E-05	4.6088E-05	3.0718E-06
7	1.0553E-04	5.3869E-05	1.1492E-05
8	1.3286E-04	7.1474E-05	1.0653E-03
9	1.3751E-04	5.7891E-05	6.3678E-05
10	1.9830E-04	5.2026E-05	4.3152E-04
11	3.3272E-05	5.6931E-05	1.3272E-04
12	4.1769E-05	2.3093E-04	9.7108E-04
13	9.2286E-05	6.6563E-05	8.4299E-05
14	1.1127E-04	1.2448E-04	9.8418E-04
15	1.5795E-04	2.1868E-04	7.0175E-02

Tabla B.84. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con I

I	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	1.6283E-04	3.7583E-05	1.8307E-04
2	2.0638E-04	6.6517E-05	2.9338E-04
3	4.4230E-05	5.3155E-05	3.4179E-05
4	1.4688E-05	4.2437E-05	3.5298E-05
5	4.7702E-05	7.6123E-05	5.3681E-05
6	1.4473E-04	9.2365E-05	9.7335E-05
7	8.8363E-05	5.2320E-05	1.0616E-04
8	3.8652E-05	3.0381E-05	4.5396E-05
9	7.4437E-05	8.1253E-05	1.9202E-05
10	3.9035E-05	4.9273E-05	1.1339E-04
11	1.4666E-04	1.6272E-04	1.6043E-04
12	4.4022E-05	4.4947E-05	5.0685E-05
13	2.0492E-05	1.7745E-05	2.0864E-05
14	6.7261E-05	8.5483E-05	3.9235E-04
15	7.2258E-05	3.8033E-05	1.1258E-05

Tabla B.85. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con L

L	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	2.4902E-05	4.1892E-05	3.8132E-04
2	1.2620E-04	9.2398E-05	7.7876E-04
3	7.0566E-06	1.3624E-05	8.6770E-06
4	1.4777E-05	8.1087E-05	1.9152E-04
5	1.0116E-04	9.7544E-05	5.7761E-05
6	9.5706E-05	1.1205E-04	7.4569E-04
7	1.2999E-05	3.8176E-05	9.2523E-05
8	3.1364E-04	3.1125E-05	1.7814E-04
9	7.7183E-05	1.1309E-04	8.4908E-04
10	4.0855E-04	1.4037E-04	7.4734E-04
11	8.3479E-05	1.0117E-04	4.1118E-04
12	1.1731E-04	7.8703E-05	5.9412E-04
13	1.8165E-04	1.9318E-04	4.5523E-04
14	1.3659E-05	7.9709E-05	4.2086E-04
15	1.4791E-04	1.6220E-04	6.4717E-04

Tabla B.86. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con M

M	MSE (m ²)		
	nº neuronas	entrenamiento	verificación
1	2.5008E-04	5.2788E-05	2.1573E-05
2	2.2802E-05	5.1491E-05	5.3570E-05
3	3.9126E-05	6.5148E-05	4.2863E-06
4	3.4758E-05	5.9047E-05	9.7129E-04
5	4.1488E-05	3.0965E-05	6.3178E-05
6	1.1902E-04	8.5006E-05	1.1908E-03
7	4.4751E-04	7.1835E-05	1.1957E-04
8	3.8710E-04	4.6826E-05	1.8755E-04
9	4.2044E-05	5.0920E-05	2.5614E-05
10	7.3191E-05	7.3952E-05	1.7281E-03
11	5.9492E-05	6.6904E-05	1.2822E-03
12	3.8274E-05	6.3087E-05	2.6069E-05
13	1.1637E-04	1.2214E-04	1.0729E-04
14	9.1644E-05	1.0213E-04	2.4011E-03
15	1.7346E-04	1.8850E-04	7.0411E-05

Tabla B.87. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con O

O	MSE (m ²)		
	nº neuronas	entrenamiento	verificación
1	1.5926E-04	5.1734E-05	6.7148E-05
2	8.1375E-05	4.0176E-05	7.7130E-05
3	1.4341E-05	1.9440E-05	1.4390E-05
4	7.8322E-06	1.1606E-05	3.6230E-06
5	7.8727E-06	4.2470E-06	3.5702E-06
6	2.9851E-05	6.1427E-05	4.7613E-05
7	2.4909E-04	2.3196E-05	8.2444E-05
8	7.5148E-05	3.0868E-05	1.0547E-05
9	1.4452E-04	7.1156E-05	7.3650E-05
10	1.4092E-04	2.4489E-05	3.0129E-04
11	8.5495E-06	7.4104E-05	1.3730E-05
12	8.5408E-06	3.8401E-05	3.3171E-05
13	1.8196E-04	1.4255E-04	1.4632E-04
14	2.6454E-04	2.7343E-05	3.2175E-04
15	5.9743E-05	1.0593E-04	1.3062E-04

Tabla B.88. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con NBH y test con P

P	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	8.9496E-05	6.6124E-05	1.0802E-04
2	8.5231E-06	1.3757E-05	3.8855E-06
3	1.0921E-05	2.7399E-05	3.7182E-06
4	3.0550E-04	9.4326E-05	3.5910E-04
5	3.2288E-05	5.6575E-05	3.8268E-05
6	5.6707E-06	5.8610E-05	9.7875E-06
7	1.3637E-04	2.8652E-05	1.9522E-04
8	1.6175E-04	7.5358E-05	2.7759E-04
9	6.8949E-05	6.3817E-05	4.4278E-05
10	5.4476E-05	9.2811E-05	5.1299E-05
11	1.3128E-04	5.1694E-05	3.1096E-05
12	8.8523E-05	6.8657E-05	1.4144E-04
13	5.0853E-04	1.4981E-04	7.2804E-05
14	9.1609E-05	8.9497E-05	6.6020E-05
15	6.3515E-05	4.6012E-05	1.6468E-04

Tabla B.89. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con C

C	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	1.1384E-04	1.3219E-04	6.8966E-06
2	7.1079E-06	3.5136E-05	2.0762E-05
3	2.8488E-05	8.4073E-05	1.6687E-04
4	4.0897E-05	1.1163E-04	2.4031E-04
5	5.6979E-06	6.8898E-05	3.3612E-04
6	7.7002E-05	6.5679E-05	2.0923E-05
7	1.9779E-05	3.5849E-05	4.0842E-06
8	1.2274E-05	4.3150E-05	4.3655E-05
9	2.5323E-05	1.0054E-04	1.2127E-04
10	1.8265E-05	1.0722E-04	3.8329E-04
11	5.0723E-06	4.8803E-05	2.8240E-06
12	4.0960E-05	9.2311E-05	2.3449E-04
13	5.3314E-05	9.0083E-05	6.0232E-05
14	3.4536E-05	9.7411E-05	1.8324E-04
15	1.6688E-05	5.6033E-05	7.0819E-05

Tabla B.90. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con D

D	MSE (m ²)		
	entrenamiento	verificación	test
1	2.5441E-05	1.3129E-04	9.1339E-05
2	4.9521E-06	4.5276E-05	5.0680E-05
3	1.0621E-05	1.0402E-04	1.1075E-04
4	2.8186E-05	8.0252E-05	8.9278E-05
5	1.4756E-05	6.9648E-05	5.6885E-05
6	5.5476E-05	8.9684E-05	8.1205E-05
7	3.5394E-05	1.2268E-04	1.4831E-04
8	1.9544E-05	1.3190E-04	1.3300E-04
9	2.9969E-04	5.3635E-05	1.7261E-04
10	6.7749E-05	1.7163E-04	3.9333E-04
11	8.0740E-05	1.1758E-04	1.8455E-04
12	3.1150E-05	7.9570E-05	8.5779E-05
13	1.1540E-05	1.0886E-04	2.3183E-04
14	2.0859E-05	1.2473E-04	1.5013E-04
15	4.2120E-05	9.9605E-05	1.4555E-04

Tabla B.91. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con F

F	MSE (m ²)		
	entrenamiento	verificación	test
1	3.2216E-05	1.1138E-04	8.9635E-06
2	2.4573E-05	6.3757E-05	1.1909E-04
3	1.7639E-04	2.4926E-04	8.5448E-05
4	2.8196E-05	9.9839E-05	1.8393E-05
5	2.8316E-05	1.0108E-04	9.0047E-04
6	3.4454E-05	1.0135E-04	2.5180E-04
7	1.2803E-06	4.7875E-05	2.0843E-03
8	5.0118E-05	6.4318E-05	1.7011E-04
9	2.6688E-05	4.3923E-05	3.3906E-05
10	3.2637E-05	9.2164E-05	1.5342E-03
11	8.9381E-06	2.6597E-05	3.2461E-05
12	6.0437E-05	9.7707E-05	1.2463E-03
13	1.1676E-05	1.0003E-04	5.3596E-04
14	6.3859E-05	6.5175E-05	1.3115E-01
15	5.6982E-05	5.7146E-05	1.5425E-04

Tabla B.92. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con G

G	MSE (m ²)		
	entrenamiento	verificación	test
1	3.5546E-05	1.0538E-04	1.6139E-05
2	3.0610E-05	4.1683E-05	3.0582E-04
3	8.6902E-06	2.7702E-05	3.8072E-06
4	1.0434E-05	3.6221E-05	2.6150E-04
5	2.2022E-04	1.1017E-04	5.5635E-04
6	4.6099E-05	6.8146E-05	2.9121E-05
7	5.5924E-05	8.3498E-05	7.4365E-05
8	2.2771E-05	6.2730E-05	4.9573E-05
9	2.5240E-05	6.6569E-05	2.4415E-03
10	7.0968E-06	1.0146E-04	4.4642E-05
11	3.9539E-05	9.2570E-05	2.0617E-03
12	3.3309E-05	1.1916E-04	6.5693E-05
13	1.9296E-05	7.3898E-05	1.5521E-05
14	1.5646E-04	6.6717E-05	5.4380E-05
15	3.7520E-04	2.7574E-04	3.7193E-03

Tabla B.93. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con H

H	MSE (m ²)		
	entrenamiento	verificación	test
1	6.0281E-05	1.0736E-04	2.1074E-05
2	8.9039E-06	3.6646E-05	6.8553E-06
3	1.9916E-05	7.8711E-05	2.4497E-04
4	4.0274E-05	1.2075E-04	6.0811E-04
5	2.2634E-05	3.0664E-05	5.7919E-04
6	4.2575E-05	1.0589E-04	1.0223E-04
7	7.2482E-06	5.3790E-05	2.6235E-04
8	2.8527E-05	6.2109E-05	3.6483E-05
9	9.5082E-06	5.1950E-05	6.7829E-05
10	5.6406E-05	4.7791E-05	7.5274E-05
11	1.0342E-05	4.7738E-05	6.6938E-04
12	8.1985E-06	3.3286E-05	1.1434E-04
13	3.2584E-05	7.8519E-05	1.9425E-03
14	2.8076E-04	4.1593E-05	5.2448E-04
15	2.0295E-05	6.7750E-05	1.1552E-04

Tabla B.94. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con I

I	MSE (m ²)		
	entrenamiento	verificación	test
1	3.2969E-05	8.5320E-05	1.4318E-05
2	3.4878E-05	1.0730E-04	1.4165E-05
3	6.7644E-06	3.5117E-05	7.7629E-06
4	1.5641E-05	6.3348E-05	1.1695E-05
5	2.6184E-05	3.4853E-05	2.2872E-05
6	1.7722E-05	5.2031E-05	2.8350E-05
7	4.7379E-05	9.1031E-05	1.2820E-05
8	1.1862E-05	3.9699E-05	1.0685E-04
9	5.3893E-05	8.8214E-05	1.4814E-05
10	3.9005E-05	3.4665E-05	4.8520E-05
11	1.6140E-04	5.5788E-05	1.4321E-04
12	1.9290E-05	5.8166E-05	1.5915E-05
13	4.5540E-04	2.4210E-05	1.0854E-04
14	2.4216E-05	7.1038E-05	9.5682E-05
15	2.4392E-05	6.0331E-05	3.1071E-05

Tabla B.95. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con L

L	MSE (m ²)		
	entrenamiento	verificación	test
1	2.1241E-05	6.6499E-05	3.5980E-04
2	8.3596E-06	3.4022E-05	1.2889E-04
3	2.0146E-05	4.0228E-05	5.7492E-03
4	1.2363E-05	1.6668E-05	2.6764E-04
5	1.1911E-05	2.2033E-05	6.4796E-04
6	1.1893E-04	7.3261E-05	4.8625E-04
7	3.5991E-04	2.5812E-05	3.5153E-03
8	1.3113E-05	2.1215E-05	5.4128E-03
9	3.1371E-05	5.6548E-05	1.2513E-04
10	1.6395E-05	6.3446E-05	2.6470E-04
11	3.6046E-05	4.8702E-05	8.7090E-04
12	3.2229E-05	5.6946E-05	4.4503E-03
13	3.2450E-05	7.4434E-05	3.5557E-04
14	1.4678E-04	6.2850E-05	1.6987E-04
15	2.0233E-06	9.2740E-05	1.5344E-04

Tabla B.96. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con M

M	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	2.8670E-05	7.9465E-05	5.4875E-05
2	2.9190E-05	5.6695E-05	5.5460E-05
3	7.9685E-06	1.8700E-05	8.3072E-06
4	4.5051E-06	2.0247E-05	5.8232E-06
5	2.9951E-04	2.2961E-05	5.8507E-05
6	7.5410E-05	5.7663E-05	2.1061E-04
7	4.6678E-05	4.4266E-05	1.2752E-04
8	6.3487E-05	1.3431E-04	2.2075E-04
9	1.9428E-05	5.5462E-05	7.6362E-05
10	2.0763E-05	3.2446E-05	3.7081E-06
11	4.1626E-05	6.9345E-05	1.8217E-04
12	4.1801E-05	8.9684E-05	4.9027E-04
13	3.5261E-05	1.0361E-04	4.0517E-05
14	5.4461E-04	5.4762E-05	1.7731E-04
15	2.3739E-05	5.7610E-05	2.1455E-04

Tabla B.97. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con N

N	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	4.9447E-05	6.4710E-05	1.5441E-04
2	2.4383E-05	3.1899E-05	1.2276E-04
3	5.8811E-05	5.9728E-05	2.5820E-05
4	1.6024E-05	4.6945E-05	9.4571E-05
5	2.2210E-05	1.1279E-04	9.1660E-05
6	1.0151E-05	4.8149E-05	1.1725E-02
7	2.5176E-05	6.4066E-05	3.2140E-05
8	2.3690E-05	3.1843E-05	1.9231E-04
9	2.9736E-05	8.9392E-05	1.3188E-04
10	1.8842E-05	4.6437E-05	4.6611E-04
11	2.2520E-05	4.5037E-05	8.7601E-05
12	4.4126E-05	6.0399E-05	4.0914E-04
13	2.4198E-05	5.8989E-05	3.0376E-04
14	7.5056E-03	9.9056E-05	1.2234E-02
15	2.2216E-04	1.3358E-04	7.1063E-04

Tabla B.98. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con O

O	MSE (m ²)		
	entrenamiento	verificación	test
1	3.1153E-05	1.1267E-04	6.4193E-06
2	3.1625E-05	5.2265E-05	5.1344E-05
3	9.1255E-05	1.1612E-04	1.5109E-04
4	3.6735E-05	8.3187E-05	5.3104E-05
5	2.2337E-04	2.4869E-05	1.5940E-05
6	1.1719E-04	1.2494E-04	1.1693E-04
7	1.0077E-04	1.1953E-04	4.2737E-05
8	7.0664E-05	8.7479E-05	4.3006E-05
9	5.7282E-05	8.9958E-05	6.3010E-04
10	7.1102E-05	6.8497E-05	1.6163E-04
11	2.6643E-04	9.2454E-05	1.2179E-03
12	4.3757E-05	4.8390E-05	6.0060E-04
13	3.8976E-05	7.7614E-05	5.9791E-04
14	6.4358E-05	1.0632E-04	4.2769E-04
15	2.0191E-05	1.1873E-04	2.7526E-04

Tabla B.99. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con ABE y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	2.9691E-05	1.1260E-04	2.5086E-05
2	8.0295E-06	4.2554E-05	5.8760E-06
3	8.8886E-06	1.6112E-05	2.0817E-05
4	3.3581E-06	2.9841E-05	4.2977E-06
5	2.4294E-06	2.0081E-05	1.8846E-05
6	1.8415E-05	4.9177E-05	5.9552E-06
7	1.3511E-04	9.3397E-05	5.0937E-04
8	2.7110E-05	9.4090E-05	2.5201E-05
9	2.8526E-05	7.0948E-05	2.2287E-05
10	4.1671E-05	5.4562E-05	3.3384E-05
11	2.4162E-05	5.5029E-05	1.5110E-05
12	1.9205E-05	6.9305E-05	2.7659E-05
13	5.4461E-05	1.1742E-04	6.2660E-05
14	1.3473E-05	4.5586E-05	2.1962E-06
15	1.8285E-05	6.2237E-05	1.7636E-05

Tabla B.100. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con ABE y test con Q

Q	MSE (m ²)		
	entrenamiento	verificación	test
1	4.7582E-05	5.9440E-05	1.7886E-04
2	1.2004E-05	4.3833E-05	5.3821E-04
3	2.1807E-05	6.8731E-05	3.7064E-01
4	1.3923E-05	4.1708E-05	5.6833E-03
5	1.6050E-05	3.4258E-05	5.2472E-05
6	4.2225E-06	1.9011E-05	4.8463E-04
7	2.1830E-05	5.4953E-05	5.1967E-03
8	5.9275E-04	5.9358E-05	1.0704E-02
9	2.4143E-05	5.4767E-05	1.2016E-03
10	2.9301E-05	5.9341E-05	1.0573E-04
11	3.7598E-05	5.3485E-05	3.8473E-03
12	2.0532E-05	6.2158E-05	1.6410E-04
13	2.1186E-05	6.9797E-05	3.3172E-03
14	1.0273E-05	3.1455E-05	2.5065E-03
15	2.2332E-05	9.8034E-05	2.0928E-04

Tabla B.101. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con C

C	MSE (m ²)		
	entrenamiento	verificación	test
1	5.7433E-05	6.1912E-05	2.2034E-05
2	8.4307E-06	3.7099E-05	9.7655E-06
3	5.6753E-06	5.4075E-05	3.0159E-05
4	5.3868E-05	1.1051E-04	4.3247E-05
5	5.0800E-06	6.2630E-05	4.9672E-05
6	1.7243E-05	4.2518E-05	1.0959E-04
7	2.3241E-05	8.3548E-05	9.2243E-05
8	6.7772E-06	4.9371E-05	5.1562E-06
9	4.5614E-05	1.0027E-04	2.9077E-04
10	3.6383E-05	6.7376E-05	1.5734E-04
11	5.0316E-05	1.1414E-04	8.5303E-05
12	1.0294E-05	8.6964E-05	5.8434E-04
13	2.4397E-05	9.6271E-05	6.8735E-04
14	5.1058E-05	1.6252E-04	3.4853E-05
15	3.4345E-05	7.3307E-05	1.6166E-04

Tabla B.102. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con D

D	MSE (m ²)		
	entrenamiento	verificación	test
1	5.7609E-05	9.3911E-05	8.6366E-05
2	3.9084E-06	2.0037E-05	5.4903E-05
3	4.5414E-06	2.5234E-05	2.4874E-05
4	1.0701E-05	6.8737E-05	7.5085E-05
5	6.8616E-06	3.5242E-05	2.9863E-05
6	1.2878E-05	6.3904E-05	1.6544E-04
7	3.9003E-06	1.3539E-04	8.9355E-05
8	6.6725E-06	3.8014E-05	8.6285E-05
9	1.4970E-05	5.8669E-05	1.0118E-04
10	6.3844E-05	1.8912E-04	1.6469E-04
11	1.0706E-05	8.6932E-05	2.4269E-04
12	1.8423E-04	1.2530E-04	1.1296E-04
13	9.6389E-05	1.6200E-04	1.2391E-04
14	5.7842E-05	7.6840E-05	1.6700E-04
15	1.6438E-05	9.9055E-05	1.4794E-04

Tabla B.103. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con F

F	MSE (m ²)		
	entrenamiento	verificación	Test
1	3.7327E-05	5.3982E-05	7.5399E-05
2	9.1037E-06	4.2095E-05	3.6350E-05
3	7.9657E-05	6.8475E-05	1.8296E-04
4	1.2745E-05	8.5203E-05	5.4783E-04
5	2.3621E-05	9.5057E-05	2.4149E-05
6	4.1457E-06	2.6556E-05	3.5974E-04
7	4.9626E-05	5.4128E-05	4.0179E-03
8	1.1605E-05	2.9716E-05	1.4462E-03
9	5.4618E-05	6.0475E-05	1.4959E-04
10	6.9347E-05	5.6866E-05	5.4939E-04
11	3.5810E-05	5.6163E-05	4.5432E-03
12	3.4301E-05	5.1145E-05	2.9797E-04
13	2.7359E-05	9.0758E-05	3.0499E-03
14	2.6429E-05	8.4903E-05	1.8189E-04
15	2.6504E-05	1.9489E-04	1.7288E-04

Tabla B.104. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con G

G	MSE (m ²)		
	entrenamiento	verificación	test
1	4.0263E-05	7.9930E-05	1.3235E-05
2	8.9181E-06	3.6794E-05	5.0074E-06
3	5.1852E-06	2.9817E-05	7.2440E-06
4	1.7801E-05	4.5586E-05	1.4628E-05
5	1.4887E-04	3.2385E-05	2.4852E-04
6	3.4288E-06	6.8286E-05	1.0579E-03
7	2.1403E-05	4.0501E-05	3.3050E-05
8	3.1338E-05	5.4632E-05	4.4488E-04
9	1.6223E-04	6.3252E-05	8.5166E-05
10	4.9794E-05	1.0815E-04	4.7893E-04
11	2.0956E-05	3.0658E-05	2.5577E-03
12	2.0047E-04	5.0114E-05	1.3912E-03
13	3.7261E-05	1.2747E-04	3.7075E-04
14	1.8288E-05	5.2963E-05	7.6551E-05
15	6.1714E-05	4.7861E-05	1.2026E-04

Tabla B.105. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con H

H	MSE (m ²)		
	entrenamiento	verificación	test
1	5.8418E-05	6.7745E-05	5.0750E-05
2	8.3727E-06	4.0103E-05	6.6444E-06
3	3.6183E-06	4.3263E-05	1.0113E-04
4	5.5450E-06	2.3343E-05	2.6685E-04
5	1.2387E-05	5.6837E-05	8.8279E-05
6	2.6999E-05	6.5785E-05	2.4981E-04
7	3.1254E-05	5.6080E-05	2.4636E-05
8	1.4847E-05	5.1511E-05	1.5577E-05
9	3.8986E-05	6.2427E-05	2.5670E-05
10	1.0338E-05	7.3999E-05	1.0216E-05
11	5.2781E-05	1.4673E-04	6.6397E-03
12	4.5716E-05	1.4377E-04	1.8949E-04
13	3.1988E-05	5.5904E-05	6.1456E-04
14	3.0241E-04	6.5292E-05	4.9427E-04
15	2.1962E-06	6.0010E-05	1.0405E-05

Tabla B.106. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con I

I	MSE (m ²)		
	entrenamiento	verificación	test
1	5.6780E-05	5.9929E-05	3.4312E-05
2	3.0895E-05	5.6179E-05	1.0060E-05
3	2.8172E-06	2.6363E-05	3.5496E-05
4	4.6094E-06	1.4877E-05	1.4546E-04
5	5.7709E-06	3.0873E-05	8.9086E-06
6	1.2427E-05	5.2575E-05	1.8430E-05
7	1.5952E-04	1.0226E-04	2.7906E-04
8	2.4918E-05	5.6040E-05	4.0724E-05
9	5.9578E-05	8.8264E-05	1.7264E-04
10	1.9847E-05	5.8885E-05	1.1110E-04
11	6.9777E-05	1.0040E-04	4.2267E-05
12	4.7556E-05	4.3848E-05	9.3844E-05
13	2.6272E-04	4.0547E-05	1.7010E-04
14	5.3308E-05	7.0947E-05	7.3712E-05
15	2.0323E-04	1.4444E-04	1.5139E-04

Tabla B.107. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con L

L	MSE (m ²)		
	entrenamiento	verificación	test
1	2.5898E-05	4.7224E-05	7.2682E-04
2	8.9871E-06	3.2098E-05	2.1811E-05
3	1.0004E-05	4.0148E-05	2.0233E-05
4	8.6324E-06	3.0921E-05	4.4224E-05
5	4.6803E-05	5.3314E-05	9.4429E-05
6	2.6644E-04	7.7309E-05	4.1124E-03
7	6.6718E-05	7.3861E-05	1.0789E-04
8	1.5800E-05	5.0272E-05	6.2007E-04
9	3.1834E-05	1.0826E-04	1.0947E-04
10	4.5896E-05	1.1692E-04	1.9432E-04
11	4.6372E-06	2.3418E-05	1.6500E-04
12	2.7119E-05	7.0646E-05	3.2302E-04
13	4.2610E-05	3.2924E-05	2.7651E-03
14	1.1957E-05	1.6499E-04	5.2028E-04
15	1.6214E-05	6.0700E-05	3.9292E-03

Tabla B.108. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con M

M	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	4.7235E-05	5.2908E-05	5.2820E-05
2	2.4045E-05	4.4131E-05	2.1877E-05
3	7.3712E-06	3.9164E-05	3.5559E-06
4	1.3739E-05	4.8752E-05	3.8223E-05
5	7.5509E-06	3.4002E-05	7.7041E-06
6	3.1720E-05	9.5654E-05	7.1409E-05
7	7.6831E-05	3.7221E-05	8.2583E-05
8	7.6386E-05	8.6557E-05	1.1320E-04
9	3.2998E-05	5.5590E-05	4.7888E-05
10	2.0727E-05	1.0290E-04	1.0759E-03
11	8.1897E-05	6.0787E-05	6.4410E-04
12	2.3760E-05	5.6040E-05	1.0270E-03
13	3.7170E-04	1.4059E-04	2.1830E-03
14	3.1005E-05	5.7448E-05	7.0557E-05
15	3.3689E-05	8.0399E-05	2.5360E-04

Tabla B.109. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con N

N	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	2.6637E-05	6.3663E-05	2.1509E-04
2	5.7456E-06	3.0011E-05	3.3670E-05
3	2.7352E-06	2.4300E-05	6.0254E-06
4	1.3401E-05	3.6803E-05	1.3605E-05
5	2.2381E-05	6.3307E-05	1.4777E-02
6	1.4628E-05	5.0180E-05	3.9429E-05
7	5.6391E-06	2.7918E-05	8.3487E-05
8	2.1465E-05	5.6058E-05	5.8534E-05
9	1.6661E-05	9.0966E-05	1.6530E-03
10	7.8650E-05	1.2115E-04	1.8634E-04
11	1.5012E-05	9.4021E-05	1.4873E-04
12	1.4820E-05	5.1942E-05	8.9090E-04
13	5.4955E-05	7.8584E-05	9.4100E-05
14	5.4800E-05	1.1891E-04	3.5833E-04
15	3.9675E-05	1.4887E-04	6.0606E-04

Tabla B.110. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con O

O	MSE (m ²)		
	entrenamiento	verificación	test
1	4.6457E-05	4.9554E-05	9.2138E-06
2	4.5672E-06	2.8638E-05	3.5824E-06
3	2.2328E-05	4.8596E-05	5.2234E-05
4	2.0090E-06	2.4259E-05	7.0714E-07
5	3.7811E-05	8.0540E-05	1.2570E-04
6	1.2236E-05	4.3773E-05	4.8392E-05
7	9.2783E-05	2.4099E-04	1.1139E-04
8	5.0412E-06	9.6068E-05	1.4536E-04
9	2.5800E-06	4.6449E-05	1.4757E-03
10	8.8272E-05	6.5577E-05	5.8332E-05
11	2.0067E-05	7.7848E-05	3.7405E-05
12	5.3440E-05	8.7719E-05	7.5533E-05
13	1.7021E-05	9.6763E-05	2.4814E-04
14	1.7696E-05	5.2590E-05	5.0401E-05
15	6.0753E-05	1.1075E-04	1.0305E-05

Tabla B.111. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con ABE y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	6.2804E-05	7.6883E-05	1.6816E-05
2	4.3670E-06	3.0036E-05	7.1823E-06
3	1.2305E-05	3.4982E-05	2.5892E-06
4	1.6492E-05	6.5672E-05	2.1779E-05
5	3.5184E-05	7.2915E-05	2.6821E-05
6	7.1514E-05	1.2814E-04	4.8332E-05
7	1.2027E-05	7.2744E-05	6.4559E-06
8	1.4604E-05	6.0490E-05	2.8323E-06
9	2.9213E-05	7.2868E-05	7.4789E-05
10	8.0181E-05	1.3873E-04	5.7651E-05
11	5.3417E-05	9.4529E-05	1.6924E-04
12	1.9761E-05	7.8962E-05	8.9293E-05
13	4.1070E-05	1.2312E-04	3.1451E-05
14	4.5420E-05	4.4701E-05	1.9012E-05
15	1.2938E-05	7.6227E-05	1.1317E-05

Tabla B.112. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con A

A	MSE (m ²)		
	entrenamiento	verificación	test
1	6.4681E-05	1.2317E-04	1.6537E-06
2	5.9539E-06	3.7402E-05	1.5817E-06
3	4.1350E-06	5.4679E-05	3.3315E-06
4	4.7136E-05	6.9788E-05	1.3779E-04
5	4.3985E-04	8.9933E-05	1.5517E-05
6	7.6169E-05	1.4490E-04	1.0909E-04
7	6.0037E-05	1.5035E-04	8.4050E-05
8	7.1875E-06	7.7576E-05	2.8583E-04
9	9.7899E-06	1.4651E-04	6.7900E-04
10	1.3488E-04	1.4116E-04	2.6212E-04
11	1.3547E-04	1.9501E-04	2.0052E-05
12	2.8270E-05	8.7948E-05	1.0650E-04
13	2.4152E-04	1.2714E-04	1.6980E-03
14	2.3232E-05	1.2469E-04	6.7968E-04
15	2.4090E-05	1.4952E-04	5.9475E-04

Tabla B.113. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con F

F	MSE (m ²)		
	entrenamiento	verificación	test
1	7.2445E-05	2.1497E-04	5.0912E-05
2	1.4200E-05	7.9961E-05	1.3905E-04
3	5.2235E-06	3.1444E-05	1.3063E-04
4	6.2577E-06	1.2487E-04	3.0116E-05
5	1.7737E-05	1.0139E-04	3.3138E-06
6	4.9753E-04	7.0911E-05	4.9697E-04
7	4.1023E-05	8.5062E-05	1.6178E-04
8	6.9331E-04	1.0165E-04	2.8364E-03
9	2.5175E-05	1.0301E-04	7.7195E-04
10	6.3027E-06	2.0052E-04	8.4271E-04
11	4.7727E-05	1.6110E-04	2.3695E-05
12	1.0149E-04	1.3937E-04	5.9779E-03
13	3.8613E-05	1.4592E-04	3.5867E-03
14	2.3524E-05	7.5725E-05	7.3985E-03
15	2.5489E-04	1.2571E-04	7.3977E-04

Tabla B.114. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con G

G	MSE (m ²)		
	entrenamiento	verificación	test
1	4.1510E-05	2.2141E-04	6.4049E-06
2	6.1841E-05	1.7278E-04	1.4255E-04
3	5.2331E-05	9.3610E-05	2.0923E-05
4	3.9321E-06	1.2878E-04	2.8499E-05
5	3.9335E-05	5.2038E-05	3.8299E-04
6	2.3125E-04	1.9446E-04	5.1151E-06
7	2.5460E-05	9.3931E-05	1.1574E-06
8	1.6651E-05	9.1323E-05	1.1040E-03
9	2.4634E-05	1.0109E-04	4.4808E-05
10	1.9190E-05	1.3588E-04	9.7720E-04
11	2.2675E-05	1.3110E-04	1.6521E-03
12	6.1322E-04	1.1742E-04	3.1244E-02
13	1.4736E-03	1.6700E-04	2.3606E-02
14	1.3206E-05	1.2024E-04	1.0956E-03
15	2.5781E-04	5.3783E-05	3.4937E-04

Tabla B.115. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con H

H	MSE (m ²)		
	entrenamiento	verificación	test
1	3.3020E-05	1.6930E-04	4.3699E-05
2	4.0585E-06	5.3357E-05	7.7130E-06
3	9.0655E-06	7.3497E-05	3.6192E-05
4	9.5851E-05	2.6972E-04	1.1867E-04
5	1.5008E-05	1.6592E-04	1.0814E-04
6	1.9409E-05	1.8658E-04	7.2414E-05
7	9.8597E-05	1.4171E-04	3.1041E-04
8	3.1508E-05	1.3437E-04	9.0011E-04
9	2.7592E-04	1.3488E-04	3.8425E-04
10	9.0688E-07	1.1355E-04	5.4783E-04
11	1.5143E-05	6.1795E-05	2.7969E-05
12	6.7906E-06	1.0256E-04	2.2869E-04
13	3.3430E-05	8.4179E-05	3.8774E-04
14	1.9569E-05	1.7062E-04	4.7641E-05
15	3.7945E-06	1.4461E-04	5.5253E-04

Tabla B.116. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con I

I	MSE (m ²)		
	entrenamiento	verificación	test
1	4.1699E-05	2.1881E-04	1.0651E-04
2	8.9705E-05	1.8428E-04	1.0745E-04
3	3.0942E-06	2.7083E-05	5.2987E-06
4	3.9491E-05	8.9748E-05	2.2951E-05
5	6.9752E-05	1.8398E-04	1.6115E-04
6	1.1385E-05	1.3808E-04	3.7405E-05
7	2.2383E-05	1.3059E-04	9.6434E-05
8	3.4030E-05	7.8411E-05	2.1927E-05
9	9.7417E-06	5.7523E-05	9.7630E-06
10	3.9887E-05	1.0942E-04	1.2553E-04
11	3.7083E-05	1.2996E-04	1.0201E-04
12	2.4112E-05	1.0754E-04	6.3372E-05
13	1.4602E-05	1.5999E-04	8.0169E-05
14	3.4489E-05	9.8626E-05	4.2299E-05
15	8.2941E-05	8.1972E-05	2.3269E-05

Tabla B.117. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con L

L	MSE (m ²)		
	entrenamiento	verificación	test
1	2.0852E-05	7.7416E-05	3.2010E-04
2	4.6435E-06	6.1962E-05	1.3786E-04
3	1.4200E-05	7.8434E-05	1.7533E-04
4	9.6205E-06	6.8423E-05	6.0645E-05
5	4.0723E-05	9.5606E-05	3.1880E-04
6	7.0557E-05	1.5775E-04	1.0494E-03
7	1.8815E-05	9.6659E-05	1.0424E-03
8	8.1220E-05	2.9842E-05	3.8561E-04
9	8.1164E-05	1.5797E-04	1.4255E-03
10	6.0206E-05	8.5678E-05	3.8386E-05
11	4.1561E-05	6.4062E-05	5.4483E-04
12	2.0429E-05	1.5163E-04	2.7607E-04
13	6.8494E-05	1.2993E-04	1.5403E-05
14	1.9486E-05	1.0247E-04	1.7357E-04
15	2.5723E-05	1.2777E-04	1.4654E-04

Tabla B.118. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con M

M	MSE (m ²)		
	entrenamiento	verificación	test
1	8.0849E-05	1.9802E-04	5.8389E-05
2	1.3684E-04	1.1789E-04	2.8985E-05
3	3.2470E-06	4.4106E-05	9.0096E-07
4	1.4918E-05	1.7815E-04	1.1268E-04
5	3.1702E-04	1.7013E-04	3.3970E-05
6	2.2498E-06	2.2874E-04	1.0862E-04
7	1.7760E-05	7.1529E-05	1.2623E-04
8	1.0814E-04	1.3239E-04	3.6655E-04
9	4.4701E-05	1.7286E-04	4.6337E-04
10	7.1580E-05	1.2865E-04	1.9239E-04
11	7.1346E-05	1.6406E-04	1.2510E-05
12	4.6187E-05	1.5623E-04	2.5832E-04
13	1.1240E-05	1.7579E-04	2.7274E-04
14	9.1311E-06	1.7881E-04	1.3656E-04
15	1.9589E-04	1.4702E-04	2.9666E-04

Tabla B.119. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con N

N	MSE (m ²)		
	entrenamiento	verificación	test
1	7.7103E-05	1.6649E-04	7.3314E-05
2	5.0148E-06	1.0404E-04	4.4319E-04
3	6.3738E-05	1.5385E-04	4.0666E-05
4	7.6705E-06	6.4263E-05	6.5094E-05
5	9.9756E-04	1.0798E-04	7.0608E-04
6	1.7312E-06	6.8478E-05	1.7923E-04
7	7.2764E-06	9.9516E-05	4.8454E-03
8	1.9530E-06	1.0676E-04	7.5026E-05
9	2.3179E-05	1.3645E-04	2.2790E-04
10	7.3053E-05	1.2389E-04	1.5020E-03
11	1.3312E-05	8.3964E-05	1.2164E-04
12	1.7212E-05	1.3439E-04	5.2805E-03
13	1.6392E-05	6.7543E-05	1.6633E-04
14	5.5646E-05	8.3245E-05	1.9871E-04
15	8.9934E-05	4.7737E-05	5.9582E-05

Tabla B.120. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con O

O	MSE (m ²)		
	entrenamiento	verificación	test
1	4.6636E-05	1.7797E-04	2.5050E-05
2	7.3386E-05	1.6704E-04	1.0864E-04
3	2.0253E-05	7.4855E-05	8.5517E-06
4	1.0047E-04	1.6511E-04	7.3235E-04
5	4.3057E-05	1.1353E-04	9.0336E-04
6	6.7168E-05	1.0049E-04	1.2908E-05
7	4.7759E-05	1.2192E-04	1.3415E-04
8	1.9058E-05	7.4233E-05	2.5712E-04
9	8.7493E-05	1.3328E-04	3.7657E-05
10	2.1783E-05	1.3335E-04	9.6922E-05
11	1.5716E-05	1.3988E-04	1.6068E-03
12	4.0203E-05	1.2124E-04	3.7186E-05
13	4.9847E-05	3.8132E-05	1.4378E-04
14	2.7326E-05	8.3232E-05	7.7156E-05
15	5.4160E-05	1.6452E-04	3.1151E-05

Tabla B. 121. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con BCDE y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	7.1675E-05	2.9290E-04	3.6613E-04
2	8.0301E-05	1.8047E-04	1.3724E-04
3	1.1812E-06	8.2886E-05	2.0133E-05
4	2.0084E-05	5.6107E-05	5.5958E-06
5	6.5653E-05	2.0557E-04	1.4640E-04
6	3.5189E-06	8.4897E-05	3.4083E-06
7	4.4553E-05	1.8655E-04	1.6600E-04
8	5.1950E-05	1.3439E-04	4.0628E-05
9	1.8853E-05	8.0216E-05	3.6687E-05
10	8.6040E-06	1.5500E-04	5.1231E-05
11	7.6174E-05	1.2218E-04	2.8806E-04
12	1.6163E-05	1.3171E-04	8.5510E-05
13	2.0837E-05	5.7573E-05	4.3844E-05
14	4.6692E-05	1.7525E-04	1.0839E-04
15	3.7341E-05	1.9834E-04	5.3508E-05

Tabla B.122. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con BCDE y test con Q

Q	MSE (m ²)		
	entrenamiento	verificación	test
1	5.2611E-05	1.1435E-04	4.9868E-03
2	1.6450E-05	7.6724E-05	1.7013E-02
3	7.8454E-06	5.3774E-05	1.6983E-05
4	7.6091E-06	7.2569E-05	3.2223E-03
5	1.2843E-04	8.6849E-05	4.7483E-06
6	9.5881E-06	7.0275E-05	1.4929E-04
7	2.1882E-05	1.7219E-04	5.5300E-03
8	1.8381E-05	6.4018E-05	5.6771E-03
9	3.0385E-05	7.7382E-05	1.0177E-03
10	6.4194E-05	6.5924E-05	5.2567E-03
11	5.4574E-05	1.5667E-04	1.6996E-04
12	1.6984E-05	9.5469E-05	1.1161E-03
13	5.3316E-05	7.9857E-05	7.6253E-03
14	5.9546E-06	6.9031E-05	1.2726E-03
15	9.5719E-06	2.7936E-04	8.4867E-05

Tabla B.123. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con A

A	MSE (m ²)		
	entrenamiento	verificación	test
1	7.6008E-05	1.5426E-04	9.6399E-05
2	3.9548E-06	5.7219E-05	5.3498E-06
3	4.6773E-05	1.1219E-04	3.4844E-03
4	1.0099E-05	5.6575E-05	2.0379E-05
5	6.0083E-06	4.1411E-05	6.9157E-06
6	1.2890E-04	2.1942E-04	8.6787E-04
7	1.3034E-05	7.0373E-05	1.7086E-04
8	2.5990E-04	6.5171E-05	1.6942E-03
9	1.8388E-05	6.9631E-05	2.5341E-03
10	1.5712E-05	1.1320E-04	3.0669E-03
11	4.3383E-06	8.3091E-05	1.5339E-03
12	9.7532E-05	1.2964E-04	3.9533E-03
13	1.7168E-05	8.8047E-05	1.2793E-03
14	1.2393E-06	7.8343E-05	7.7916E-04
15	2.8462E-05	1.5583E-04	1.6652E-03

Tabla B.124. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con F

F	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	1.2999E-04	2.8851E-04	1.9790E-05
2	7.7194E-05	3.2738E-04	5.1217E-06
3	9.6622E-04	1.6634E-04	4.5332E-03
4	3.7384E-05	9.4638E-05	4.8223E-04
5	1.6754E-05	1.5841E-04	5.2890E-04
6	7.6979E-05	9.0175E-05	2.6257E-03
7	2.7808E-05	1.5522E-04	1.3759E-02
8	2.3851E-05	1.2896E-04	3.6327E-04
9	1.9788E-04	1.0638E-04	8.7740E-04
10	6.8876E-05	1.4584E-04	3.0210E-01
11	3.5248E-05	5.4386E-05	2.4002E-04
12	1.3739E-06	3.6764E-05	2.3015E-03
13	4.6257E-05	1.9473E-04	1.2494E-02
14	1.1970E-05	4.9605E-05	6.5427E-04
15	5.5249E-05	1.2734E-04	7.0921E-04

Tabla B.125. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con H

H	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	6.2726E-05	2.6637E-04	8.0571E-05
2	6.7214E-05	1.4042E-04	3.0643E-04
3	5.0938E-05	1.5380E-04	8.5463E-05
4	1.5214E-04	1.9543E-04	1.6755E-04
5	7.5301E-05	1.8692E-04	1.8777E-04
6	5.9892E-06	6.7457E-05	6.9294E-05
7	5.8287E-05	1.4763E-04	8.5418E-04
8	5.1086E-05	9.0046E-05	1.7696E-04
9	3.3374E-05	9.3564E-05	6.6617E-04
10	5.9996E-05	1.2905E-04	1.4425E-04
11	1.8550E-05	1.8285E-04	5.6610E-05
12	2.4957E-06	9.1337E-05	7.4682E-04
13	9.8903E-05	1.4993E-04	5.9007E-03
14	2.1014E-04	1.2304E-04	1.1647E-04
15	5.3533E-05	3.0357E-04	2.2674E-03

Tabla B.126. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con I

I	MSE (m ²)		
	entrenamiento	verificación	test
1	4.8753E-05	3.1439E-04	7.0970E-05
2	6.3241E-05	2.0091E-04	1.2915E-04
3	4.6916E-05	1.1890E-04	3.8541E-05
4	1.3064E-04	2.5841E-04	2.5409E-04
5	4.7045E-05	1.3628E-04	3.7524E-05
6	4.4276E-06	8.7599E-05	3.1784E-06
7	1.4359E-05	1.1586E-04	7.9153E-05
8	3.7595E-05	1.0148E-04	8.0580E-05
9	1.3347E-04	2.1697E-04	9.9558E-05
10	4.8362E-05	1.3435E-04	1.8435E-05
11	9.1495E-06	1.2908E-04	9.3703E-06
12	4.0136E-06	5.6455E-05	6.4861E-05
13	2.9983E-05	1.4741E-04	1.1379E-04
14	1.7905E-04	1.2965E-04	2.7733E-05
15	8.0190E-05	1.5480E-04	6.1997E-06

Tabla B.127. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con L

L	MSE (m ²)		
	entrenamiento	verificación	test
1	4.1550E-05	1.1618E-04	7.5870E-04
2	9.3523E-06	1.0640E-04	1.0245E-03
3	1.3383E-05	8.9147E-05	2.5293E-04
4	1.3784E-05	6.3599E-05	4.4993E-04
5	3.1552E-05	4.7514E-05	5.0731E-04
6	6.9598E-05	2.1632E-04	5.3681E-04
7	1.9281E-04	9.6313E-05	3.2112E-04
8	4.1616E-05	7.1529E-05	1.2192E-03
9	1.8624E-05	7.8105E-05	5.5889E-04
10	6.1426E-06	7.5429E-05	1.1959E-04
11	3.5911E-05	1.4690E-04	1.2134E-04
12	1.9373E-05	9.1142E-05	2.4580E-04
13	2.5291E-06	9.5034E-05	1.8911E-03
14	9.5353E-05	1.5724E-04	2.6370E-04
15	5.5449E-06	1.1506E-04	1.8549E-04

Tabla B.128. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con M

M	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	1.8659E-04	3.5200E-04	3.4945E-05
2	6.4065E-05	1.2939E-04	5.2904E-05
3	3.5624E-05	1.0557E-04	2.1822E-04
4	4.3286E-06	1.1419E-04	3.6615E-04
5	6.3967E-05	1.4267E-04	3.3483E-05
6	4.8131E-05	2.3792E-04	2.3515E-04
7	1.6400E-05	9.4207E-05	5.5242E-06
8	8.9024E-05	1.2847E-04	4.6301E-05
9	1.0166E-04	2.1324E-04	3.8208E-04
10	1.3585E-04	1.8104E-04	1.1319E-04
11	4.3334E-05	9.4895E-05	1.0730E-04
12	4.0181E-04	1.3076E-04	7.8934E-04
13	7.9953E-05	2.2736E-04	8.3058E-05
14	2.2653E-05	1.3840E-04	1.8887E-04
15	3.2253E-05	1.0896E-04	6.6669E-04

Tabla B.129. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con N

N	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	2.1520E-05	1.8198E-04	7.0783E-05
2	3.2952E-05	6.9514E-05	3.2344E-04
3	3.7228E-06	4.6167E-05	6.6018E-06
4	1.4360E-05	5.9854E-05	5.5456E-04
5	6.2752E-05	2.0689E-04	6.9744E-05
6	1.2657E-04	2.5283E-04	2.2779E-03
7	2.4120E-05	1.5335E-04	3.1553E-04
8	1.6286E-05	1.5084E-04	1.4005E-04
9	2.9090E-05	1.1497E-04	3.1600E-05
10	5.0686E-05	2.1341E-04	2.2172E-04
11	1.6502E-05	1.5594E-04	2.6396E-03
12	1.8654E-04	7.8550E-05	1.0130E-02
13	1.5211E-04	2.3971E-04	8.3645E-04
14	2.4543E-06	1.8218E-04	2.1686E-03
15	5.6107E-06	3.7857E-04	4.7375E-03

Tabla B.130. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con O

O	MSE (m ²)		
	entrenamiento	verificación	test
1	7.7359E-05	2.1882E-04	1.6244E-04
2	7.7436E-05	2.1672E-04	9.2384E-05
3	2.1269E-05	8.1108E-05	6.9043E-05
4	1.4893E-05	1.4033E-04	5.5331E-05
5	3.8519E-06	4.1915E-05	2.5284E-04
6	2.9776E-05	1.1757E-04	3.6971E-04
7	3.4000E-05	9.5852E-05	6.4197E-05
8	1.5859E-05	4.7664E-05	6.9558E-04
9	7.7901E-05	8.3501E-05	1.0759E-04
10	3.9439E-05	7.6021E-05	1.7836E-05
11	1.7030E-05	1.4595E-04	9.7188E-04
12	4.4973E-06	9.4567E-05	7.6661E-05
13	2.2657E-05	1.1583E-04	9.9167E-04
14	3.0518E-05	1.6641E-04	5.3426E-05
15	1.4376E-05	1.3720E-04	1.9620E-03

Tabla B.131. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	4.4587E-05	1.8311E-04	1.7931E-04
2	7.2799E-05	2.3473E-04	2.2310E-04
3	2.8824E-06	9.2881E-05	2.4151E-05
4	1.6076E-05	8.5716E-05	1.6288E-05
5	6.2455E-05	3.9381E-05	2.2803E-05
6	1.1643E-02	1.8746E-04	5.5947E-05
7	3.1427E-06	8.8235E-05	5.3249E-05
8	3.2903E-05	2.1629E-04	6.0054E-05
9	1.6711E-05	1.3317E-04	4.1275E-05
10	3.9820E-04	1.2698E-04	3.8650E-05
11	7.0215E-03	6.9928E-05	1.3684E-04
12	6.1508E-06	7.9666E-05	3.1286E-05
13	2.4763E-05	1.1212E-04	1.4788E-05
14	7.9656E-06	1.5062E-04	2.3025E-05
15	3.8673E-04	1.7117E-04	1.6072E-04

Tabla B.132. Errores de entrenamiento y test de una red excluyendo G del entrenamiento. Verificación con ABE y test con Q

Q	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	6.6241E-05	1.2327E-04	4.4733E-03
2	1.9408E-05	4.9447E-05	9.7389E-03
3	6.8412E-06	3.9371E-05	9.7941E-03
4	2.1158E-05	5.0799E-05	4.8823E-03
5	1.3113E-05	7.0395E-05	5.0816E-03
6	1.5235E-05	5.0465E-05	6.5575E-03
7	3.8257E-05	1.0448E-04	3.4981E-03
8	4.1605E-05	1.0027E-04	1.1795E-04
9	1.0819E-05	1.0869E-04	4.5152E-02
10	1.3459E-05	7.8032E-05	6.2496E-04
11	1.0064E-04	9.9893E-05	1.4992E-03
12	1.8311E-06	6.7489E-05	2.4977E-03
13	1.8438E-05	1.8535E-04	1.8854E-03
14	1.2505E-05	3.2003E-04	3.7991E-04
15	2.7340E-05	9.1184E-05	2.0015E-04

Tabla B.133. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento. Verificación con ABE y test con A

A	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	6.8856E-05	1.0897E-04	4.7614E-05
2	6.7132E-05	1.1137E-04	3.0589E-05
3	1.9510E-04	6.1218E-05	2.7491E-05
4	1.5103E-05	3.1366E-05	9.7630E-07
5	8.2532E-05	1.3602E-04	1.1097E-03
6	2.8317E-06	5.9362E-05	1.2822E-05
7	1.6329E-04	8.2045E-05	1.9612E-05
8	2.4766E-05	7.3255E-05	1.1466E-04
9	4.7827E-05	1.2245E-04	4.0318E-04
10	1.0843E-05	7.8613E-05	7.4301E-06
11	1.2990E-05	1.2995E-04	5.6306E-04
12	1.8858E-05	1.1441E-04	3.3481E-04
13	1.3667E-05	6.8709E-05	7.6638E-05
14	8.8910E-06	1.7969E-04	1.0474E-03
15	2.1036E-06	1.3919E-04	4.1080E-03

Tabla B.134. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento.
Verificación con ABE y test con F

F	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	6.8174E-05	9.6855E-05	1.3332E-04
2	6.5321E-06	5.6955E-05	9.7812E-05
3	4.4393E-06	6.1469E-05	3.4974E-06
4	5.3422E-05	1.3597E-04	2.6584E-04
5	1.8340E-05	4.8870E-05	3.5447E-04
6	1.1972E-04	1.4267E-04	2.1353E-04
7	4.6453E-06	8.9181E-05	1.4566E-02
8	3.4112E-05	6.0118E-05	6.6356E-03
9	5.1302E-05	1.5084E-04	7.7668E-04
10	2.6444E-05	8.1213E-05	9.6885E-03
11	6.8603E-05	8.3277E-05	2.7609E-02
12	8.8425E-06	1.7684E-04	3.5621E-03
13	3.0001E-04	2.3200E-04	1.0544E-03
14	3.6314E-06	1.7299E-04	2.1434E-03
15	1.2109E-04	1.7710E-04	2.3971E-03

Tabla B.135. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento.
Verificación con ABE y test con H

H	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	6.0201E-05	1.4531E-04	2.9525E-04
2	1.2634E-05	6.0271E-05	3.5378E-06
3	8.8874E-06	6.2999E-05	1.8772E-04
4	2.7507E-06	9.5184E-05	3.4553E-04
5	1.8178E-05	1.9414E-04	3.0301E-04
6	6.6860E-05	1.8977E-04	4.0635E-04
7	4.4867E-05	6.0868E-05	5.1463E-05
8	1.2762E-05	1.1764E-04	1.2243E-03
9	8.0151E-05	1.2723E-04	3.0267E-04
10	4.4235E-06	4.6140E-05	1.3709E-06
11	3.3750E-05	5.4539E-05	1.2315E-04
12	2.3500E-03	1.4279E-04	6.7599E-04
13	9.0160E-06	2.0030E-04	1.1259E-04
14	1.9766E-07	1.1064E-04	5.9549E-03
15	3.4468E-04	1.5826E-04	3.8062E-04

Tabla B.136. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento.
Verificación con ABE y test con I

I	MSE (m ²)		
	entrenamiento	verificación	test
1	6.4497E-05	1.0661E-04	1.3847E-05
2	1.8123E-05	5.5617E-05	4.0094E-06
3	1.2430E-05	5.6951E-05	4.3819E-06
4	3.2451E-05	9.6939E-05	3.7175E-05
5	2.3313E-06	4.4022E-05	5.3612E-05
6	2.2051E-05	6.6687E-05	5.2863E-05
7	7.2741E-05	1.6630E-04	1.0383E-04
8	1.4744E-05	1.5994E-04	4.0325E-05
9	9.2675E-06	7.9590E-05	3.4455E-06
10	1.6061E-05	1.3878E-04	6.8578E-05
11	2.2182E-04	1.3012E-04	8.5841E-05
12	1.5772E-05	1.7165E-04	8.9793E-06
13	1.5413E-05	7.4003E-05	5.7539E-05
14	1.3026E-05	1.8837E-04	5.7305E-05
15	9.4937E-06	1.1618E-04	2.3977E-05

Tabla B.137. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento.
Verificación con ABE y test con L

L	MSE (m ²)		
	entrenamiento	verificación	test
1	1.8426E-05	6.5913E-05	5.3657E-04
2	3.1254E-05	6.9722E-05	4.7830E-04
3	4.8776E-06	6.4434E-05	6.4847E-05
4	2.3907E-05	6.5558E-05	2.5006E-04
5	7.1445E-06	6.1645E-05	7.8247E-04
6	1.3390E-05	8.3286E-05	2.2849E-04
7	4.2767E-05	1.0903E-04	1.1326E-03
8	2.4440E-05	6.9082E-05	1.1190E-03
9	3.5926E-05	1.1248E-04	1.1475E-04
10	5.1643E-05	1.3748E-04	8.9456E-04
11	4.9434E-06	6.1169E-05	2.4634E-03
12	5.1863E-05	1.2556E-04	6.0533E-04
13	8.1516E-07	5.1266E-05	2.4194E-04
14	2.0369E-05	8.6904E-05	7.7904E-03
15	1.8685E-05	1.0497E-04	4.6685E-04

Tabla B.138. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento.
Verificación con ABE y test con M

M	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	5.6488E-05	9.4655E-05	5.0903E-05
2	1.4691E-05	4.4090E-05	2.3025E-06
3	3.1025E-05	8.1098E-05	3.7586E-05
4	1.7254E-05	6.1156E-05	2.4796E-04
5	4.1633E-05	1.7509E-04	4.3711E-04
6	2.4448E-04	1.7386E-04	3.0171E-04
7	6.8837E-06	4.1514E-05	5.8673E-06
8	5.5436E-06	1.0249E-04	6.3304E-06
9	4.5345E-05	8.2681E-05	1.9176E-05
10	5.5378E-05	1.8605E-04	1.2077E-04
11	1.5264E-05	9.2956E-05	2.9664E-04
12	3.1599E-06	1.6376E-04	1.8537E-03
13	1.6799E-05	1.7447E-04	3.0986E-04
14	1.0195E-03	1.7382E-04	3.3415E-03
15	7.8765E-05	6.2276E-05	2.2182E-04

Tabla B.139. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento.
Verificación con ABE y test con N

N	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	5.1478E-05	8.3508E-05	2.0676E-04
2	7.3525E-06	5.6757E-05	7.4813E-05
3	3.1253E-05	6.2583E-05	3.3465E-03
4	1.3756E-05	5.8362E-05	1.6699E-05
5	3.7492E-06	1.2839E-04	5.1265E-05
6	7.0000E-06	1.4540E-04	6.0108E-05
7	2.5957E-06	4.5276E-05	3.5872E-05
8	2.5389E-05	7.0804E-05	1.3131E-04
9	1.5900E-04	2.2360E-04	9.6369E-05
10	3.1668E-05	1.7588E-04	3.7622E-03
11	5.3192E-05	1.0024E-04	1.5507E-04
12	4.4459E-05	1.5288E-04	5.8428E-03
13	7.3954E-05	1.9869E-04	6.1564E-03
14	1.2473E-05	1.4370E-04	3.1152E-05
15	1.3748E-04	1.3629E-04	6.8428E-03

Tabla B.140. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento.
Verificación con ABE y test con O

O	MSE (m ²)		
	entrenamiento	verificación	test
1	3.8072E-05	1.6144E-04	6.0252E-05
2	4.2482E-05	5.8143E-05	2.3805E-05
3	1.8721E-05	7.2305E-05	7.1367E-05
4	6.3496E-06	1.1837E-04	7.0074E-05
5	2.7272E-06	5.3368E-05	1.4491E-05
6	1.4575E-04	1.1092E-04	1.2001E-02
7	8.3171E-05	1.5810E-04	2.6871E-04
8	5.2447E-04	1.7550E-04	7.5408E-04
9	2.1079E-05	5.6543E-05	2.8435E-04
10	1.1221E-05	1.1001E-04	2.4783E-05
11	2.1199E-05	1.2086E-04	7.8761E-04
12	3.5409E-04	1.4427E-04	6.2613E-04
13	1.5249E-05	8.1869E-05	4.7425E-05
14	6.4472E-06	1.6680E-04	4.7805E-04
15	1.1029E-04	1.5239E-04	3.9596E-05

Tabla B.141. Errores de entrenamiento y test de una red excluyendo G y Q del entrenamiento.
Verificación con ABE y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	4.7644E-05	1.6682E-04	4.0981E-05
2	1.2166E-05	6.5550E-05	1.0524E-05
3	9.4296E-06	9.4234E-05	2.9139E-05
4	3.3635E-05	1.0480E-04	3.9761E-05
5	7.3896E-05	1.5779E-04	1.7833E-04
6	2.5228E-05	5.3940E-05	2.3484E-05
7	3.9243E-04	1.6675E-04	1.2090E-05
8	1.3133E-04	1.5230E-04	7.4924E-05
9	1.6957E-05	3.3645E-05	2.1597E-05
10	1.1777E-04	5.7055E-05	5.5889E-05
11	1.7115E-05	1.0022E-04	5.6588E-05
12	3.0352E-05	1.3749E-04	2.6597E-04
13	2.5396E-04	9.8203E-05	1.4107E-04
14	1.1388E-05	1.5452E-04	3.8257E-05
15	3.3376E-06	6.0980E-05	1.9000E-05

Tabla B.142. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con A

A	MSE (m ²)		
	entrenamiento	verificación	test
1	7.7159E-05	1.3231E-05	2.5880E-06
2	9.0508E-06	5.4869E-05	9.4946E-06
3	1.1987E-04	1.0433E-04	1.3660E-04
4	1.2066E-04	1.0322E-04	3.5199E-05
5	2.2502E-04	1.1428E-04	1.1407E-04
6	6.8523E-05	7.5676E-05	1.5339E-04
7	3.0021E-05	8.9682E-05	4.2675E-04
8	1.9184E-04	1.3602E-04	4.9360E-05
9	3.2917E-05	4.5075E-05	1.9081E-04
10	3.9350E-05	8.0218E-05	1.4780E-04
11	2.7170E-05	1.5642E-04	1.7662E-03
12	5.7364E-05	1.2941E-04	1.3402E-02
13	1.8383E-04	2.2391E-04	3.2443E-03
14	1.7743E-04	5.4612E-05	2.0696E-04
15	8.3900E-05	1.1375E-04	2.1910E-02

Tabla B.143. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con C

C	MSE (m ²)		
	entrenamiento	verificación	test
1	3.7841E-04	6.2191E-05	2.1369E-05
2	1.2387E-04	2.8149E-05	1.7582E-05
3	1.4513E-04	9.3001E-05	2.2007E-04
4	1.5051E-04	1.1444E-04	3.8877E-05
5	1.0144E-04	8.3501E-05	1.6125E-04
6	2.2110E-04	1.0143E-04	6.4874E-04
7	2.9583E-05	6.0720E-05	1.2470E-04
8	1.0205E-04	9.3635E-05	1.4576E-04
9	5.4954E-05	1.1457E-04	1.0811E-04
10	8.8734E-05	6.4853E-05	7.9963E-05
11	1.3483E-05	1.0093E-04	4.9853E-06
12	1.2051E-04	3.6075E-05	7.3142E-05
13	5.3462E-05	1.3521E-04	6.9911E-05
14	4.6045E-05	4.9400E-05	6.1079E-05
15	6.9353E-05	9.4814E-05	1.2722E-04

Tabla B.144. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con D

D	MSE (m ²)		
	entrenamiento	verificación	test
1	5.6065E-05	2.5702E-05	6.8631E-05
2	1.1466E-04	5.7869E-05	2.4871E-04
3	6.9987E-05	4.7721E-05	2.1171E-04
4	2.4164E-05	1.9169E-05	5.5490E-05
5	5.3404E-06	5.0081E-05	2.9676E-05
6	8.1198E-05	8.0835E-05	1.9522E-04
7	6.4449E-05	3.4826E-05	9.0772E-05
8	4.8315E-05	1.1316E-05	2.7792E-05
9	9.1611E-05	1.1751E-04	2.0804E-04
10	6.8519E-05	8.3145E-05	1.4768E-04
11	6.4308E-05	7.3125E-05	1.3936E-04
12	1.3902E-05	6.5935E-05	6.0222E-05
13	4.9035E-05	6.5616E-05	1.9711E-05
14	1.3985E-05	5.3262E-05	7.0642E-05
15	6.1841E-05	1.1699E-04	7.6165E-05

Tabla B.145. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con E

E	MSE (m ²)		
	entrenamiento	verificación	test
1	3.9863E-05	2.2626E-05	1.6489E-04
2	1.5058E-05	2.3423E-05	1.5678E-04
3	1.8859E-04	1.6276E-04	7.7521E-04
4	9.0154E-05	1.0688E-04	5.1129E-04
5	1.6171E-05	2.2750E-05	2.5802E-04
6	7.5272E-06	2.7672E-05	9.6692E-05
7	1.7483E-05	3.3144E-05	1.6024E-04
8	1.1648E-05	4.3790E-05	3.5768E-05
9	1.4046E-04	3.3213E-05	1.7503E-04
10	7.7268E-05	5.0105E-05	2.6171E-04
11	1.4220E-05	1.1012E-04	2.6095E-04
12	7.5121E-05	6.3172E-05	2.7619E-04
13	5.1343E-05	4.0418E-05	3.8754E-04
14	6.7437E-06	8.9179E-05	1.0457E-04
15	9.2204E-05	7.9436E-05	3.2450E-04

Tabla B.146. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con F

F	MSE (m ²)		
	entrenamiento	verificación	test
1	1.1367E-04	2.1109E-05	2.4598E-06
2	1.3706E-04	5.1484E-05	9.0292E-06
3	4.9795E-05	6.8507E-05	1.7613E-02
4	8.7680E-05	5.5067E-05	9.1722E-04
5	2.5019E-04	1.2428E-04	4.7897E-05
6	2.3894E-04	1.5243E-04	1.0573E-03
7	5.4743E-05	7.7560E-05	1.2287E-01
8	4.1066E-04	1.4009E-04	2.2179E-04
9	1.5409E-04	5.4981E-05	1.8373E-04
10	3.9215E-05	1.3831E-04	8.8734E-04
11	9.2181E-05	1.4637E-04	3.8229E-04
12	1.2847E-04	1.1326E-04	5.0879E-02
13	1.6589E-05	3.5273E-05	4.6222E-02
14	2.1196E-05	1.1156E-04	8.2239E-03
15	1.1006E-04	9.5196E-05	2.4160E-04

Tabla B.147. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con L

L	MSE (m ²)		
	entrenamiento	verificación	test
1	3.3274E-05	2.3800E-05	4.1485E-04
2	3.6231E-05	2.4591E-05	3.9132E-04
3	2.5408E-05	9.0203E-05	1.0936E-03
4	2.5266E-04	9.5846E-05	4.8848E-04
5	4.2060E-05	9.3584E-05	5.6784E-03
6	6.0597E-05	3.2901E-05	2.2859E-04
7	8.1647E-05	1.1519E-04	2.3161E-04
8	9.4938E-05	9.9852E-05	2.7872E-04
9	4.4481E-05	1.0424E-04	2.4115E-04
10	2.2664E-05	5.2133E-05	5.4153E-05
11	3.1250E-05	1.1877E-04	3.9567E-03
12	6.4254E-05	8.2192E-05	3.8944E-04
13	1.0526E-04	9.1346E-05	1.4639E-04
14	1.6729E-04	1.5177E-04	1.1355E-03
15	1.6395E-04	1.3102E-04	4.9033E-04

Tabla B.148. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con M

M	MSE (m ²)		
	entrenamiento	verificación	test
1	8.9817E-05	2.8405E-05	1.1704E-04
2	7.7770E-05	2.5227E-05	1.0187E-04
3	3.2518E-04	1.2608E-04	1.5526E-04
4	2.4809E-04	1.7312E-04	1.7215E-04
5	1.7833E-04	2.5061E-05	1.2165E-04
6	5.2041E-05	9.4859E-05	1.8896E-05
7	3.4294E-05	1.9129E-05	2.0760E-05
8	1.8318E-04	6.1392E-05	1.3939E-04
9	1.2231E-04	9.2040E-05	5.4465E-05
10	5.6887E-05	5.0743E-05	2.7528E-05
11	6.1363E-05	1.3580E-04	4.2691E-06
12	2.5923E-05	9.1408E-05	1.0449E-05
13	2.0244E-04	4.7069E-05	4.8023E-04
14	1.2154E-04	1.6638E-04	2.0148E-04
15	2.5826E-05	9.6139E-05	5.1151E-05

Tabla B.149. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con N

N	MSE (m ²)		
	entrenamiento	verificación	test
1	8.6327E-05	2.4851E-05	1.9108E-04
2	8.2313E-05	3.0562E-05	1.0528E-04
3	1.4519E-04	8.9798E-05	1.4014E-04
4	2.0560E-04	6.5901E-05	2.0570E-05
5	1.6453E-04	7.7822E-05	5.3133E-05
6	8.9803E-05	1.3149E-04	3.1175E-04
7	1.3724E-04	1.1124E-04	1.3544E-04
8	2.6542E-04	7.4425E-05	1.7927E-02
9	9.0148E-05	3.4168E-05	4.5327E-04
10	1.2437E-04	9.4409E-05	5.5048E-05
11	1.0497E-04	1.2966E-04	1.3033E-03
12	9.6620E-06	7.4703E-05	3.3426E-04
13	3.1601E-05	9.3419E-05	5.5669E-03
14	4.0099E-05	6.5642E-05	2.0675E-05
15	5.9284E-05	6.1938E-05	1.1092E-04

Tabla B.150. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con O

O	MSE (m ²)		
	entrenamiento	verificación	test
1	7.2328E-05	2.3589E-05	2.4277E-05
2	1.1533E-04	5.7060E-05	2.8275E-05
3	1.3409E-04	6.9263E-05	5.2014E-05
4	1.1457E-04	9.0963E-05	2.5131E-04
5	7.9132E-05	4.6065E-05	2.3252E-05
6	1.7383E-04	3.7450E-05	5.0024E-04
7	1.7473E-05	5.4741E-05	2.3402E-05
8	5.2996E-05	6.1182E-05	5.0229E-05
9	2.9556E-04	9.2411E-05	4.8689E-04
10	4.2773E-05	4.6311E-05	3.6807E-05
11	1.2434E-04	5.0747E-05	2.5347E-05
12	3.6649E-05	4.2808E-05	9.2819E-04
13	4.4143E-04	1.1055E-04	9.8698E-04
14	1.4873E-04	1.0966E-04	3.1604E-04
15	3.7422E-05	7.2591E-05	1.5288E-04

Tabla B.151. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento.
Verificación con GBHI y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	5.9331E-05	2.2866E-05	2.3860E-05
2	7.4856E-05	1.4325E-05	3.2564E-05
3	7.2385E-05	4.6975E-05	2.6606E-05
4	2.3178E-04	6.5074E-05	7.8550E-05
5	9.6124E-05	1.0500E-04	5.8385E-05
6	3.3294E-04	9.4182E-05	1.9766E-04
7	8.1857E-05	7.5064E-05	6.5487E-05
8	1.7142E-04	1.0666E-04	2.8240E-04
9	4.9117E-05	2.1976E-05	1.7580E-05
10	6.0344E-05	5.0644E-05	4.8691E-05
11	2.8956E-05	4.1569E-05	1.2558E-05
12	4.0615E-05	7.7424E-05	6.6347E-05
13	2.6477E-04	1.2243E-04	5.3688E-05
14	8.8264E-05	6.0677E-05	7.6095E-06
15	5.0229E-05	6.8303E-05	8.7275E-06

Tabla B.152. Errores de entrenamiento y test de una red sin excluir emisores del entrenamiento. Verificación con GBHI y test con Q

Q	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	1.7877E-04	1.4849E-05	8.2752E-03
2	1.3804E-05	1.3153E-05	2.6032E-03
3	1.1661E-05	2.9222E-05	7.8653E-03
4	1.4942E-05	8.2103E-05	6.1582E-03
5	1.8204E-05	3.4181E-05	3.2604E-03
6	2.6329E-05	8.7209E-05	4.7422E-03
7	1.9285E-04	6.9509E-05	1.3482E-04
8	8.6761E-05	1.0603E-04	1.1269E-04
9	6.1145E-05	3.6240E-05	7.9747E-05
10	4.5819E-05	7.4040E-05	8.9240E-04
11	6.7045E-05	1.1331E-04	2.2096E-05
12	6.2110E-05	9.8426E-05	2.1806E-03
13	6.1161E-05	5.7697E-05	4.5942E-04
14	2.1652E-05	1.0244E-04	5.0918E-03
15	5.4459E-05	5.8246E-05	2.5852E-03

Tabla B.153. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con A

A	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	5.6151E-05	2.8364E-05	2.0681E-05
2	6.4120E-05	6.7752E-05	3.5686E-05
3	1.0458E-05	1.0090E-05	1.5327E-05
4	5.0174E-05	1.8601E-05	1.7913E-06
5	7.9264E-05	1.0164E-04	2.4612E-04
6	1.0747E-05	5.7829E-05	9.4683E-07
7	8.9362E-05	5.7529E-05	1.0068E-04
8	6.9888E-05	5.0746E-05	6.8559E-05
9	9.0817E-05	1.5763E-04	1.3599E-03
10	1.3062E-04	8.5485E-05	5.1697E-04
11	1.1154E-05	7.6662E-05	1.8603E-04
12	3.0030E-05	2.2697E-05	1.8304E-04
13	2.2999E-05	1.3712E-04	7.7570E-05
14	4.5593E-05	9.4024E-05	5.3732E-04
15	1.2467E-04	1.1291E-04	7.5515E-04

Tabla B.154. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con C

C	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	6.6360E-05	3.0761E-05	2.1909E-05
2	4.7626E-05	2.2925E-05	7.2606E-06
3	1.8704E-05	2.2570E-05	1.3591E-05
4	1.0680E-04	4.9099E-05	3.7057E-05
5	5.7383E-05	2.9502E-05	4.7530E-05
6	1.9200E-05	1.1995E-04	1.8522E-04
7	9.7426E-05	7.3741E-05	1.5548E-04
8	4.7315E-05	2.0685E-05	2.8200E-05
9	4.5521E-05	4.7075E-05	1.7993E-04
10	2.8390E-04	7.9984E-05	4.1346E-04
11	1.6623E-05	1.4300E-04	2.5301E-04
12	1.1310E-04	1.7513E-04	3.5564E-04
13	1.0216E-04	2.0774E-04	2.7858E-04
14	5.9080E-05	6.0204E-05	6.8085E-05
15	9.0616E-05	9.9341E-05	1.0816E-04

Tabla B.155. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con D

D	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	1.0011E-04	1.7292E-05	1.0953E-04
2	3.4149E-05	1.6521E-05	1.8826E-05
3	8.0128E-05	3.8903E-05	1.1906E-04
4	5.7164E-05	4.9563E-05	4.0492E-05
5	3.9923E-05	1.1632E-05	7.4873E-05
6	1.5931E-04	7.8171E-05	2.5800E-04
7	1.5244E-05	2.4110E-05	1.8873E-05
8	4.5572E-06	5.2101E-05	7.3264E-05
9	6.0368E-06	8.9625E-05	1.2320E-04
10	1.9748E-05	3.5807E-05	7.1093E-05
11	1.1602E-04	2.7733E-05	1.3746E-04
12	1.7918E-04	4.6895E-05	1.8481E-05
13	2.4860E-05	5.5867E-05	1.0088E-04
14	2.7274E-05	1.1325E-04	3.0952E-05
15	1.1758E-04	6.9406E-05	8.8236E-05

Tabla B.156. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con E

E	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	3.6872E-05	2.6840E-05	1.9698E-04
2	1.3623E-05	1.8476E-05	1.3779E-04
3	6.5295E-05	4.6485E-05	1.2432E-04
4	4.1013E-05	2.5609E-05	2.4570E-04
5	1.0239E-04	7.6673E-05	4.0788E-04
6	5.2551E-05	9.2686E-05	5.7568E-05
7	8.6181E-06	2.6279E-05	1.3075E-04
8	5.2457E-05	7.2762E-05	2.4241E-04
9	1.8346E-05	9.5540E-05	5.2769E-05
10	2.9438E-05	1.2535E-04	1.6369E-04
11	1.4588E-05	7.6443E-05	1.5200E-04
12	1.5963E-05	9.4079E-05	8.0377E-05
13	1.0521E-04	7.8429E-05	3.2438E-04
14	1.3932E-05	1.0831E-04	2.2421E-04
15	5.5277E-05	3.8516E-04	2.3617E-04

Tabla B.157. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con F

F	MSE (m ²)		
	n° neuronas	entrenamiento	verificación
1	6.9183E-05	1.5386E-05	1.1644E-04
2	6.6543E-05	1.5162E-05	8.1226E-05
3	6.4672E-05	1.6827E-05	1.2338E-04
4	7.6054E-06	1.3420E-05	6.2207E-06
5	3.0583E-06	5.0603E-05	4.9793E-06
6	5.7883E-05	2.8067E-05	4.9873E-05
7	1.6025E-04	1.4442E-04	7.0682E-04
8	1.1788E-05	3.9735E-05	3.3330E-04
9	3.6735E-05	5.5589E-05	1.3471E-03
10	2.2610E-04	8.9605E-05	6.4886E-04
11	1.1227E-04	1.1179E-04	7.0721E-04
12	4.6406E-05	2.5277E-04	1.6053E-04
13	1.1523E-04	1.2898E-04	6.7340E-05
14	8.9617E-05	6.5146E-05	2.7765E-04
15	1.3390E-04	9.1066E-05	1.7868E-04

Tabla B.158. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con L

L	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	6.6861E-05	3.2188E-05	6.3971E-04
2	2.5473E-05	7.4209E-05	1.1881E-03
3	2.5082E-05	1.2684E-04	5.4268E-04
4	2.8001E-05	9.5192E-05	1.2453E-03
5	1.7860E-04	1.1283E-04	7.7323E-05
6	3.0688E-05	2.4151E-05	1.4566E-04
7	4.5773E-05	8.0588E-05	3.8074E-04
8	1.1056E-04	6.9679E-05	7.4153E-05
9	1.0770E-05	6.5481E-05	3.3127E-06
10	3.4677E-05	1.2052E-04	1.5297E-04
11	7.7481E-05	2.5217E-04	5.1383E-04
12	1.9298E-05	1.8075E-04	2.9960E-03
13	7.8956E-06	2.0366E-04	4.2405E-04
14	1.4189E-05	1.9207E-04	3.0340E-04
15	5.2794E-05	3.2406E-05	3.2885E-03

Tabla B.159. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con M

M	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	9.6594E-05	1.9908E-05	4.2054E-05
2	1.4651E-05	3.5966E-05	1.4513E-04
3	1.0739E-05	2.6157E-05	3.4791E-06
4	4.5196E-05	1.8008E-05	1.1103E-05
5	2.1740E-05	4.7145E-05	1.4132E-05
6	1.3367E-04	1.4624E-04	4.5565E-05
7	8.0274E-05	1.2793E-04	8.7471E-04
8	3.0169E-05	9.7171E-05	1.5468E-03
9	4.5795E-05	1.4646E-04	8.5818E-04
10	1.1962E-05	4.0880E-05	4.3528E-05
11	8.8832E-05	1.2727E-04	7.6129E-05
12	7.5855E-05	1.1022E-04	8.4819E-05
13	8.7209E-05	6.5174E-05	9.9412E-05
14	7.4585E-05	2.1643E-04	1.9029E-04
15	2.4596E-05	2.2228E-05	1.6482E-05

Tabla B.160. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con N

N	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	4.3677E-05	1.6870E-05	2.1143E-04
2	3.0993E-05	2.5351E-05	2.0314E-04
3	1.2613E-05	8.8342E-06	7.1786E-05
4	1.0063E-05	2.8261E-05	5.6133E-05
5	7.3160E-05	4.1179E-05	5.6129E-05
6	4.7445E-05	2.1642E-05	1.3024E-04
7	1.8184E-04	1.1073E-04	4.0392E-04
8	4.7946E-05	8.8338E-05	2.0612E-04
9	4.7905E-05	5.8302E-05	3.2251E-05
10	1.1683E-05	9.1459E-05	1.2123E-05
11	4.5474E-05	7.3560E-05	1.5482E-04
12	3.9569E-04	6.6636E-05	7.1761E-05
13	3.2520E-04	1.3346E-04	1.1231E-04
14	1.0141E-04	1.1106E-04	4.0600E-04
15	8.9807E-05	1.4419E-04	6.4228E-05

Tabla B.161. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con O

O	MSE (m ²)		
n° neuronas	entrenamiento	verificación	test
1	4.6381E-05	2.8655E-05	1.8852E-05
2	3.4040E-05	4.1010E-05	1.0062E-04
3	4.9850E-05	2.9437E-05	2.6662E-05
4	1.7261E-05	1.0105E-05	9.9361E-06
5	1.1188E-04	5.1155E-05	6.5587E-05
6	2.7377E-05	2.5582E-05	9.7801E-06
7	5.0687E-05	7.0452E-05	4.9967E-05
8	1.1913E-04	1.5722E-04	2.4056E-04
9	2.3634E-05	4.7895E-05	7.1125E-05
10	7.2358E-05	8.1353E-05	1.4858E-03
11	8.4304E-04	2.7195E-04	9.1884E-04
12	3.1304E-05	9.2570E-05	5.5772E-05
13	2.8758E-05	1.4634E-04	9.1143E-05
14	8.1791E-07	1.8929E-04	4.0088E-03
15	1.3487E-04	4.6981E-05	8.5339E-05

Tabla B.162. Errores de entrenamiento y test de una red excluyendo Q del entrenamiento. Verificación con GBHI y test con P

P	MSE (m ²)		
	entrenamiento	verificación	test
1	4.7918E-05	2.7765E-05	8.0024E-06
2	1.3124E-05	1.7918E-05	1.9368E-05
3	8.5486E-06	2.3516E-05	1.6751E-05
4	3.2648E-05	3.0277E-05	6.0412E-05
5	8.1768E-05	6.7495E-05	1.0443E-04
6	9.6374E-05	4.2105E-05	1.1058E-04
7	3.0418E-04	1.5054E-04	6.0116E-04
8	7.3439E-05	1.2412E-04	8.5559E-05
9	3.4394E-05	8.5771E-05	2.9572E-05
10	6.2536E-05	1.3350E-04	5.4225E-05
11	3.9454E-05	9.1308E-05	3.5325E-05
12	1.9467E-04	1.5553E-04	2.1880E-04
13	9.3434E-05	1.6758E-04	1.1608E-04
14	7.8655E-05	1.5170E-04	5.1835E-05
15	4.7705E-04	1.8232E-04	6.6421E-04

anejo C

aplicabilidad de un modelo ANN de 4 inputs
para predicción de ET_0

C.1. CÁLCULOS REALIZADOS CON EL NEURAL NETWORKS TOOLBOX DE MATLAB	257
C.1.1. MODELO ANN DE 4 INPUTS	257
C.1.1.1. <i>Indicadores de rendimiento del modelo.</i>	257
C.1.1.2. <i>Predicción del modelo sobre el set de test.</i>	259
C.1.2. MODELO ANN DE 7 INPUTS	261
C.1.2.1. <i>Indicadores de rendimiento del modelo</i>	261
C.1.2.2. <i>Predicción del modelo sobre el set de test</i>	263
C.2. CÁLCULOS REALIZADOS CON MATLAB EDITOR	265
C.2.1. MODELO ANN DE 4 INPUTS	265
C.2.1.1. <i>Selección de arquitectura óptima</i>	265
C.2.1.2. <i>Predicción del modelo ANN de 4 inputs para los sets de test</i>	266
C.2.2. MODELO ANN DE 7 INPUTS	268
C.2.2.1. <i>Selección de arquitectura óptima</i>	268
C.2.2.2. <i>Predicción del modelo sobre el set de test</i>	270

C.1. Cálculos realizados con el *Neural Networks Toolbox* de *Matlab*

Los valores en amarillo corresponden al menor error de validación, mientras que los valores en azul corresponden al menor error medio de test en el exterior.

C.1.1. MODELO ANN DE 4 INPUTS

C.1.1.1. Indicadores de rendimiento del modelo.

Tabla C.1. Errores cuadráticos medios obtenidos con el modelo ANN de 4 inputs en las fases de entrenamiento y test

		MSE (mm/día) ²							
capas ocultas		1				2			
número de neuronas		5	10	15	20	5	10	15	20
Altea	entrenamiento	0.1898	0.1934	0.1868	0.1814	0.1842	0.1879	0.1766	0.1797
	validación cruzada	0.2413	0.2338	0.2455	0.2483	0.2613	0.2375	0.2803	0.2489
	Altea	0.2154	0.2129	0.2243	0.2099	0.2082	0.2124	0.2509	0.2423
	Benavites	0.4027	0.3655	0.4388	0.4553	0.3174	0.6554	0.5374	0.4471
	Campo Arcís	0.9101	0.6253	1.0825	0.6503	0.6441	0.4937	1.2683	1.0213
	Castalla	0.7111	0.6812	0.7787	0.6818	0.7089	0.6223	0.7898	0.8500
	media test exterior	0.6746	0.5573	0.7667	0.5958	0.5568	0.5905	0.8652	0.7728
Benavites	entrenamiento	0.2396	0.2504	0.2202	0.2150	0.2398	0.2105	0.2324	0.2032
	validación cruzada	0.2996	0.2875	0.3004	0.2998	0.3177	0.3161	0.2929	0.3131
	Altea	0.4395	0.3537	0.5442	0.4428	0.5190	0.5466	0.5001	0.4821
	Benavites	0.3373	0.3272	0.3101	0.3148	0.3432	0.3147	0.3327	0.3383
	Campo Arcís	0.8073	0.7448	0.7519	0.7754	0.8350	0.7915	0.7821	0.9213
	Castalla	1.0419	0.9770	1.1739	1.1107	1.1597	1.2403	1.0056	1.2038
	media test exterior	0.7629	0.6918	0.8233	0.7763	0.8379	0.8595	0.7626	0.8691
Campo Arcís	entrenamiento	0.2464	0.2323	0.2319	0.2299	0.2392	0.2321	0.2152	0.2096
	validación cruzada	0.2675	0.2833	0.2882	0.2694	0.2764	0.2756	0.2800	0.2951
	Altea	0.2784	0.2946	0.3687	0.2885	0.3099	0.3789	0.3569	0.4479
	Benavites	0.3406	0.3471	0.3576	0.3760	0.3551	0.3800	0.4096	0.4704
	Campo Arcís	0.3536	0.3509	0.3617	0.3546	0.3630	0.3583	0.3679	0.3650
	Castalla	0.6154	0.7064	0.7264	0.5732	0.6383	0.5924	0.6551	0.7206
	media test exterior	0.4115	0.4494	0.4842	0.4126	0.4344	0.4504	0.4739	0.5463
Castalla	entrenamiento	0.3826	0.3827	0.3763	0.3481	0.3692	0.3527	0.3407	0.3437
	validación cruzada	0.3654	0.3889	0.3732	0.3641	0.3713	0.3866	0.3601	0.3654
	Altea	0.5442	0.4989	0.5384	0.7279	0.5611	0.7151	0.9001	0.7775
	Benavites	0.8991	0.8638	0.8562	0.8642	0.7754	0.4629	0.4882	1.0663
	Campo Arcís	0.4990	0.5437	0.4767	0.4354	1.1519	0.3922	0.5244	0.4763
	Castalla	0.4157	0.4229	0.3970	0.3913	0.3910	0.3712	0.3882	0.3887
	media test exterior	0.6474	0.6355	0.6238	0.6758	0.8295	0.5234	0.6376	0.7734

Tabla C.2. Performance index obtenidos con el modelo ANN de 4 inputs en las fases de entrenamiento y test

		c (-)							
capas ocultas		1				2			
número de neuronas		5	10	15	20	5	10	15	20
Altea	entrenamiento	0.9497	0.9487	0.9504	0.9520	0.9512	0.9503	0.9533	0.9523
	validación cruzada	0.9379	0.9398	0.9368	0.9361	0.9329	0.9390	0.9278	0.9358
	Altea	0.9501	0.9506	0.9483	0.9515	0.9517	0.9506	0.9415	0.9438
	Benavites	0.8903	0.9021	0.8795	0.8923	0.9089	0.8753	0.8680	0.8805
	Campo Arcís	0.8705	0.9136	0.8490	0.8936	0.9148	0.9186	0.8047	0.8526
	Castalla	0.8978	0.9027	0.8912	0.9006	0.9029	0.9024	0.8882	0.8766
	media test exterior	0.8862	0.9061	0.8732	0.8955	0.9089	0.8988	0.8536	0.8699
Benavites	entrenamiento	0.9165	0.9138	0.9238	0.9257	0.9166	0.9269	0.9195	0.9295
	validación cruzada	0.9116	0.9126	0.9075	0.9080	0.9062	0.9041	0.9089	0.9043
	Altea	0.9214	0.9285	0.9022	0.9182	0.9132	0.9078	0.9015	0.9125
	Benavites	0.9082	0.9078	0.9137	0.9128	0.9075	0.9139	0.9072	0.9066
	Campo Arcís	0.9072	0.9084	0.9106	0.9062	0.9035	0.9063	0.9001	0.8843
	Castalla	0.8810	0.8764	0.8630	0.8643	0.8669	0.8545	0.8650	0.8527
	media test exterior	0.9032	0.9044	0.8919	0.8962	0.8945	0.8895	0.8889	0.8832
Campo Arcís	entrenamiento	0.9528	0.9556	0.9557	0.9561	0.9542	0.9555	0.9589	0.9599
	validación cruzada	0.9520	0.9492	0.9484	0.9514	0.9503	0.9503	0.9498	0.9467
	Altea	0.9381	0.9382	0.9265	0.9382	0.9325	0.9201	0.9190	0.8990
	Benavites	0.9087	0.9078	0.9033	0.9028	0.9055	0.9033	0.8938	0.8807
	Campo Arcís	0.9426	0.9437	0.9421	0.9421	0.9415	0.9421	0.9402	0.9406
	Castalla	0.9081	0.9025	0.9017	0.9127	0.9083	0.9133	0.9048	0.8913
	media test exterior	0.9183	0.9162	0.9105	0.9179	0.9154	0.9122	0.9059	0.8903
Castalla	entrenamiento	0.9304	0.9304	0.9316	0.9371	0.9328	0.9360	0.9382	0.9376
	validación cruzada	0.9347	0.9304	0.9332	0.9351	0.9336	0.9310	0.9357	0.9349
	Altea	0.9229	0.9218	0.9192	0.8996	0.9226	0.9104	0.8872	0.8935
	Benavites	0.8648	0.8673	0.8719	0.8627	0.8755	0.8888	0.8791	0.8472
	Campo Arcís	0.9322	0.9292	0.9321	0.9364	0.8367	0.9355	0.9222	0.9348
	Castalla	0.9255	0.9236	0.9282	0.9293	0.9295	0.9336	0.9299	0.9298
	media test exterior	0.9066	0.9061	0.9077	0.8996	0.8783	0.9116	0.8962	0.8918

C.1.1.2. Predicción del modelo sobre el set de test.

Figura C.1. ET_0 PM vs ET_0 ANN 4 inputs testados en Benavites y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

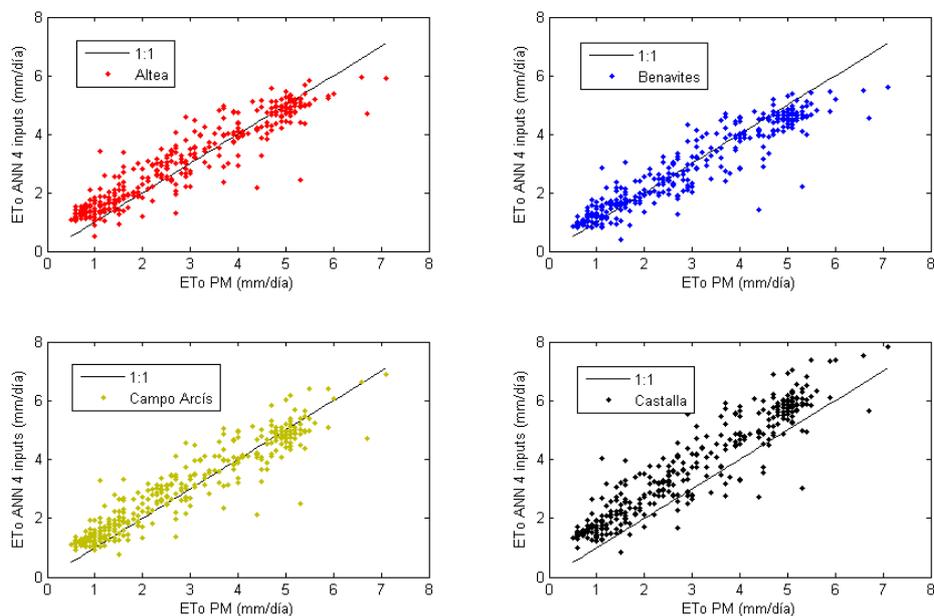


Figura C.2. ET_0 PM vs ET_0 ANN 4 inputs testados en Campo Arcís y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

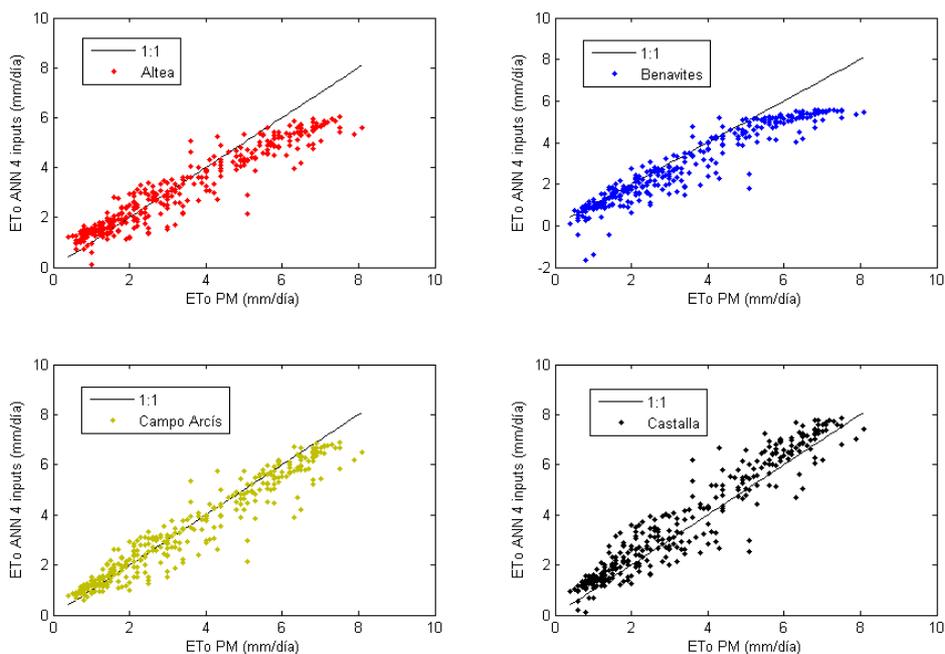
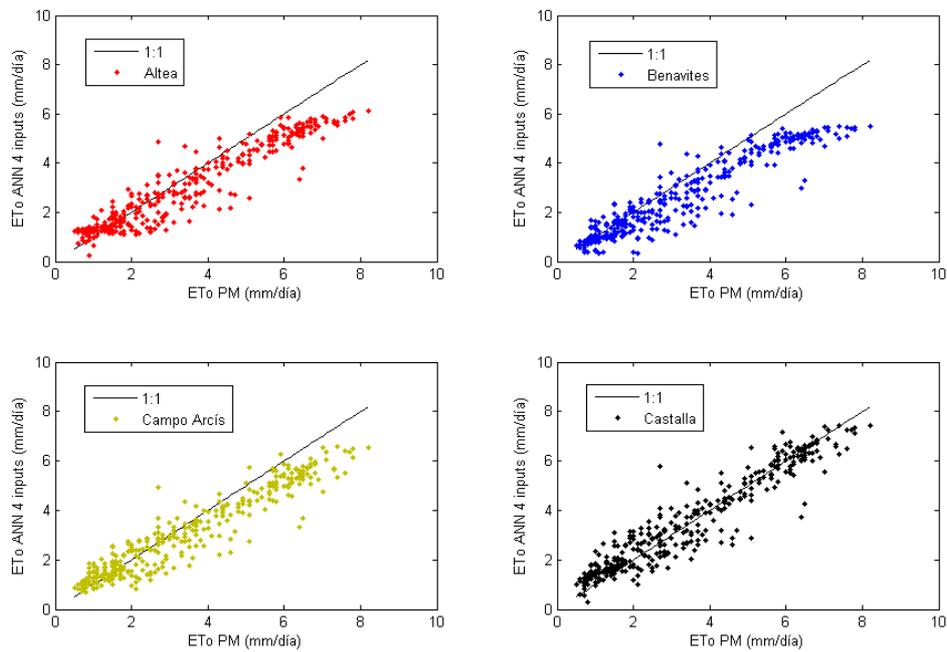


Figura C.3. ET_o PM vs ET_o ANN 4 inputs testados en Castalla y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)



C.1.2. MODELO ANN DE 7 INPUTS

C.1.2.1. Indicadores de rendimiento del modelo

Tabla C.3. Errores cuadráticos medios obtenidos con el modelo ANN de 7 inputs en las fases de entrenamiento y test

		MSE (mm/día) ²							
capas ocultas		1				2			
número de neuronas		5	10	15	20	5	10	15	20
Altea	entrenamiento	0.0182	0.0184	0.0400	0.0161	0.0209	0.0167	0.1646	0.0148
	validación cruzada	0.0168	0.0155	0.0361	0.0165	0.0210	0.0163	0.1754	0.0190
	Altea	0.0150	0.0155	0.0390	0.0154	0.0171	0.0141	0.1938	0.0140
	Benavites	0.0371	0.0423	0.0946	0.0569	0.0398	0.0453	0.2143	0.0608
	Campo Arcís	0.1711	0.1644	0.1932	0.2823	0.3317	0.2321	1.1393	0.2140
	Castalla	0.2520	0.2246	0.1812	0.3974	0.4525	0.2843	0.8750	0.2395
	media test exterior	0.1534	0.1438	0.1563	0.2455	0.2747	0.1872	0.7429	0.1714
Benavites	entrenamiento	0.0161	0.0190	0.0122	0.0129	0.0163	0.0166	0.0104	0.0102
	validación cruzada	0.0180	0.0175	0.0145	0.0161	0.0186	0.0145	0.0151	0.0194
	Altea	0.0794	0.0366	0.0480	0.0587	0.0565	0.0440	0.0520	0.0704
	Benavites	0.0218	0.0218	0.0189	0.0208	0.0237	0.0376	0.0555	0.0270
	Campo Arcís	0.1583	0.1978	0.0878	0.1175	0.1652	0.2801	0.1293	0.1957
	Castalla	0.2769	0.3169	0.1431	0.1711	0.2465	0.4690	0.2041	0.1248
	media test exterior	0.1715	0.1838	0.0930	0.1158	0.1561	0.2644	0.1285	0.1303
Campo Arcís	entrenamiento	0.0259	0.0243	0.0213	0.0217	0.0253	0.0235	0.0878	0.0187
	validación cruzada	0.0204	0.0199	0.0184	0.0214	0.0217	0.0199	0.0964	0.0222
	Altea	0.0915	0.1064	0.0734	0.0648	0.0662	0.0631	0.1503	0.0666
	Benavites	0.0521	0.0366	0.0304	0.0374	0.0388	0.0328	0.1246	0.0298
	Campo Arcís	0.0253	0.0268	0.0211	0.0250	0.0465	0.0312	0.1246	0.0261
	Castalla	0.0453	0.0535	0.0405	0.048	0.0565	0.0559	0.1649	0.0475
	media test exterior	0.0630	0.0655	0.0481	0.0501	0.0538	0.0506	0.1466	0.0480
Castalla	entrenamiento	0.0433	0.0467	0.0451	0.0369	0.0432	0.0397	0.0384	0.0484
	validación cruzada	0.0375	0.0416	0.0382	0.0363	0.0386	0.0386	0.0379	0.0387
	Altea	0.0601	0.0883	0.0818	0.0546	0.0579	0.0863	0.1086	0.0469
	Benavites	0.0329	0.0688	0.0599	0.0617	0.0969	0.0459	0.0584	0.0529
	Campo Arcís	0.0296	0.0446	0.0387	0.0443	0.0342	0.0384	0.0318	0.0706
	Castalla	0.0402	0.0482	0.0457	0.0447	0.0422	0.0406	0.0415	0.0493
	media test exterior	0.0409	0.0672	0.0601	0.0535	0.0630	0.0569	0.0663	0.0568

Tabla C.4. *Performance index* obtenidos con el modelo ANN de 7 inputs en las fases de entrenamiento y test

		c (-)							
capas ocultas		1				2			
número de neuronas		5	10	15	20	5	10	15	20
Altea	entrenamiento	0.9953	0.9952	0.9896	0.9958	0.9946	0.9956	0.9617	0.9962
	validación cruzada	0.9958	0.9961	0.9910	0.9959	0.9947	0.9959	0.9604	0.9953
	Altea	0.9966	0.9965	0.9912	0.9966	0.9961	0.9968	0.9640	0.9968
	Benavites	0.9930	0.9902	0.9760	0.9882	0.9905	0.9895	0.9399	0.9869
	Campo Arcís	0.9774	0.9783	0.9764	0.9623	0.9567	0.9673	0.8411	0.9706
	Castalla	0.9670	0.9706	0.9736	0.9459	0.9415	0.9587	0.8689	0.9650
	media test exterior	0.9791	0.9797	0.9753	0.9655	0.9629	0.9718	0.8833	0.9742
Benavites	entrenamiento	0.9945	0.9935	0.9959	0.9956	0.9944	0.9945	0.9965	0.9966
	validación cruzada	0.9946	0.9948	0.9956	0.9951	0.9944	0.9956	0.9954	0.9940
	Altea	0.9904	0.9939	0.9934	0.9925	0.9909	0.9927	0.9925	0.9906
	Benavites	0.9940	0.9939	0.9947	0.9943	0.9936	0.9895	0.9845	0.9926
	Campo Arcís	0.9743	0.9688	0.9862	0.9810	0.9727	0.9525	0.9789	0.9682
	Castalla	0.9536	0.9535	0.9773	0.9712	0.9580	0.9166	0.9647	0.9779
	media test exterior	0.9728	0.9721	0.9856	0.9816	0.9739	0.9539	0.9787	0.9789
Campo Arcís	entrenamiento	0.9951	0.9954	0.9960	0.9959	0.9952	0.9956	0.9838	0.9965
	validación cruzada	0.9966	0.9966	0.9968	0.9963	0.9962	0.9966	0.9843	0.9961
	Altea	0.9870	0.9867	0.9902	0.9882	0.9906	0.9900	0.9729	0.9890
	Benavites	0.9877	0.9905	0.9926	0.9904	0.9907	0.9911	0.9710	0.9919
	Campo Arcís	0.9959	0.9956	0.9965	0.9959	0.9925	0.9948	0.9814	0.9957
	Castalla	0.9921	0.9912	0.9929	0.9918	0.9903	0.9901	0.9737	0.9919
	media test exterior	0.9889	0.9895	0.9919	0.9901	0.9905	0.9904	0.9725	0.9909
Castalla	entrenamiento	0.9923	0.9917	0.9920	0.9934	0.9923	0.9929	0.9932	0.9914
	validación cruzada	0.9935	0.9927	0.9933	0.9937	0.9933	0.9933	0.9934	0.9933
	Altea	0.9906	0.9807	0.9857	0.9878	0.9870	0.9872	0.9848	0.9902
	Benavites	0.9910	0.9812	0.9842	0.9835	0.9803	0.9876	0.9857	0.9858
	Campo Arcís	0.9952	0.9927	0.9939	0.9926	0.9946	0.9938	0.9947	0.9894
	Castalla	0.9930	0.9914	0.9920	0.9922	0.9927	0.9930	0.9928	0.9913
	media test exterior	0.9923	0.9849	0.9879	0.9880	0.9873	0.9895	0.9884	0.9885

C.1.2.2. Predicción del modelo sobre el set de test

Figura C.4. ET_o PM vs ET_o ANN 7 inputs testados en Benavites y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

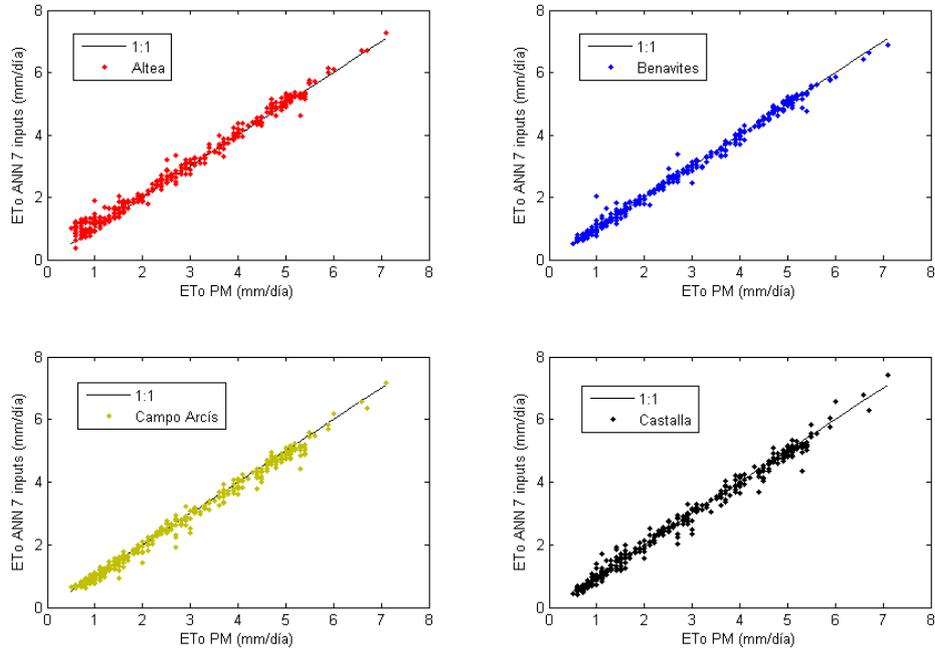


Figura C.5. ET_o PM vs ET_o ANN 7 inputs testados en Campo Arcís y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

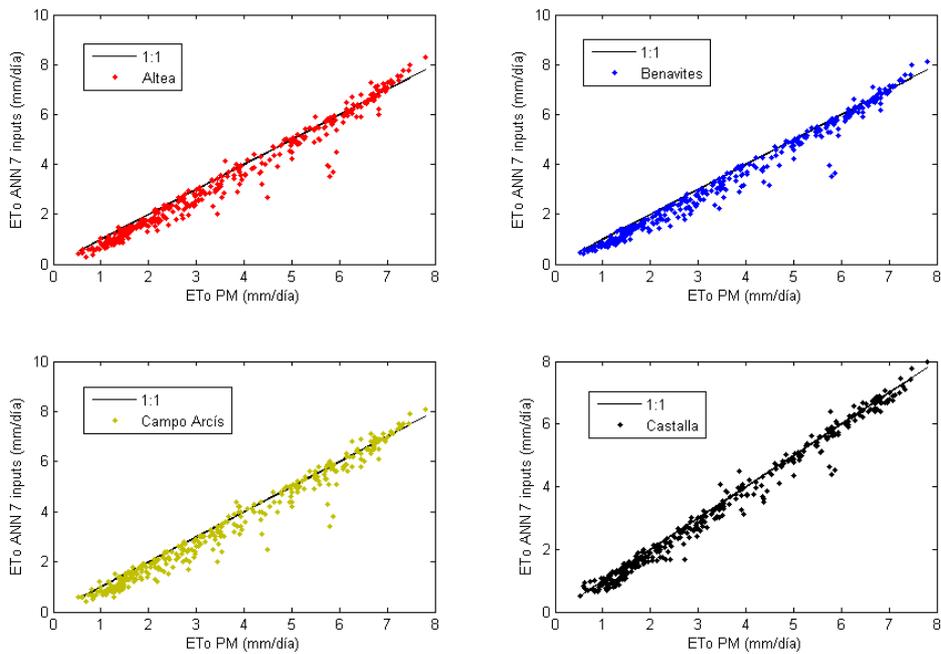
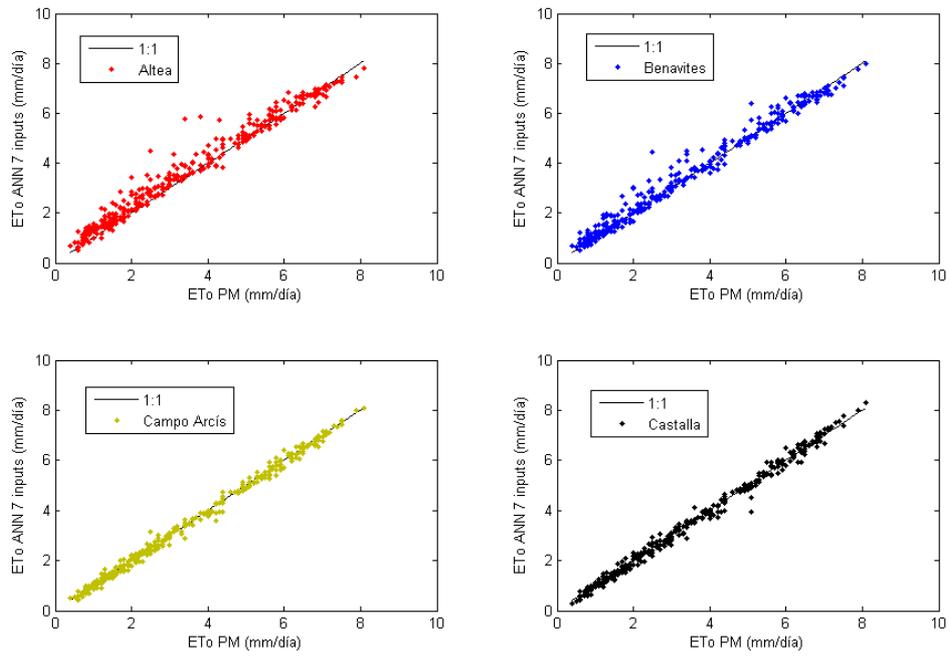


Figura C.6. ET_o PM vs ET_o ANN 7 inputs testados en Castalla y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)



C.2. Cálculos realizados con *Matlab Editor*

C.2.1. MODELO ANN DE 4 INPUTS

C.2.1.1. Selección de arquitectura óptima

Figura C.7. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Benavites

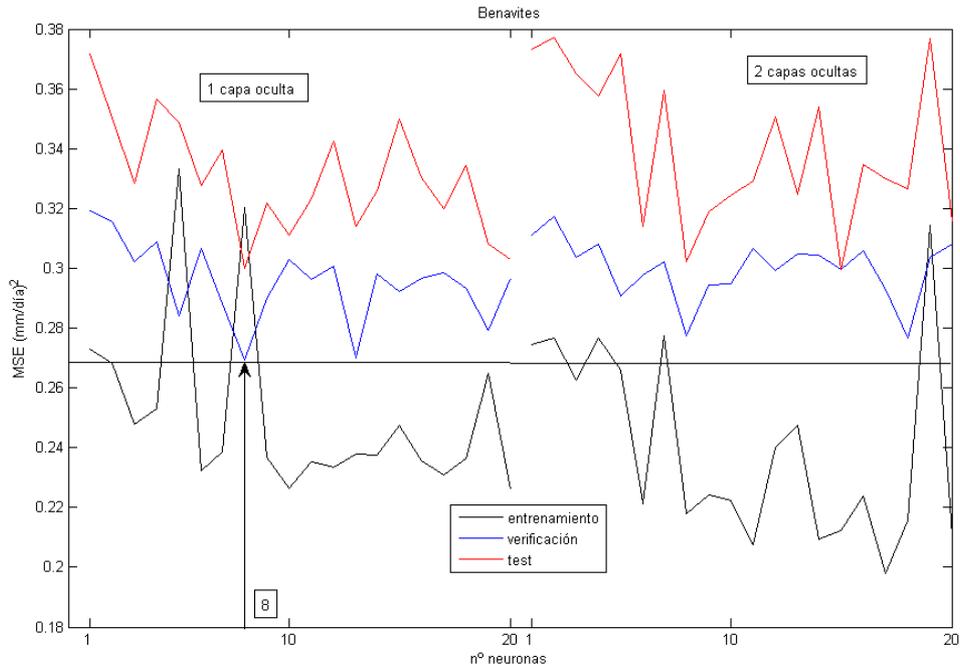


Figura C.8. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Campo Arcís

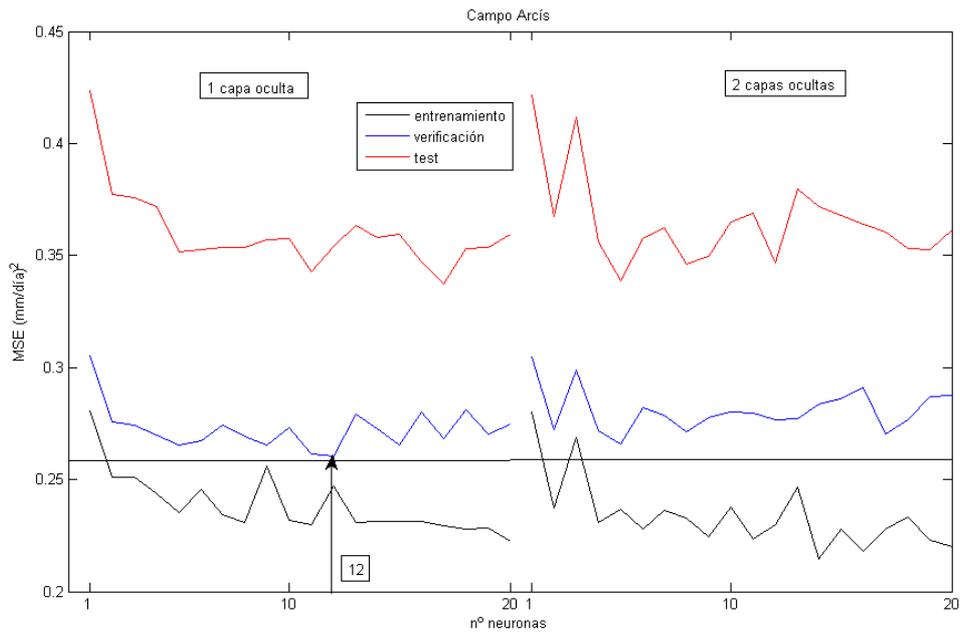
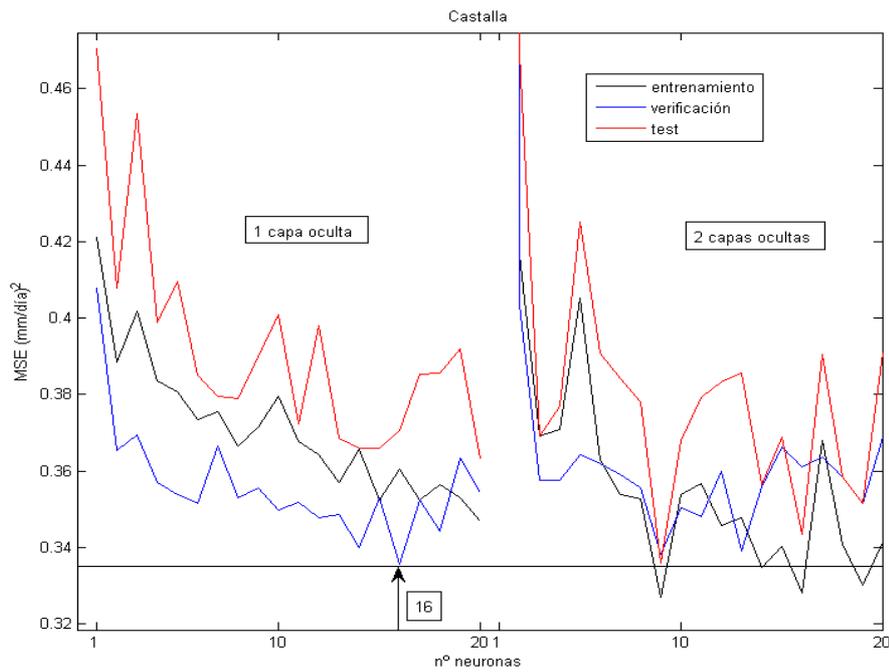


Figura C.9. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Castalla



C.2.1.2. Predicción del modelo ANN de 4 inputs para los sets de test

Figura C.10. ET_o PM vs ET_o ANN 4 inputs testados en Altea y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

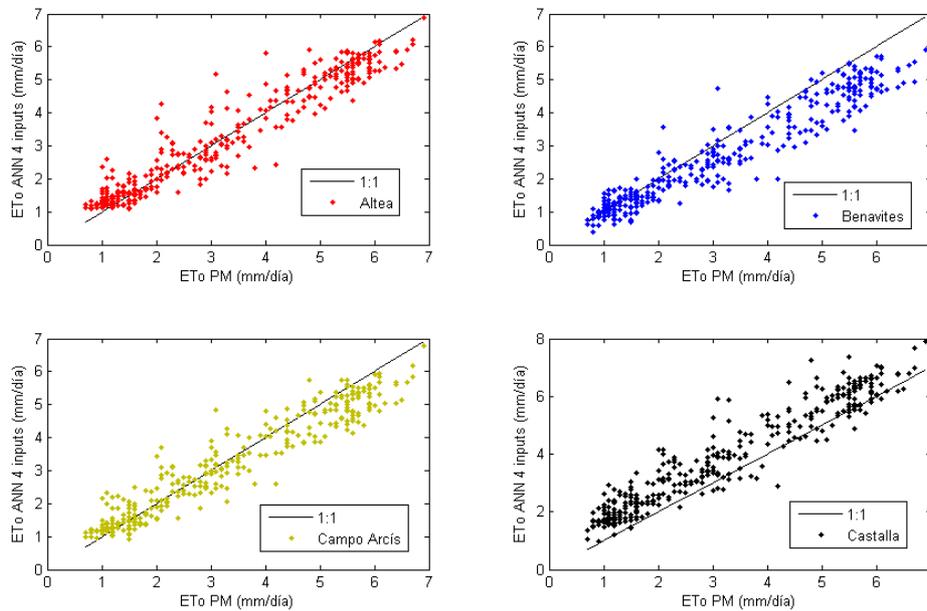


Figura C.11. ET_o PM vs ET_o ANN 4 inputs testados en Benavites y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

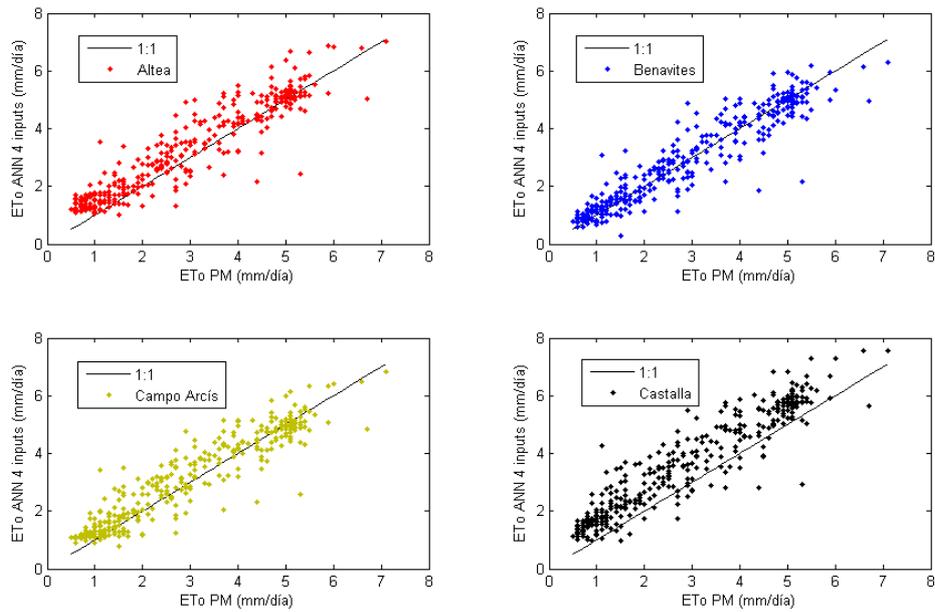


Figura C.12. ET_o PM vs ET_o ANN 4 inputs testados en Campo Arcís y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

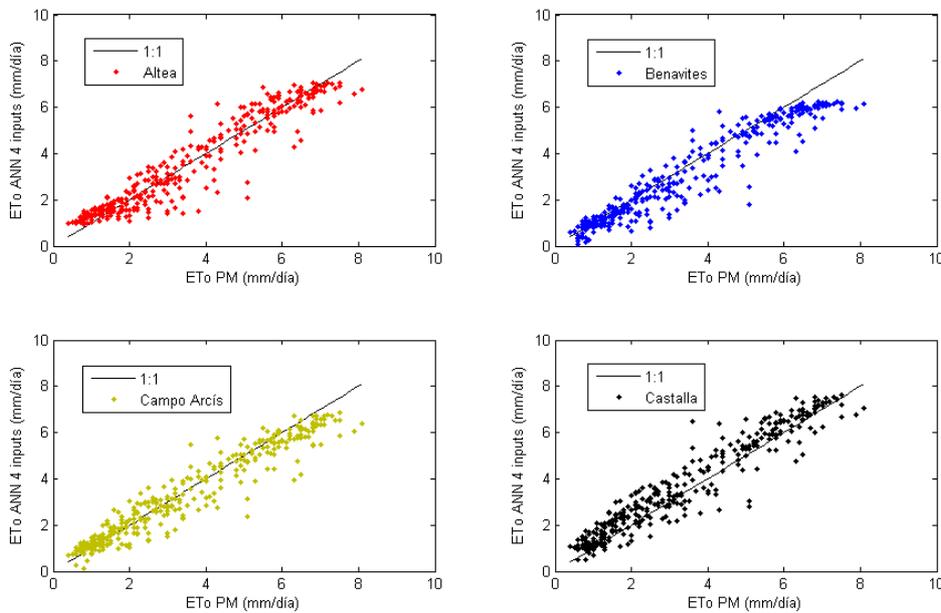
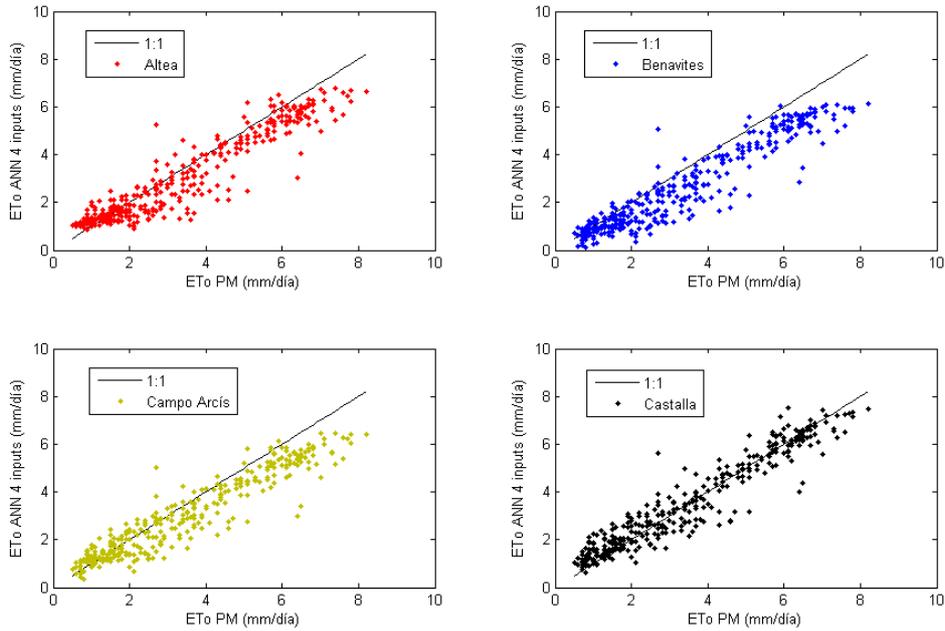


Figura C.13. ET_o PM vs ET_o ANN 4 inputs testados en Castalla y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)



C.2.2. MODELO ANN DE 7 INPUTS

C.2.2.1. Selección de arquitectura óptima

Figura C.14. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Altea

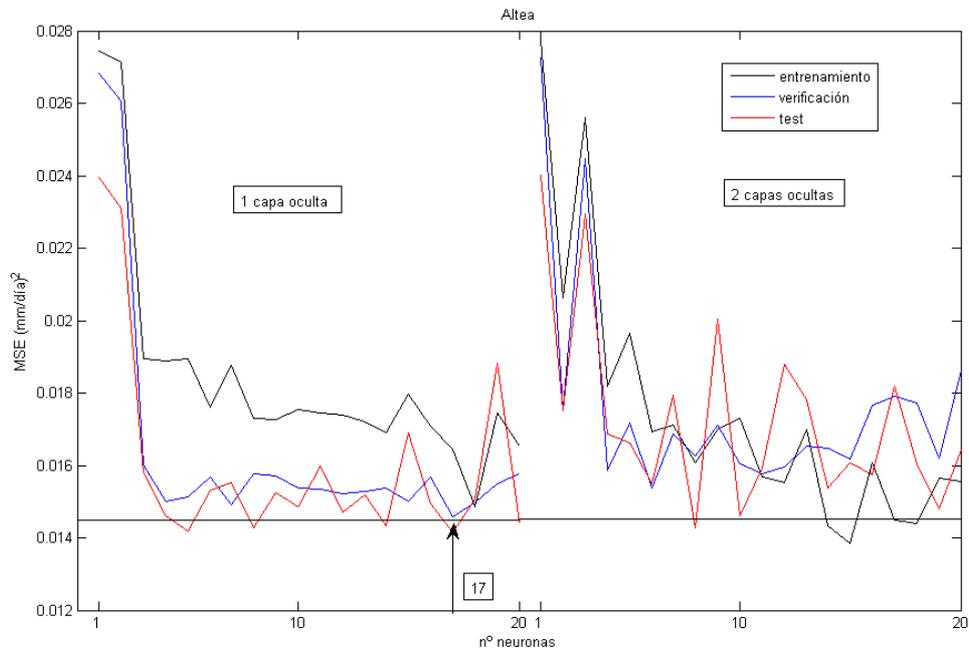


Figura C.15. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Benavites

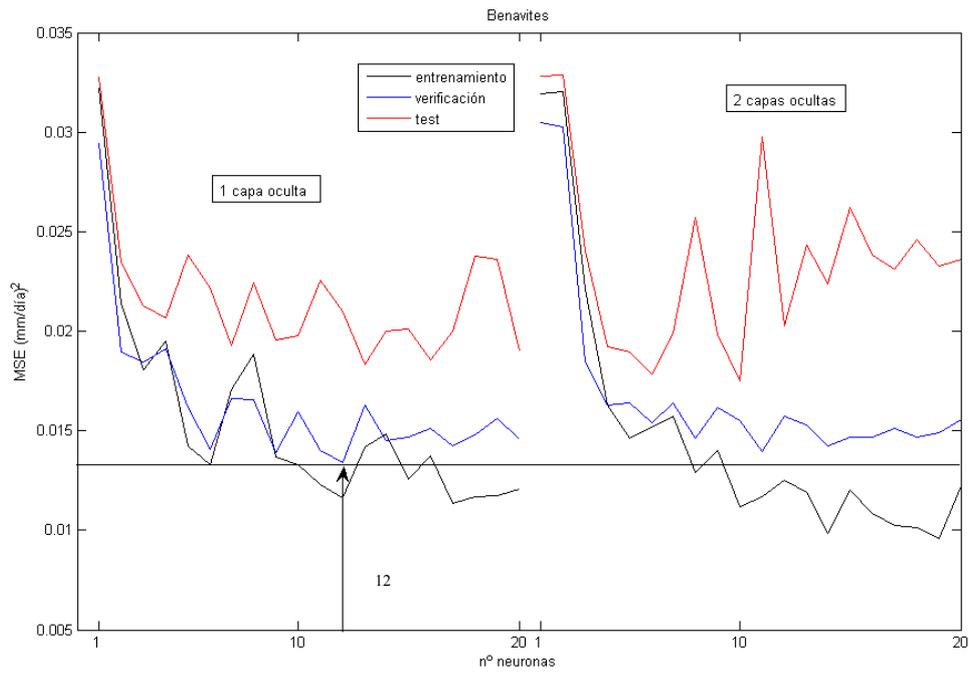


Figura C.16. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Campo Arcis

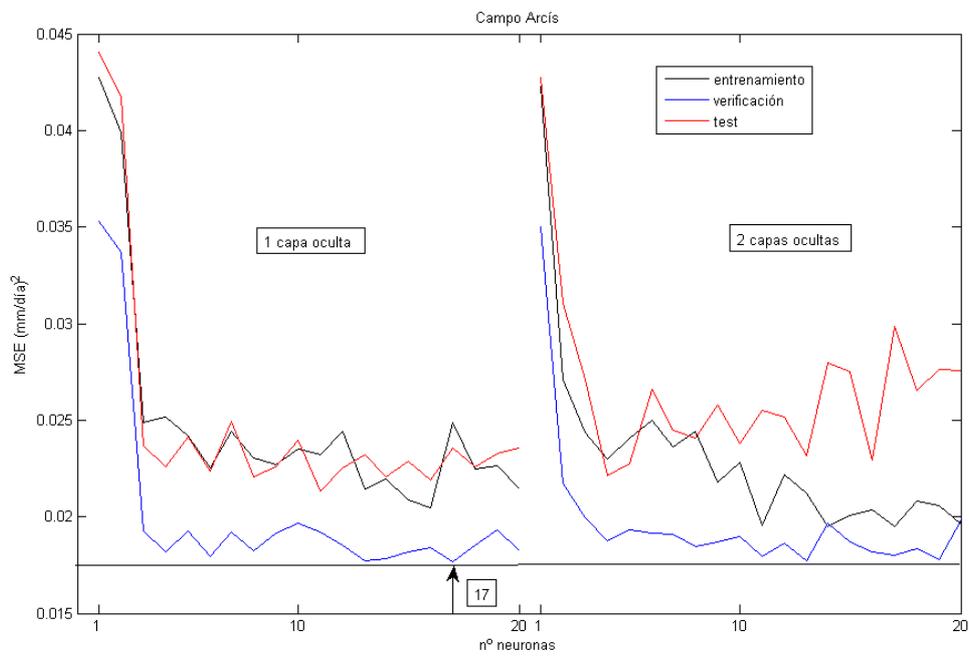
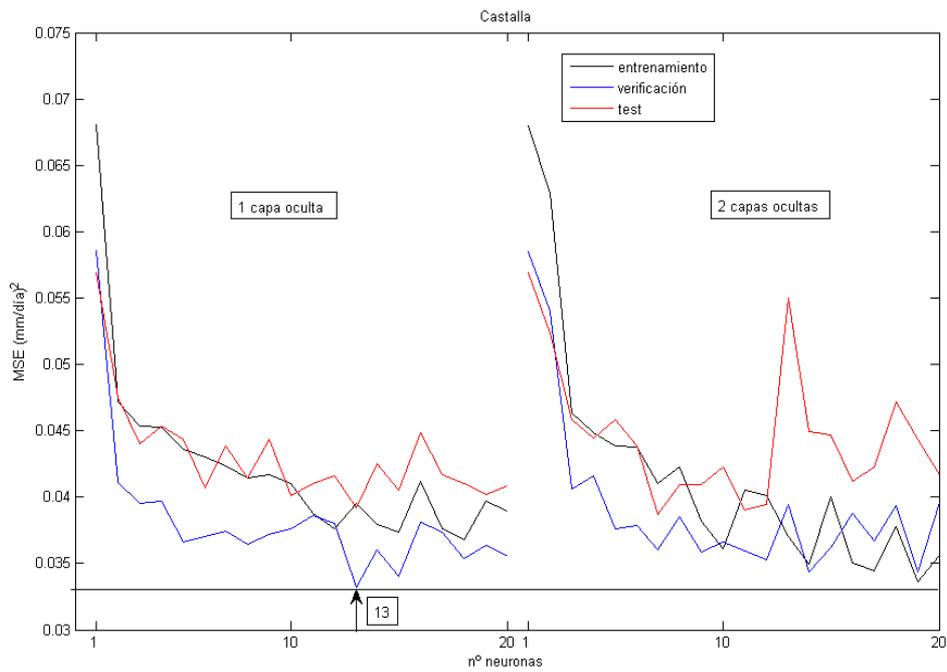


Figura C.17. Número de neuronas vs MSE para sets de entrenamiento, verificación y test en Castalla



C.2.2.2. Predicción del modelo sobre el set de test

Figura C.18. ET_0 PM vs ET_0 ANN 7 inputs testados en Altea y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

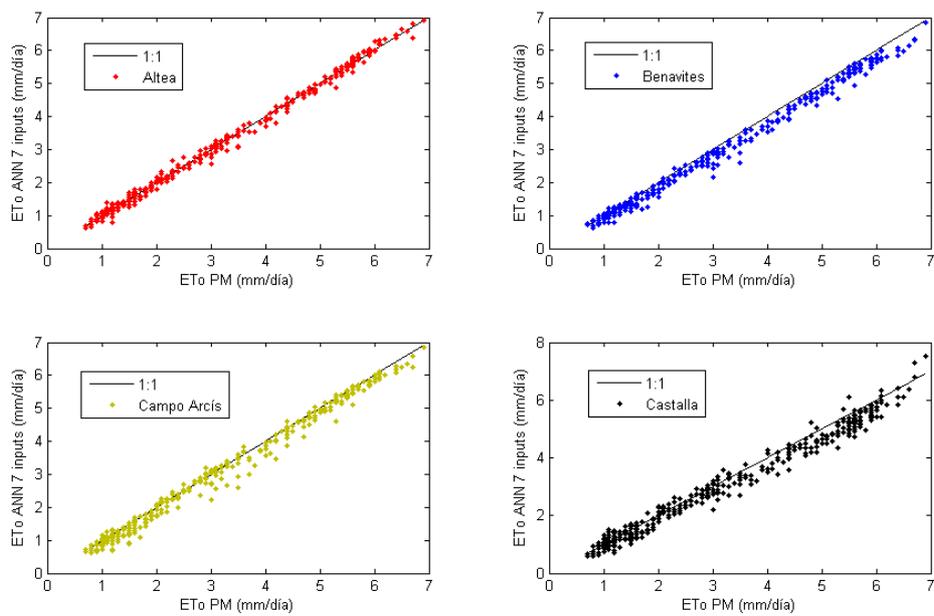


Figura C.19. ET_o PM vs ET_o ANN 7 inputs testados en Benavites y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

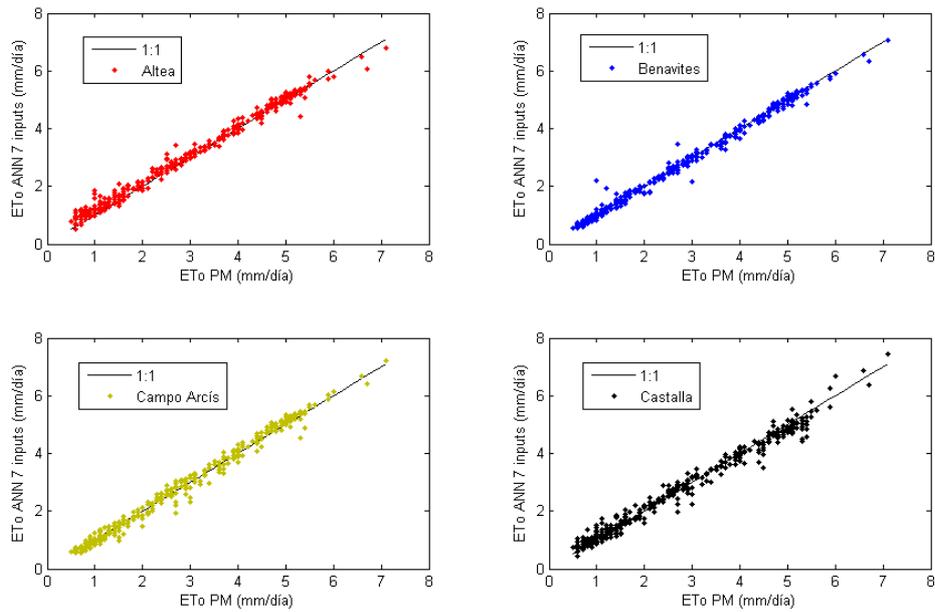


Figura C.20. ET_o PM vs ET_o ANN 7 inputs testados en campo Arcís y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)

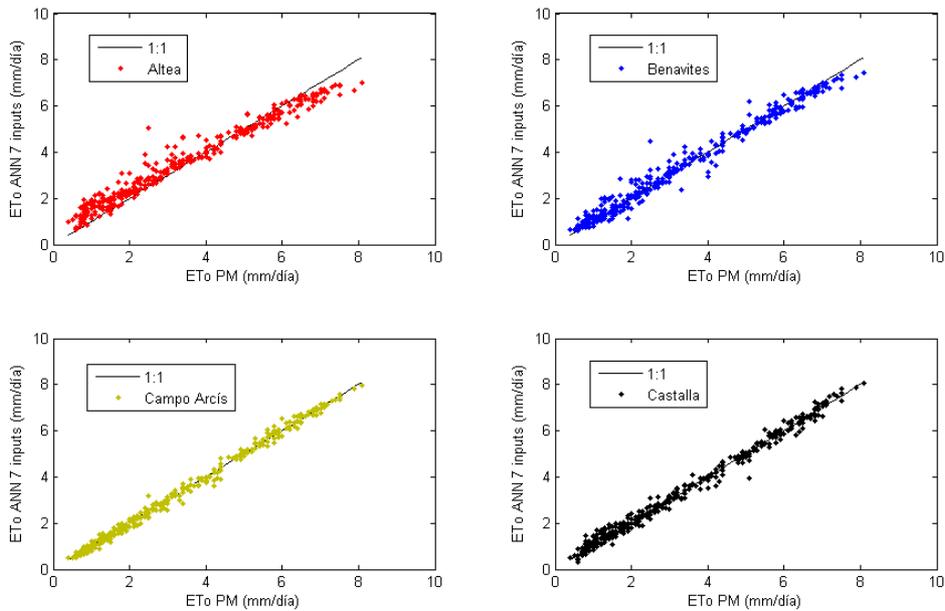
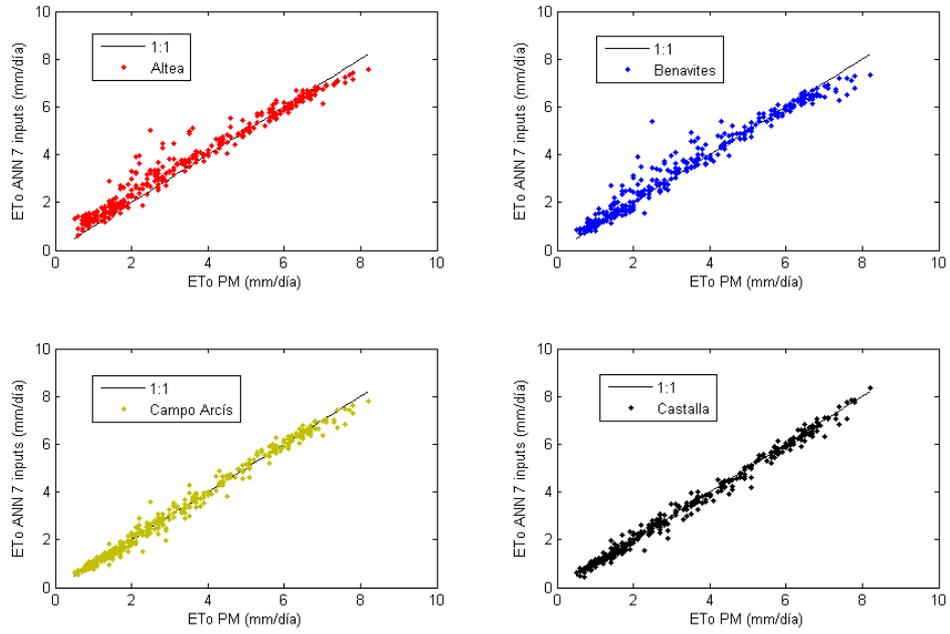


Figura C.21. ET_o PM vs ET_o ANN 7 inputs testados en Castalla y entrenados en Altea (rojo), Benavites (azul), Campo Arcís (verde) y Castalla (negro)



anejo D

predicción de ET_0 aplicando ANNs
y suplantación de datos

D.1. ANÁLISIS DE LA COMBINACIÓN DE RANGOS MÁXIMOS DE IC	277
D.2. ERRORES RELATIVOS ABSOLUTOS PROMEDIOS DE TODOS LOS MODELOS. ALTERNATIVAS DE TEST Y COMBINACIONES DE RANGOS DE IC CONSIDERADOS	281
D.2.1. CASO 0	281
D.2.2. CASO 1	282
D.2.3. CASO 2	283
D.2.4. CASO 3	284
D.2.5. CASO 4	285
D.2.6. CASO 5	286
D.3. SELECCIÓN DE ARQUITECTURA ÓPTIMA DE LOS MODELOS DE PREDICCIÓN DE R_s Y HR Y DEL MODELO ANN DE 4 INPUTS	287
D.3.1. MODELO PARA PREDICCIÓN DE R_s EN CASTALLA	287
D.3.2. MODELO PARA PREDICCIÓN DE HR EN CASTALLA	287
D.3.3. MODELO PARA PREDICCIÓN DE R_s EN PINOSO	288
D.3.4. MODELO PARA PREDICCIÓN DE HR EN PINOSO	288
D.3.5. MODELO DE 4 INPUTS PARA PREDICCIÓN DE ET_o EN ALTEA	289
D.3.6. MODELO DE 4 INPUTS PARA PREDICCIÓN DE ET_o EN ONDA	289
D.3.7. MODELO DE 4 INPUTS PARA PREDICCIÓN DE ET_o EN BENAVIDES	290
D.4. ÍNDICES DE CALIDAD DEL MODELO ÓPTIMO	290
D.5. ÍNDICES DE CALIDAD DE LOS MODELOS PRELIMINARES DE R_s Y HR CORRESPONDIENTES AL MODELO ÓPTIMO	292

D.1. Análisis de la combinación de rangos máximos de IC

Tabla D.1. Estaciones exógenas auxiliares por estación costera de test

estaciones costeras							
estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC	estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC
1-1	1	2	0.0010	1-5	1	1	0.1262
	1	3	0.0089		1	2	0.1252
	1	4	0.1021		1	3	0.1173
	1	5	0.1262		1	4	0.0241
	1	6	0.1564		1	6	0.0302
	1	7	0.2196		1	7	0.0933
	1	8	0.2310		1	8	0.1047
1-2	1	1	0.0010	1-6	1	1	0.1564
	1	3	0.0079		1	2	0.1554
	1	4	0.1011		1	3	0.1475
	1	5	0.1252		1	4	0.0543
	1	6	0.1554		1	5	0.0302
	1	7	0.2185		1	7	0.0631
	1	8	0.2299		1	8	0.0745
1-3	1	1	0.0089	1-7	1	1	0.2196
	1	2	0.0079		1	2	0.2185
	1	4	0.0932		1	3	0.2106
	1	5	0.1173		1	4	0.1174
	1	6	0.1475		1	5	0.0933
	1	7	0.2106		1	6	0.0631
	1	8	0.2220		1	8	0.0114
1-4	1	1	0.1021	1-8	1	1	0.2310
	1	2	0.1011		1	2	0.2299
	1	3	0.0932		1	3	0.2220
	1	5	0.0241		1	4	0.1288
	1	6	0.0543		1	5	0.1047
	1	7	0.1174		1	6	0.0745
	1	8	0.1288		1	7	0.0114
1-9	1	10	0.0963	1-11	1	12	0.3168
1-10	1	9	0.0963	1-12	1	11	0.3168

Tabla D.2. Estaciones exógenas auxiliares por estación intermedia de test 1/2

estaciones intermedias							
estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC	estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC
2-1	1	11	0.6071	2-8	2	3	0.3646
	1	12	0.2903		2	4	0.3424
	2	2	0.0588		2	5	0.2996
	2	3	0.5314		2	6	0.1429
	2	4	0.5535		2	7	0.1081
	2	5	0.5964		2	9	0.1384
2-2	1	11	0.6659	2-9	2	10	0.5692
	1	12	0.3491		2	11	0.5964
	2	1	0.0588		2	3	0.5030
	2	3	0.4726		2	4	0.4808
	2	4	0.4948		2	5	0.4379
	2	5	0.5376		2	6	0.2813
2-3	2	1	0.5314	2-10	2	7	0.2464
	2	2	0.4726		2	8	0.1384
	2	4	0.0222		2	10	0.4309
	2	5	0.0651		2	11	0.4580
	2	6	0.2217	2-11	2	7	0.6773
	2	7	0.2566		2	8	0.5692
	2	8	0.3646		2	9	0.4309
	2	9	0.5030		2	11	0.0272
2-4	2	1	0.5535	2-12	2	12	0.4994
	2	2	0.4948		2	8	0.5964
	2	3	0.0222		2	9	0.4580
	2	5	0.0429		2	10	0.0272
	2	6	0.1995	2-13	2	12	0.4722
	2	7	0.2344		2	13	0.6671
	2	8	0.3424		2	10	0.4994
	2	9	0.4808		2	11	0.4722
2-5	2	1	0.5964	2-14	2	13	0.1949
	2	2	0.5376		2	14	0.3630
	2	3	0.0651		2	15	0.4275
	2	4	0.0429		2	11	0.6671
	2	6	0.1566	2-15	2	12	0.1949
	2	7	0.1915		2	14	0.1681
	2	8	0.2996		2	15	0.2326
	2	9	0.4379		2	16	0.4872
2-6	2	3	0.2217	2-14	2	12	0.3630
	2	4	0.1995		2	13	0.1681
	2	5	0.1566		2	15	0.0644
	2	7	0.0349		2	16	0.3191
	2	8	0.1429		3	1	0.5327
	2	9	0.2813		3	2	0.5683
2-7	2	3	0.2566	2-15	2	12	0.4275
	2	4	0.2344		2	13	0.2326
	2	5	0.1915		2	14	0.0644
	2	6	0.0349		2	16	0.2546
	2	8	0.1081		3	1	0.4683
	2	9	0.2464		3	2	0.5039
	2	10	0.6773		3	3	0.6512

Tabla D.3. Estaciones exógenas auxiliares por estación intermedia de test 2/2

estaciones intermedias			
estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC
2-16	2	13	0.4872
	2	14	0.3191
	2	15	0.2546
	3	1	0.2137
	3	2	0.2492
	3	3	0.3965

Tabla D.4. Estaciones exógenas auxiliares por estación interior de test 1/2

estaciones interiores								
estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC	estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC	
3-1	2	10	1.3951	3-4	2	13	1.3756	
	2	11	1.3680		2	14	1.2075	
	2	12	0.8958		2	15	1.1431	
	2	13	0.7009		2	16	0.8884	
	2	14	0.5327		3	1	0.6748	
	2	15	0.4683		3	2	0.6392	
	2	16	0.2137		3	3	0.4919	
	3	2	0.0356		3	5	0.4523	
	3	3	0.1829		3	6	0.6663	
	3	4	0.6748		3	7	1.1455	
	3	5	1.1271		3-5	2	16	1.3408
	3	6	1.3411			3	1	1.1271
3-2	2	12	0.9313	3		2	1.0915	
	2	13	0.7364	3		3	0.9442	
	2	14	0.5683	3		4	0.4523	
	2	15	0.5039	3		6	0.2140	
	2	16	0.2492	3		7	0.6932	
	3	1	0.0356	3		8	1.1286	
	3	3	0.1473	3-6		3	1	1.3411
	3	4	0.6392			3	2	1.3055
3	5	1.0915	3			3	1.1582	
3	6	1.3055	3			4	0.6663	
3-3	2	12	1.0787		3	5	0.2140	
	2	13	0.8837		3	7	0.4792	
	2	14	0.7156		3	8	0.9147	
	2	15	0.6512		3-7	3	4	1.1455
	2	16	0.3965	3		5	0.6932	
	3	1	0.1829	3		6	0.4792	
	3	2	0.1473	3		8	0.4354	
	3	4	0.4919	3		9	0.9318	
	3	5	0.9442	-		-	-	
	3	6	1.1582	-		-	-	

Tabla D.5. Estaciones exógenas auxiliares por estación interior de test 2/2

estaciones interiores							
estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC	estación de test	tipo estación auxiliar	número estación auxiliar	Δ IC
3-8	3	5	1.1286	3-11	3	8	1.0964
	3	6	0.9147		3	9	0.6000
	3	7	0.4354		3	10	0.0328
	3	9	0.4964		3	12	0.8053
	3	10	1.0636		3	13	1.2989
	3	11	1.0964		3-12	3	10
3-9	3	7	0.9318	3		11	0.8053
	3	8	0.4964	3	13	0.4936	
	3	10	0.5672	3-13	3	10	1.3318
	3	11	0.6000		3	11	1.2989
3-10	3	8	1.0636	3	12	0.4936	
	3	9	0.5672	3-14	3	15	0.5787
	3	11	0.0328	3-15	3	14	0.5787
	3	12	0.8381	-			
	3	13	1.3318	-			

D.2. Errores relativos absolutos promedios de todos los modelos, alternativas de test y combinaciones de rangos de IC considerados

D.2.1. CASO 0

Tabla D.6. Indicadores del modelo 0 con la combinación 1 de rangos de IC

rango IC 1				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	13	23	13
	AARE (-)	0.1319	0.1653	0.1703
2	sede óptima	11	13	13
	AARE (-)	0.1419	0.1702	0.1711
3	sede óptima	11	13	13
	AARE (-)	0.1365	0.1678	0.1703
4	sede óptima	32	13	13
	AARE (-)	0.1405	0.1637	0.1703

Tabla D.7. Indicadores del modelo 0 con la combinación 2 de rangos de IC

rango IC 2				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	12	21	32
	AARE (-)	0.1279	0.1454	0.1583
2	sede óptima	11	21	13
	AARE (-)	0.1369	0.1535	0.1604
3	sede óptima	11	22	32
	AARE (-)	0.1295	0.1547	0.1583
4	sede óptima	32	22	32
	AARE (-)	0.1324	0.1584	0.1583

Tabla D.8. Indicadores del modelo 0 con la combinación 3 de rangos de IC

rango IC 3				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	11	21	32
	AARE (-)	0.1275	0.1480	0.1626
2	sede óptima	11	12	12
	AARE (-)	0.1355	0.1561	0.1644
3	sede óptima	11	21	32
	AARE (-)	0.1298	0.1576	0.1626
4	sede óptima	32	32	32
	AARE (-)	0.1340	0.1643	0.1626

D.2.2. CASO 1

Tabla D 9. Indicadores del modelo 1 con la combinación 1 de rangos de IC

rango IC 1				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	11	13
	AARE (-)	0.1448	0.1673	0.1678
2	sede óptima	11	11	13
	AARE (-)	0.1390	0.1686	0.1675
3	sede óptima	11	11	13
	AARE (-)	0.1391	0.1692	0.1678
4	sede óptima	32	13	13
	AARE (-)	0.1387	0.1681	0.1678

Tabla D.10. Indicadores del modelo 1 con la combinación 2 de rangos de IC

rango IC 2				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	21	13
	AARE (-)	0.1449	0.1586	0.1640
2	sede óptima	11	12	13
	AARE (-)	0.1322	0.1555	0.1618
3	sede óptima	11	11	13
	AARE (-)	0.1324	0.1632	0.1640
4	sede óptima	11	13	13
	AARE (-)	0.1398	0.1620	0.1640

Tabla D.11. Indicadores del modelo 1 con la combinación 3 de rangos de IC

rango IC 3				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	21	32
	AARE (-)	0.1509	0.1582	0.1657
2	sede óptima	11	12	12
	AARE (-)	0.1358	0.1581	0.1649
3	sede óptima	11	22	32
	AARE (-)	0.1364	0.1643	0.1657
4	sede óptima	32	22	32
	AARE (-)	0.1429	0.1650	0.1657

D.2.3. CASO 2

Tabla D.12. Indicadores del modelo 2 con la combinación 1 de rangos de IC

rango IC 1				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	32	32
	AARE (-)	0.1478	0.1796	0.1742
2	sede óptima	32	32	32
	AARE (-)	0.1444	0.1776	0.1744
3	sede óptima	32	32	32
	AARE (-)	0.1459	0.1743	0.1742
4	sede óptima	32	32	32
	AARE (-)	0.1508	0.1719	0.1742

Tabla D.13. Indicadores del modelo 2 con la combinación 2 de rangos de IC

rango IC 2				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	32	32
	AARE (-)	0.1502	0.1706	0.1696
2	sede óptima	32	21	32
	AARE (-)	0.1443	0.1607	0.1657
3	sede óptima	32	21	32
	AARE (-)	0.1494	0.1627	0.1696
4	sede óptima	32	21	32
	AARE (-)	0.1544	0.1623	0.1696

Tabla D.14. Indicadores del modelo 2 con la combinación 3 de rangos de IC

rango IC 3				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	32	32
	AARE (-)	0.1474	0.1740	0.1694
2	sede óptima	32	21	32
	AARE (-)	0.1436	0.1660	0.1657
3	sede óptima	32	21	32
	AARE (-)	0.1459	0.1668	0.1694
4	sede óptima	32	21	32
	AARE (-)	0.1506	0.1677	0.1694

D.2.4. CASO 3

Tabla D.15. Indicadores del modelo 3 con la combinación 1 de rangos de IC

rango IC 1				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	11	13
	AARE (-)	0.1309	0.1588	0.1651
2	sede óptima	13	11	13
	AARE (-)	0.1301	0.1625	0.1663
3	sede óptima	13	11	13
	AARE (-)	0.1289	0.1609	0.1651
4	sede óptima	11	13	13
	AARE (-)	0.1286	0.1604	0.1651

Tabla D.16. Indicadores del modelo 3 con la combinación 2 de rangos de IC

rango IC 2				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	31	11
	AARE (-)	0.1309	0.1459	0.1572
2	sede óptima	13	12	11
	AARE (-)	0.1298	0.1488	0.1558
3	sede óptima	13	12	11
	AARE (-)	0.1293	0.1506	0.1572
4	sede óptima	11	13	11
	AARE (-)	0.1270	0.1507	0.1572

Tabla D.17. Indicadores del modelo 3 con combinación 3 de rangos de IC

rango IC 3				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	11	13
	AARE (-)	0.1332	0.1503	0.1519
2	sede óptima	13	11	13
	AARE (-)	0.1285	0.1515	0.1535
3	sede óptima	13	11	13
	AARE (-)	0.1275	0.1520	0.1519
4	sede óptima	11	13	13
	AARE (-)	0.1268	0.1482	0.1519

D.2.5. CASO 4

Tabla D.18. Indicadores del modelo 4 con la combinación 1 de rangos de IC

rango IC 1				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	21	21
	AARE (-)	0.1482	0.1691	0.1744
2	sede óptima	32	32	32
	AARE (-)	0.1357	0.1700	0.1740
3	sede óptima	32	32	21
	AARE (-)	0.1434	0.1698	0.1744
4	sede óptima	31	13	21
	AARE (-)	0.1389	0.1700	0.1744

Tabla D.19. Indicadores del modelo 4 con la combinación 2 de rangos de IC

rango IC 2				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	22	21	22
	AARE (-)	0.1562	0.1747	0.1681
2	sede óptima	22	21	21
	AARE (-)	0.1535	0.1536	0.1700
3	sede óptima	22	21	22
	AARE (-)	0.1419	0.1546	0.1681
4	sede óptima	22	21	22
	AARE (-)	0.1410	0.1548	0.1681

Tabla D.20. Indicadores del modelo 4 con la combinación 3 de rangos de IC

rango IC 3				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	22	31	31
	AARE (-)	0.1413	0.1525	0.1581
2	sede óptima	31	31	31
	AARE (-)	0.1420	0.1615	0.1590
3	sede óptima	22	31	31
	AARE (-)	0.1350	0.1608	0.1581
4	sede óptima	31	31	31
	AARE (-)	0.1286	0.1584	0.1581

D.2.6. CASO 5

Tabla D.21. Indicadores del modelo 5 con la combinación 1 de rangos de IC

rango IC 1				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	12	13
	AARE (-)	0.1540	0.1792	0.1714
2	sede óptima	32	21	13
	AARE (-)	0.1529	0.1749	0.1713
3	sede óptima	11	23	13
	AARE (-)	0.1571	0.1752	0.1714
4	sede óptima	13	13	13
	AARE (-)	0.1490	0.1675	0.1714

Tabla D.22. Indicadores del modelo 5 con la combinación 2 de rangos de IC

rango IC 2				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	31	32
	AARE (-)	0.1555	0.1655	0.1767
2	sede óptima	32	21	32
	AARE (-)	0.1551	0.1596	0.1705
3	sede óptima	22	21	32
	AARE (-)	0.1582	0.1628	0.1767
4	sede óptima	13	13	32
	AARE (-)	0.1490	0.1709	0.1767

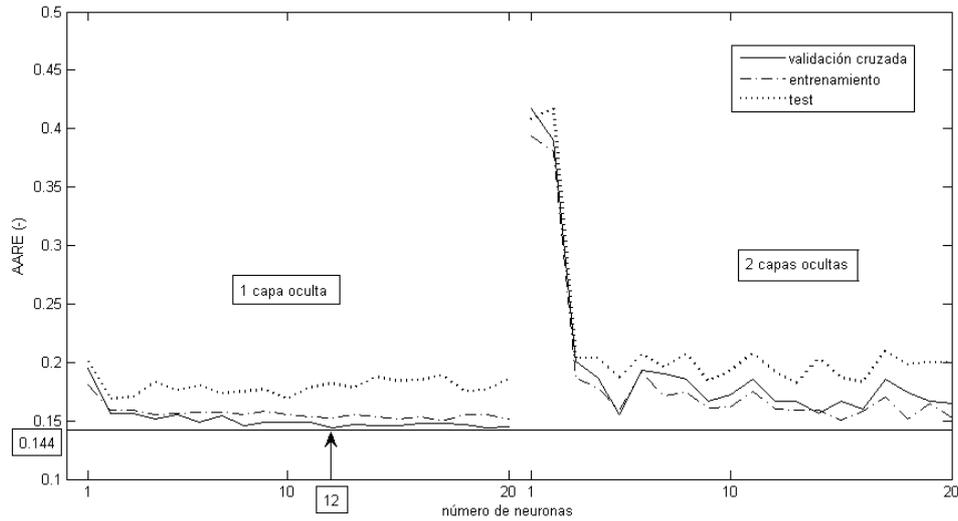
Tabla D.23. Indicadores del modelo 5 con la combinación 3 de rangos de IC

rango IC 3				
alternativa de test	parámetro	costeras	intermedias	interiores
1	sede óptima	32	12	13
	AARE (-)	0.1489	0.1748	0.1684
2	sede óptima	32	21	32
	AARE (-)	0.1433	0.1668	0.1680
3	sede óptima	32	21	13
	AARE (-)	0.1522	0.1704	0.1684
4	sede óptima	13	13	13
	AARE (-)	0.1481	0.1635	0.1684

D.3. Selección de arquitectura óptima de los modelos de predicción de R_s y HR y del modelo ANN de 4 inputs

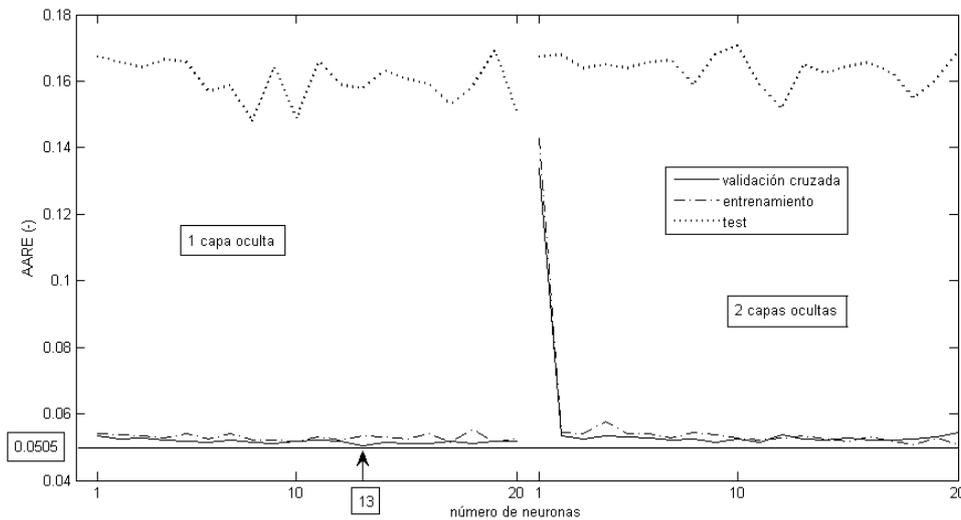
D.3.1. MODELO PARA PREDICCIÓN DE R_s EN CASTALLA

Figura D.1. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo R_s en Castalla



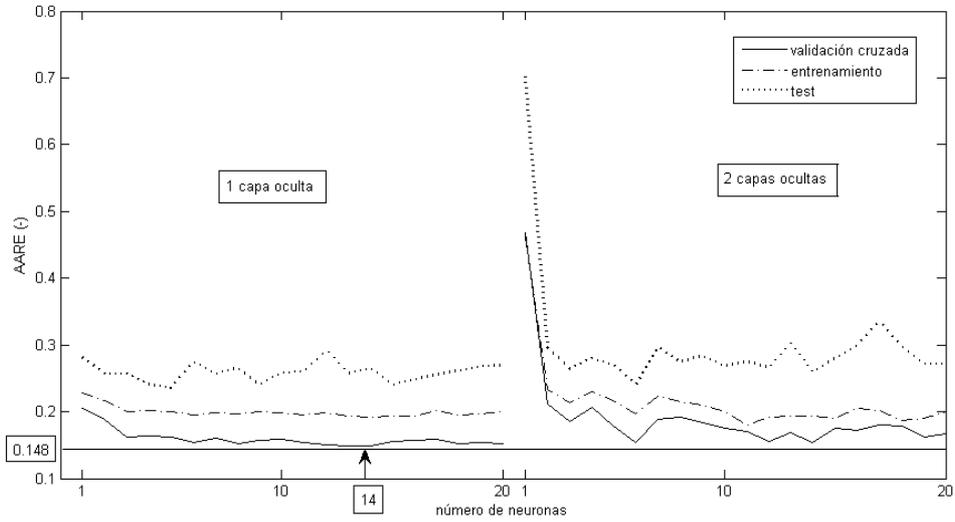
D.3.2. MODELO PARA PREDICCIÓN DE HR EN CASTALLA

Figura D.2. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo HR en Castalla



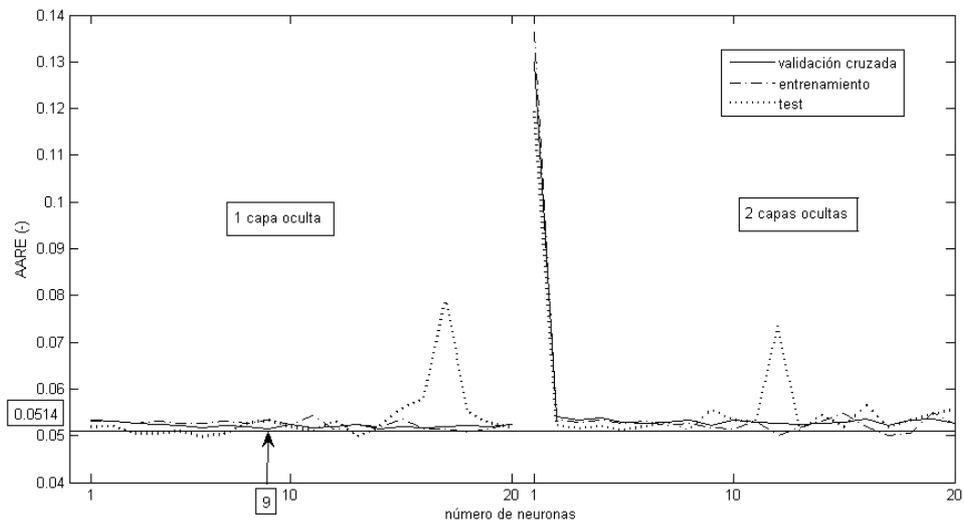
D.3.3. MODELO PARA PREDICCIÓN DE R_s EN PINOSO

Figura D.3. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo R_s en Pinoso



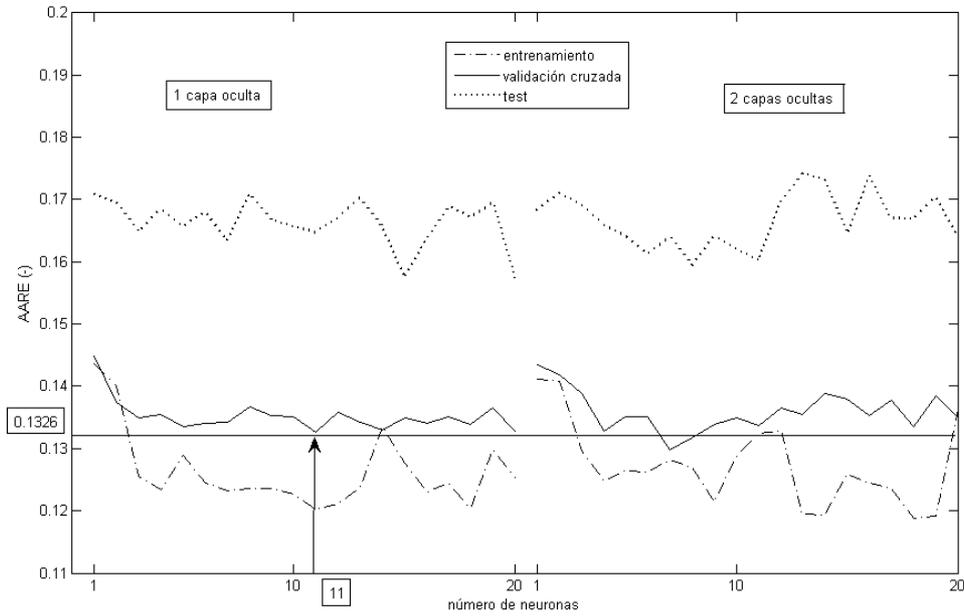
D.3.4. MODELO PARA PREDICCIÓN DE HR EN PINOSO

Figura D.4. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo HR en Pinoso



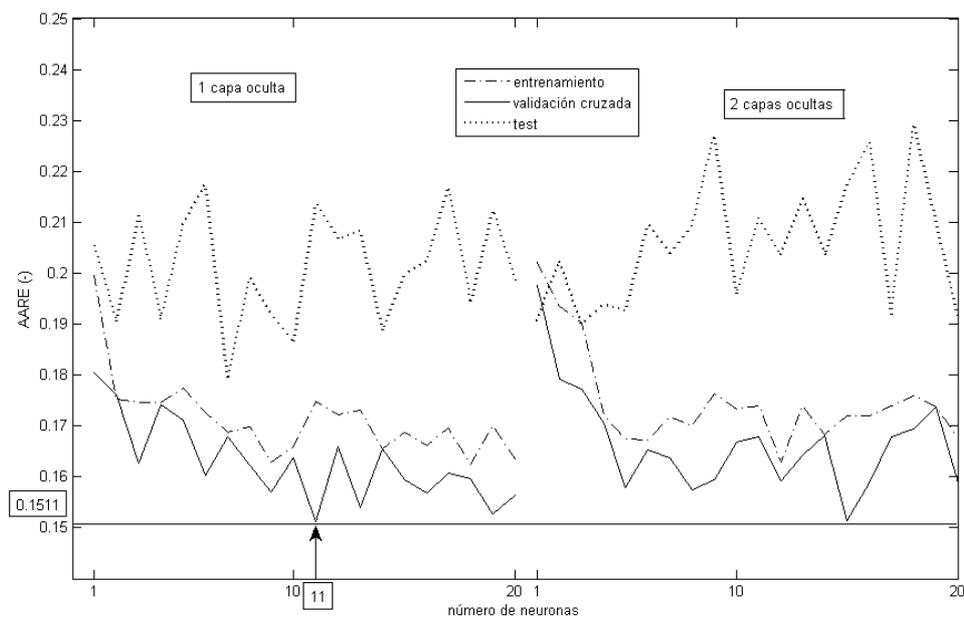
D.3.5. MODELO DE 4 INPUTS PARA PREDICCIÓN DE ET₀ EN ALTEA

Figura D.5. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo ANN de 4 inputs en Altea



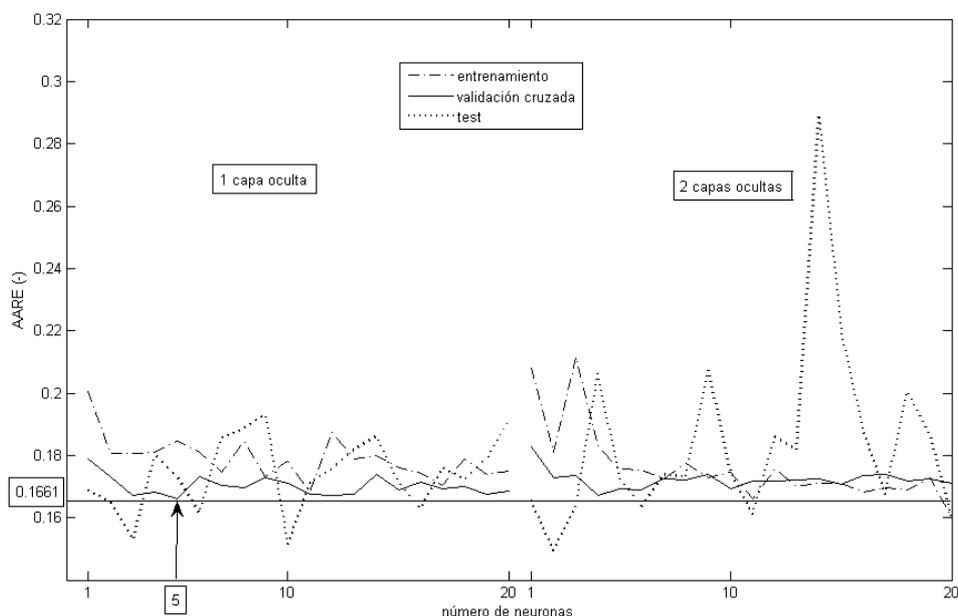
D.3.6. MODELO DE 4 INPUTS PARA PREDICCIÓN DE ET₀ EN ONDA

Figura D.6. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo ANN de 4 inputs en Onda



D.3.7. MODELO DE 4 INPUTS PARA PREDICCIÓN DE ET_o EN BENAVIDES

Figura D.7. Número de neuronas vs AARE para sets de entrenamiento, verificación y test en modelo ANN de 4 inputs en Benavites



D.4. Índices de calidad del modelo óptimo

Tabla D.24. Índices de calidad del modelo óptimo y de los modelos ANN de 4 inputs y Hargreaves en estaciones de test costeras

localidades de test costeras IC=[0.2]										
estación de test	IC	MSE (mm/día) ²			AARE (-)			c (-)		
		4-inputs	6-inputs	HG	4-inputs	6-inputs	HG	4-inputs	6-inputs	HG
1-1	0.2475	0.3784	0.1640	0.4050	0.1613	0.1082	0.2350	0.8903	0.9549	0.8790
1-2	0.2486	0.2482	0.2195	0.2996	0.1299	0.1121	0.1950	0.9363	0.9549	0.9280
1-3	0.2565	0.3272	0.2348	0.3770	0.1441	0.1162	0.1960	0.9112	0.9462	0.9050
1-4	0.3497	0.6018	0.4163	0.6630	0.2111	0.1612	0.3110	0.8626	0.9134	0.8510
1-5	0.3738	0.3950	0.2250	0.4520	0.1613	0.1201	0.2580	0.8986	0.9554	0.8870
1-6	0.4040	0.2350	0.1741	0.2500	0.1414	0.1204	0.2250	0.9341	0.9542	0.9310
1-7	0.4671	0.3092	0.0901	0.2920	0.1796	0.0951	0.3060	0.9097	0.9729	0.9130
1-8	0.4785	0.3109	0.0834	0.3720	0.1875	0.0987	0.3260	0.9292	0.9739	0.9180
1-9	1.1278	0.3857	0.1687	0.5610	0.2511	0.1301	0.4090	0.9071	0.9651	0.8870
1-10	1.2241	0.3332	0.0973	0.5720	0.2685	0.1431	0.4780	0.9279	0.9763	0.9050
1-11	1.5365	0.2356	0.3527	0.1900	0.1346	0.1601	0.1770	0.937	0.9255	0.9460
1-12	1.8533	0.2993	0.3205	0.2930	0.1891	0.1559	0.2840	0.9236	0.9193	0.9250
media	-	0.3383	0.2122	0.3939	0.1800	0.1268	0.2833	0.9140	0.9510	0.9063

Tabla D.25. Índices de calidad del modelo óptimo y de los modelos ANN de 4 inputs y Hargreaves en estaciones de test intermedias

localidades de test intermedias IC=[2.5]										
estación de test	IC	MSE (mm/día) ²			AARE (-)			c (-)		
		4-inputs	6-inputs	HG	4-inputs	6-inputs	HG	4-inputs	6-inputs	HG
2-1	2.1436	0.3104	0.1170	0.6258	0.1721	0.1327	0.3005	0.9069	0.9645	0.8848
2-2	2.2024	0.4064	0.1681	0.9433	0.2341	0.1698	0.4473	0.8771	0.9573	0.8415
2-3	2.6750	0.9425	0.3882	0.5093	0.2136	0.1480	0.1982	0.8124	0.9287	0.8637
2-4	2.6972	1.0099	0.4347	0.3740	0.2279	0.1666	0.1432	0.8166	0.9256	0.9005
2-5	2.7400	0.4919	0.2023	0.5247	0.2072	0.1410	0.3082	0.8803	0.9505	0.8859
2-6	2.8967	0.5978	0.2350	0.3156	0.1955	0.1216	0.2102	0.8733	0.9490	0.9161
2-7	2.9316	0.6348	0.2178	0.5204	0.2042	0.1306	0.2730	0.8501	0.9470	0.8703
2-8	3.0396	1.3284	0.6076	0.5821	0.2605	0.1750	0.1973	0.8057	0.8985	0.8801
2-9	3.1780	0.9366	0.3385	0.4703	0.2229	0.1711	0.2325	0.8445	0.9411	0.8949
2-10	3.6088	0.5332	0.2606	0.5399	0.1892	0.1212	0.2723	0.8880	0.9452	0.8958
2-11	3.6360	1.4836	0.7270	0.6416	0.2629	0.2090	0.1703	0.7763	0.8975	0.8656
2-12	4.1082	0.6845	0.2889	0.4737	0.1862	0.1282	0.2623	0.8911	0.9579	0.9152
2-13	4.3031	0.2684	0.1217	0.8864	0.1985	0.1392	0.4421	0.9342	0.9731	0.8955
2-14	4.4712	0.6284	0.3924	0.5843	0.1792	0.1601	0.2213	0.8534	0.9131	0.8670
2-15	4.5356	0.8399	0.3751	0.7559	0.1991	0.1411	0.2710	0.8016	0.9090	0.8219
2-16	4.7903	0.3579	0.1191	0.9182	0.1829	0.1168	0.3604	0.9094	0.9707	0.8847
media	-	0.7159	0.3121	0.6041	0.2085	0.1483	0.2694	0.8576	0.9393	0.8802

Tabla D.26. Índices de calidad del modelo óptimo y de los modelos ANN de 4 inputs y Hargreaves en estaciones de test interiores

localidades de test interiores IC=[5.20]										
estación de test	IC	MSE (mm/día) ²			AARE (-)			c (-)		
		4-inputs	6-inputs	HG	4-inputs	6-inputs	HG	4-inputs	6-inputs	HG
3-1	5.0039	1.1788	1.0289	0.6013	0.2231	0.2149	0.1695	0.8646	0.9042	0.9140
3-2	5.0395	0.2477	0.1583	0.6045	0.1996	0.1310	0.3223	0.9342	0.9587	0.9047
3-3	5.1868	0.2657	0.1124	0.6008	0.1952	0.1036	0.3105	0.9442	0.9792	0.9297
3-4	5.6787	0.4313	0.1952	0.9051	0.2748	0.1660	0.4440	0.8936	0.9555	0.8711
3-5	6.1311	0.6339	0.6676	0.3978	0.1804	0.1796	0.1779	0.8950	0.9167	0.9180
3-6	6.3450	0.5000	0.2438	0.6550	0.2008	0.1213	0.2727	0.8762	0.9439	0.8720
3-7	6.8242	0.3101	0.1512	0.6958	0.1847	0.1227	0.2821	0.9207	0.9628	0.8989
3-8	7.2597	0.5436	0.2817	0.4836	0.1821	0.1253	0.2152	0.8846	0.9545	0.8931
3-9	7.7561	0.2455	0.0970	0.4029	0.1893	0.1060	0.2955	0.9430	0.9778	0.9359
3-10	8.3233	0.4787	0.2718	0.9717	0.2152	0.1434	0.3457	0.8811	0.9394	0.8550
3-11	8.3561	1.0146	0.7317	0.5108	0.2366	0.2137	0.1608	0.8751	0.9281	0.9179
3-12	9.1614	0.8259	0.5970	0.3189	0.1906	0.1558	0.1578	0.9147	0.9490	0.9525
3-13	9.6550	1.0231	0.8826	0.4208	0.2074	0.2201	0.1577	0.8910	0.9269	0.9388
3-14	14.9251	0.3098	0.1370	0.4527	0.1633	0.1081	0.2371	0.9413	0.9732	0.9368
3-15	15.5038	0.5018	0.4166	0.3402	0.1677	0.1663	0.1809	0.9288	0.9541	0.9463
media	-	0.5674	0.3982	0.5575	0.2007	0.1519	0.2486	0.9059	0.9483	0.9123

D.5. Índices de calidad de los modelos preliminares de R_s y HR correspondientes al modelo óptimo

Tabla D.27. Desglose de los índices de calidad de los modelos R_s y HR en estaciones costeras. Sede de entrenamiento: Castalla

estaciones costeras IC=[0.2]				
estación de test	AARE (-)		c (-)	
	modelo R_s	modelo HR	modelo R_s	modelo HR
1-1	0.2134	0.0987	0.8814	0.7326
1-2	0.2466	0.1026	0.8813	0.7649
1-3	0.2215	0.1360	0.8813	0.6641
1-4	0.3107	0.1012	0.8526	0.7416
1-5	0.2807	0.0675	0.8859	0.8849
1-6	0.5372	0.0788	0.8625	0.8056
1-7	0.2096	0.0601	0.9211	0.9040
1-8	0.2182	0.0657	0.9140	0.8566
1-9	0.3048	0.0764	0.9378	0.9258
1-10	0.3961	0.0852	0.9331	0.9053
1-11	0.2591	0.1609	0.8776	0.7722
1-12	0.2572	0.1353	0.8382	0.7970
media	0.2879	0.0974	0.8889	0.8129

Tabla D.28. Desglose de los índices de calidad de los modelos R_s y HR en estaciones intermedias. Sede de entrenamiento: Pinoso

estaciones intermedias IC=[2.5]				
estación de test	AARE (-)		c (-)	
	modelo R_s	modelo HR	modelo R_s	modelo HR
2-1	0.4449	0.0966	0.9034	0.8061
2-2	0.3802	0.0732	0.8664	0.8546
2-3	0.2632	0.0612	0.8971	0.8911
2-4	0.2447	0.0798	0.8309	0.7981
2-5	0.2712	0.0618	0.8919	0.8687
2-6	0.1898	0.0979	0.8750	0.7212
2-7	0.2801	0.0659	0.9103	0.8918
2-8	0.4346	0.1378	0.8018	0.7674
2-9	0.2705	0.0943	0.8971	0.7274
2-10	0.2037	0.0800	0.8855	0.7826
2-11	0.1650	0.1345	0.8829	0.7069
2-12	0.3032	0.0613	0.8860	0.8690
2-13	0.2979	0.1076	0.8966	0.8333
2-14	0.2053	0.1174	0.8821	0.7774
2-15	0.2464	0.0931	0.8861	0.7841
2-16	0.3723	0.0944	0.9172	0.8116
media	0.2858	0.0911	0.8819	0.8057

Tabla D.29. Desglose de los índices de calidad de los modelos R_s y HR en estaciones interiores. Sede de entrenamiento: Pinoso

estaciones interiores IC=[5.20]				
estación de test	AARE (-)		c (-)	
	modelo R_s	modelo HR	modelo R_s	Modelo HR
3-1	0.1772	0.1467	0.8962	0.6579
3-2	0.3123	0.1012	0.8659	0.6607
3-3	0.2649	0.0551	0.9176	0.8929
3-4	0.3762	0.0994	0.8773	0.7420
3-5	0.2563	0.0989	0.8550	0.7412
3-6	0.2296	0.0842	0.9344	0.8927
3-7	0.2372	0.0702	0.9161	0.8672
3-8	0.3749	0.0809	0.8335	0.9161
3-9	0.2372	0.0999	0.9208	0.8176
3-10	0.3019	0.0982	0.9071	0.7799
3-11	0.1751	0.0954	0.9284	0.8272
3-12	0.2103	0.0850	0.9165	0.8747
3-13	0.1914	0.0690	0.9224	0.9023
3-14	0.2077	0.0819	0.9249	0.9172
3-15	0.2255	0.0573	0.9254	0.9268
media	0.2518	0.0882	0.9028	0.8278

