

Propuesta didáctica para modelizar evapotranspiración de referencia con redes neuronales artificiales en el aula

Teaching methodology for modeling reference evapotranspiration with artificial neural networks

Pau Martí
UNIVERSITAT POLITÈCNICA DE VALÈNCIA
paumarpe@doctor.upv.es

**Inmaculada Pulido-Calvo,
Juan Carlos Gutiérrez-Estrada**
UNIVERSIDAD DE HUELVA
ipulido@uhu.es, juanc@uhu.es

Abstract

Las redes neuronales artificiales constituyen una buena alternativa a los modelos convencionales para estimar diferentes variables en ingeniería del riego, entre ellas la evapotranspiración de referencia, clave en la determinación de las necesidades de agua de riego. En este artículo se presenta una metodología didáctica para introducir al alumno en la aplicación de redes neuronales para el cálculo de evapotranspiración de referencia mediante el programa MATLAB[®]. Además de aprender a usar esta herramienta en una aplicación concreta dentro de su campo de competencias profesionales futuras, el alumno toma contacto con líneas actuales de investigación en el campo de la ingeniería del riego y se promueven eventuales colaboraciones de investigación.

Artificial neural networks are a robust alternative to conventional models for estimating different targets in irrigation engineering, among others, reference evapotranspiration, a key variable for estimating crop water requirements. This paper presents a didactic methodology for introducing students in the application of artificial neural networks for reference evapotranspiration estimation using MATLAB[®]. Apart from learning a specific application of this software within their field of future professional competencies, students would get in touch with current research work in irrigation engineering, and eventual future research collaborations might be promoted.

Keywords: Reference Evapotranspiration, irrigation, artificial neural networks, MATLAB[®].

Palabras clave: Evapotranspiración de referencia, riego, redes neuronales artificiales, MATLAB[®].

1 Introducción

La capacidad para acometer el diseño y manejo de instalaciones de riego se halla entre las competencias profesionales más importantes de un ingeniero agrónomo. Por ello, el grado de Ingeniería Agronómica incluye diferentes asignaturas sobre los fundamentos de la ingeniería del riego.

La evapotranspiración de referencia (ET_0) es un parámetro clave en muchos estudios de naturaleza agrícola, hidrológica y climática. Desempeña un papel fundamental en la gestión y planificación de recursos hídricos. Específicamente, los sistemas modernos de regadío requieren, cada vez más, estimar de manera precisa las necesidades de agua de riego para optimizar las dosis de agua, así como la calidad y productividad de los cultivos.

La ET_0 representa la evapotranspiración de una superficie hipotética de referencia y se introdujo para expresar la demanda evaporativa de la atmósfera independientemente de prácticas de cultivo, tipo de cultivo y desarrollo. El conocimiento de la distribución espacio-temporal de la ET_0 permite el cálculo de las necesidades de agua de riego mediante la aplicación de coeficientes de cultivo establecidos. La evapotranspiración puede determinarse experimentalmente mediante técnicas micro-meteorológicas basadas en balances de energía y métodos de transferencia de flujo de vapor. Asimismo, puede determinarse mediante lisímetros, basándose en un balance de agua en un área de cultivo controlada. Sin embargo, tanto su instalación como su uso son complejos y costosos. Como consecuencia, la disponibilidad de valores experimentales de ET_0 es muy limitada en la práctica.

Para compensar este hecho, se han desarrollado un gran número de modelos matemáticos para su estimación. La adecuación de un método dado para un clima concreto sigue siendo incierta en muchos casos y la elección de un método suele depender de las variables climáticas disponibles. La ecuación de Penman-Monteith (FAO-56 PM) es el método de referencia propuesto por la FAO para determinar ET_0 y validar otras ecuaciones (Allen et al., 1998), pero en muchas situaciones no es aplicable porque requiere muchas variables climáticas (temperatura, humedad relativa, radiación solar y velocidad del viento), algunas de las cuales no suelen estar disponibles o cuya medida puede no ser fiable. Esta ausencia de datos (fiables) ha dado lugar al desarrollo de ecuaciones más sencillas que requieren menos variables climáticas de entrada. Sin embargo, muchos de estos modelos suelen ser ecuaciones empíricas cuya validez depende de los rangos climáticos para los que fueron determinadas. Por ello, existe mucho margen de mejora en la determinación de nuevos modelos para estimar ET_0 a partir de inputs limitados.

En la última década, la aplicación de redes neuronales artificiales (ANN) ha captado la atención de muchos investigadores en diversos campos de la Ciencia y de la Ingeniería. De forma específica, en Ingeniería Agronómica se han propuesto un gran número de nuevos modelos en diversas aplicaciones, incluyendo el riego. Así, las redes neuronales constituyen una buena alternativa a los modelos convencionales existentes para estimar variables en el ámbito del riego, y particularmente para estimar ET_0 . Considerando la importancia adquirida por estos modelos, parece razonable ampliar los contenidos de los programas docentes de grado y plantear la necesidad de elaborar una serie de propuestas didácticas de forma que puedan permitir al estudiante de esta disciplina no sólo entender la base matemática de estos modelos, sino también la metodología y utilidad de la aplicación a casos reales.

Pese a la relevancia de la modelización en el ejercicio profesional, ésta no se ve reflejada en muchos casos en los contenidos curriculares de las titulaciones de ingeniería. Para suplir esta carencia formativa, se han realizado diferentes propuestas para tratar de introducir herramientas de modelización y sus procedimientos en distintas asignaturas de las titulaciones de ingeniería. Estas herramientas no sólo constituyen material para uso profesional, sino que sirven como recursos pedagógicos útiles para una mejor visualización y comprensión de los fenómenos físicos

estudiados en las asignaturas de carácter científico-tecnológico.

Este artículo pretende contribuir en este sentido presentando una metodología para introducir al alumno en la aplicación de redes neuronales para el cálculo de evapotranspiración de referencia. Para ello, se ha decidido utilizar como soporte para la aplicación práctica del método un software matemático común y al alcance de cualquier estudiante universitario, MATLAB[®], con sus toolboxes NNF (Neural Network Fitting Toolbox) y NN (Neural Network Toolbox). Este software se presenta en un entorno gráfico sencillo donde definir las matrices requeridas, así como los parámetros necesarios para aplicar los algoritmos de entrenamiento de las redes. Concretamente, se desarrollará una red neuronal artificial para estimar valores FAO-56 PM a partir de dos combinaciones de inputs. Los resultados se compararan con modelos convencionales existentes que consideren los mismos inputs (la ecuación de Hargreaves y su versión calibrada). Asimismo, se hará hincapié en dos procedimientos para evaluar los modelos: el hold-out y el k-fold test.

2 Gestión de datos climáticos

El estudio que se presenta considera las series climáticas de 10 estaciones (5 costeras y 5 interiores) de la Comunidad Valenciana (Figura 1). Los datos están disponibles en la página web del Servicio de Tecnología del Riego del Instituto Valenciano de Investigaciones Agrarias (IVIA). Para este estudio se consideraron valores diarios de temperaturas máxima, mínima y media, velocidad del viento, humedad relativa y radiación solar entre los años 2000 y 2007.

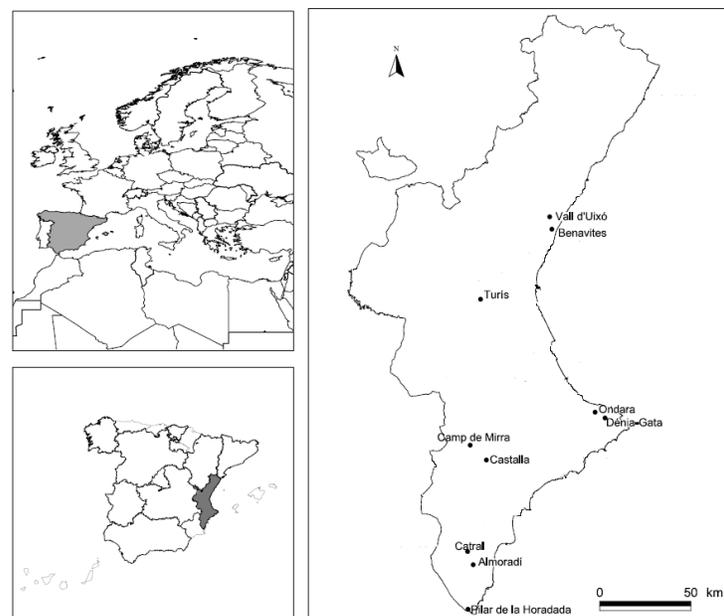


Figura 1: Situación de las estaciones climáticas consideradas

El modelo neuronal considerará como inputs temperatura máxima y mínima medidas, así como radiación extraterrestre y número de horas de sol teóricas (ANN_4). Es decir, el modelo tiene 4 variables de entrada, aunque en realidad sólo requiere la medida de 2 inputs, pues los otros dos se calculan a partir de datos de latitud y altitud para cada día del año (Zanetti, et al., 2007). Además, se desarrollará otro modelo neuronal añadiendo humedad relativa a las variables de entrada anteriores (ANN_5). Con ello se pretende visualizar la relevancia de este parámetro en la exactitud del modelo.

Asimismo, se compararán dos metodologías para evaluar el modelo: el hold out y el k-fold test. El primero considera una única asignación de datos para entrenar y evaluar el modelo neuronal, mientras que el segundo lleva a cabo un barrido del set de datos a partir de un tamaño predefinido del set de test. En ambos casos se considerará un tamaño del set de test de un año ($k=8$). El k-fold test requerirá repetir el proceso de entrenamiento y test 8 veces, dejando cada vez un año diferente para evaluar. El primer procedimiento se ejecutará usando los toolboxes NNF y NN de MATLAB[®], mientras que para el segundo se aplicará un fichero .m previamente implementado por el profesor. Se pretende poner de manifiesto la importancia de poder programar las rutinas para optimizar el tiempo de cálculo.

3 Evapotranspiración de referencia

Debido a la ausencia de medidas experimentales de ET_0 en las estaciones consideradas, se utilizarán valores de ET_0 de FAO-56 PM (Allen et al., 1998) como variable objetivo para entrenar, validar y evaluar las redes. Es decir,

$$ET_0^{PM} = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)},$$

donde ET_0^{PM} es la evapotranspiración de referencia calculada con la ecuación FAO-56 PM (mm/día); R_n es la radiación neta en la superficie del cultivo (MJ/m^2 día); G es la densidad de flujo de calor en el suelo (MJ/m^2 día); T es la temperatura media diaria del aire a 2 m de altura ($^{\circ}C$); γ es la constante psicrométrica ($kPa/^{\circ}C$); Δ es la presión de la curva de presión de vapor ($kPa/^{\circ}C$); e_s es la presión de saturación de vapor (kPa); e_a es la presión de vapor real; u_2 es la velocidad del viento a 2 m de altura (m/s).

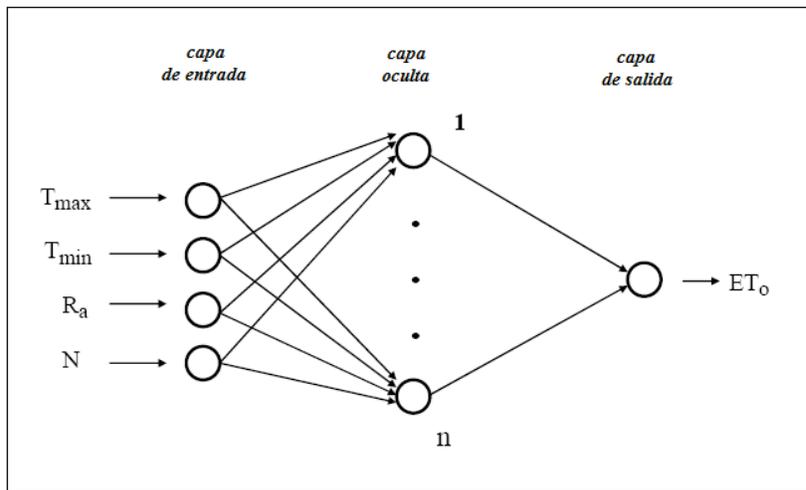


Figura 2: Esquema de una ANN de 4 inputs con una capa oculta.

Asimismo, se compararán las estimaciones de ET_0 de los modelos neuronales propuestos con un modelo convencional muy aplicado y que considera las mismas variables de entrada, el modelo HG (Hargreaves et al., 1985). Para ello:

$$ET_0^{HG} = 9.388 \cdot 10^{-4} R_a (T_{max} - T_{min})^{0.5} (T + 17.8),$$

donde ET_0^{HG} es la evapotranspiración de referencia de Hargreaves (mm/día); R_a es la radiación extraterrestre (MJ/m^2 día); T_{max} y T_{min} son las temperaturas máxima y mínima, medidas a una altura de 2 m ($^{\circ}C$), respectivamente; T es la temperatura media diaria ($^{\circ}C$). Finalmente, los resultados se compararán con la versión calibrada linealmente de la ecuación de HG (HG_c), también mediante hold out y k-fold test, obtenida con un ajuste preliminar según la expresión:

$$ET_0^{PM} = a \cdot ET_0^{HG},$$

donde a es la pendiente que se obtiene por regresión lineal.

4 Redes neuronales artificiales

Haykin (1999) define las redes neuronales artificiales como procesadores distribuidos masivamente en paralelo consistentes en unidades de procesamiento simples, con una propensión natural a almacenar conocimiento experimental. Son capaces de realizar una vinculación no lineal de un espacio multidimensional de entrada en otro espacio multidimensional de salida, sin requerir información detallada sobre el sistema. Las conexiones sinápticas entre las neuronas se ajustan durante el entrenamiento o proceso de aprendizaje, y, como consecuencia, el conocimiento se adquiere y se almacena.

Hay muchos tipos de redes neuronales. La tipología empleada en este estudio corresponde a un perceptrón multicapa con retropropagación del error, uno de los tipos más comunes y empleados. Estas redes constan de diferentes capas (entrada, salida, ocultas) que, a su vez, constan de un número específico de unidades de procesamiento o neuronas (Figura 2). La señal se extiende hacia adelante capa a capa como se muestra en la Figura 3.

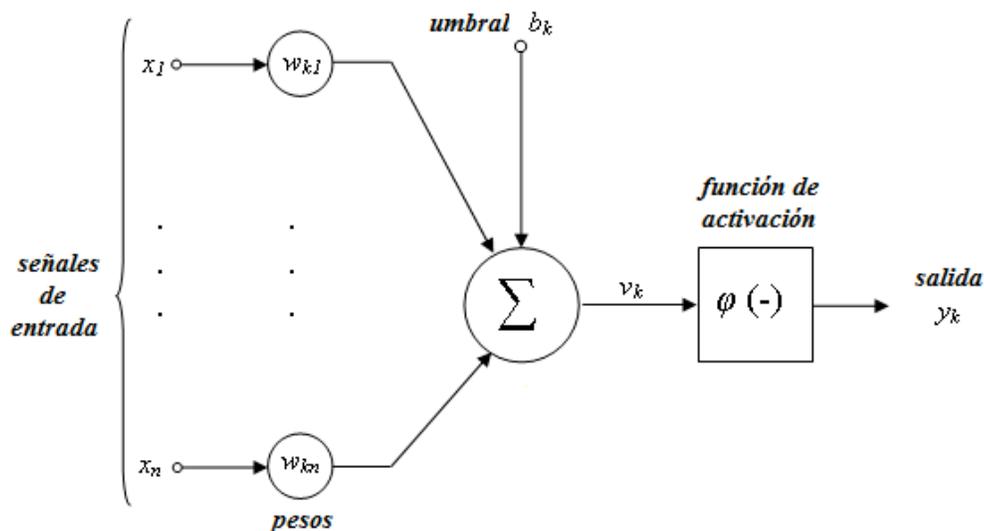


Figura 3: Procesamiento de la señal en las neuronas.

En este tipo de redes, se aplican reglas de entrenamiento supervisado para minimizar la diferencia entre la variable de salida de la red y la variable objetivo deseada. Los pesos o factores de ponderación de las conexiones entre neuronas se mueven iterativamente a lo largo del gradiente negativo de la función de error. La retropropagación implica que los errores se usan como inputs para retroalimentar las conexiones, y, como resultado, los pesos se van ajustando capa a capa hacia atrás.

El sobreajuste de los datos de entrenamiento se evita mediante el procedimiento de parada temprana (early-stopping). Así, mientras el error del conjunto de validación sea menor que su valor en la iteración anterior, el entrenamiento de la red continúa. Si aumenta, el entrenamiento se para —Bishop (1995)—. Para ello, deben definirse tres conjuntos de datos: uno para entrenar, uno para validar y otro para evaluar (test). La determinación de la arquitectura óptima se realiza mediante prueba y error. Para agilizar el ejercicio y teniendo en cuenta que una parte de la actividad está pensada para ejecutarse manualmente con el NNF/NN toolbox, sólo se contemplarán hasta 10 neuronas ocultas y una capa oculta. Estas arquitecturas han resultado ser suficientes en la práctica para garantizar una vinculación adecuada entre variables de entrada y de salida. Asimismo, se usará la función de activación TANSIG en las neuronas ocultas (función tangente hiperbólica) y la PURELIN en la neurona de salida (lineal), así como el algoritmo de entrenamiento Levenberg-Marquardt (TRAINLM).

5 Programación de la actividad

La actividad se programa de la siguiente manera. En primer lugar, se introducirían conceptos básicos sobre redes neuronales, concretamente sobre el tipo de redes utilizadas en este estudio. Dicha explicación incluiría un resumen de las aplicaciones más recientes de estos modelos en ingeniería del riego. Los alumnos bajarían directamente de la página web del IVIA los datos necesarios para los cálculos y definirían las matrices para su procesamiento con MATLAB[®]. Posteriormente se normalizarían los datos. En la primera aplicación (hold out) se usarían el NNF y el NN toolbox (Figuras 4 y 5). Los alumnos importarían las diferentes matrices, previamente desglosadas en los conjuntos de entrenamiento, validación y test. Repetirían el procedimiento de entrenamiento para visualizar la importancia de la asignación inicial aleatoria de pesos. Al considerar diversas arquitecturas, repeticiones, estaciones y configuraciones de test, tomarían consciencia de la necesidad de programar rutinas para optimizar el proceso de cálculo. Así pues, en la segunda fase de la actividad, los alumnos aprenderían a calcular con ficheros .m, previamente implementados por el profesor en este caso (Figura 6).

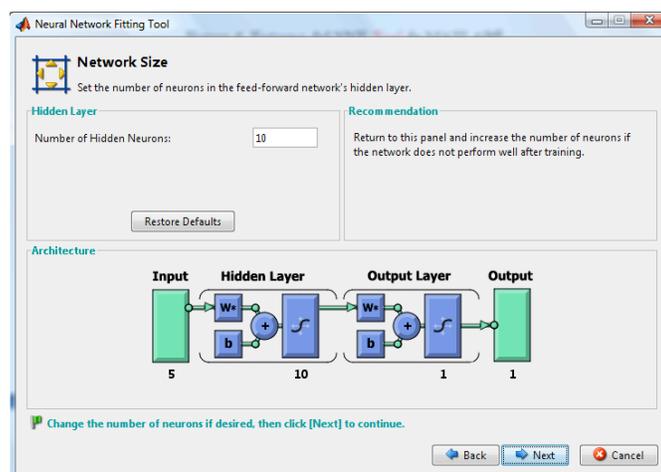


Figura 4: Entorno del NNF Tool de MATLAB[®].

La programación de otros casos quedaría como actividad individual para el alumno. Dados los conocimientos previos sobre MATLAB[®] adquiridos en otras asignaturas (fundamentos matemáticos), los alumnos podrían participar activamente en la aplicación propuesta de las redes neuronales. Dada la imposibilidad de terminar la actividad en el aula, los alumnos

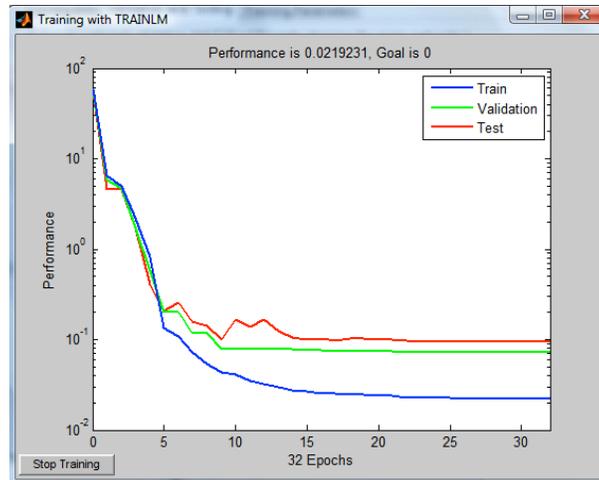


Figura 5: Errores de entrenamiento, validación y test con el NN Toolbox.

prepararían una memoria por grupos con los resultados de la sesión práctica.

```

24 - net=newff(p,t,[nn1,nn2],{'tansig','purelin'},'trainlm');
25 -
26 - %Iniciación de la red
27 -
28 - net = init(net);
29 -
30 - %función de error MSE
31 -
32 - net.performFcn = 'mse';
33 -
34 -
35 - %definición de los parámetros de entrenamiento
36 -
37 - net.trainParam.show = NaN;
38 - net.trainParam.epochs = 100;
39 - net.trainParam.goal = 0;
40 - net.trainParam.max_fail = 5;
41 - net.trainParam.mem_reduc = 1;
42 - net.trainParam.min_grad = 1e-10;
43 - net.trainParam.mu = 0.001;
44 - net.trainParam.mu_dec = 0.1;
45 - net.trainParam.mu_inc = 10;
46 - net.trainParam.mu_max = 1e10;
47 - net.trainParam.time = inf;
48 -
49 - %entrenamiento de la red
50 -
51 - [net,tr]=train(net,p,t,[],[],valV,testV);
52 -

```

Figura 6: Fragmento del fichero .m.

6 Resultados

Los resultados de la actividad deberían permitir una comparativa, por ejemplo mediante la magnitud del relative root mean squared error (RRMSE), entre los 4 modelos propuestos. Las comparativas deberían contemplar el rendimiento de cada modelo globalmente por estación (resultado del k-fold test completo en cada una de las estaciones estudiadas, Figura 7), así como el rendimiento de cada modelo por año en cada estación (resultados parciales del k-fold test, Figuras 8 y 9). En el primer caso, se pretendería establecer una comparación entre modelos (ANN vs. convencionales, ANN₄ vs ANN₅ y HG vs HG_c), mientras que en la segunda se pretendería poner de manifiesto la variación de dichas comparaciones según el año de test elegido. Esto permitiría visualizar la importancia de llevar a cabo barridos completos del conjunto de test en contraposición a la asignación única contemplada en el hold out (muy usada en algunos estudios científicos del área).

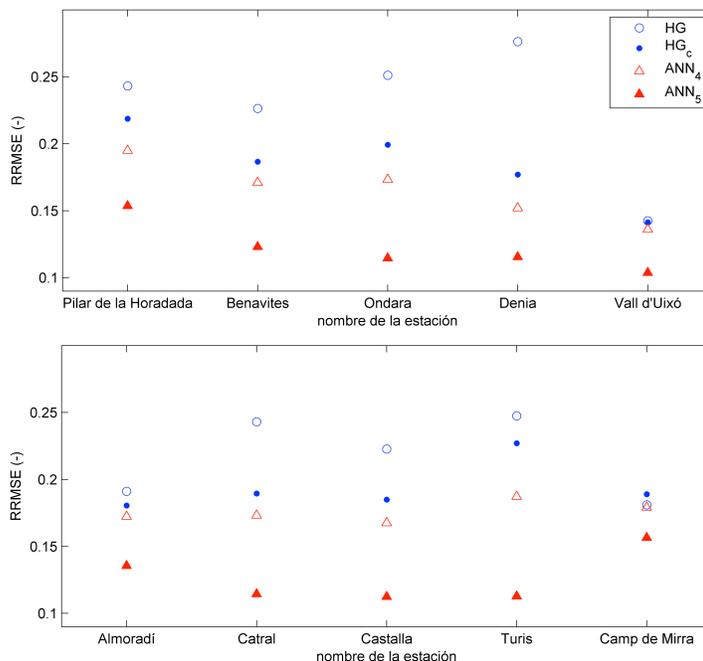


Figura 7: Comparativa de RRMSE por estación.

Finalmente, se plantearía el estudio de la exactitud de las estimaciones en función de la naturaleza de las estaciones (costeras vs. interiores), así como la detección de posibles tendencias de infra/sobreestimación debido al efecto amortiguador del mar y/o a la velocidad local del viento. También se analizarían las causas por las que los modelos ANN podrían presentar menores errores. Por una parte, podrían presentar mejor rendimiento que la ecuación de HG porque se han entrenado con patrones locales (ANN₄ y ANN₅ vs. HG). Por otra parte, la versión calibrada de HG, aunque considera también patrones locales para su calibración, presentaría un rendimiento peor que las ANN porque sólo considera un único parámetro de ajuste por estación, la pendiente. Podría aducirse también una eventual mayor capacidad de vinculación entre inputs y output por parte de las redes. Finalmente, la red ANN₅ permitiría una mejora notable del rendimiento porque, aparentemente, la humedad relativa estaría altamente correlacionada con la ET_0 en las estaciones consideradas.

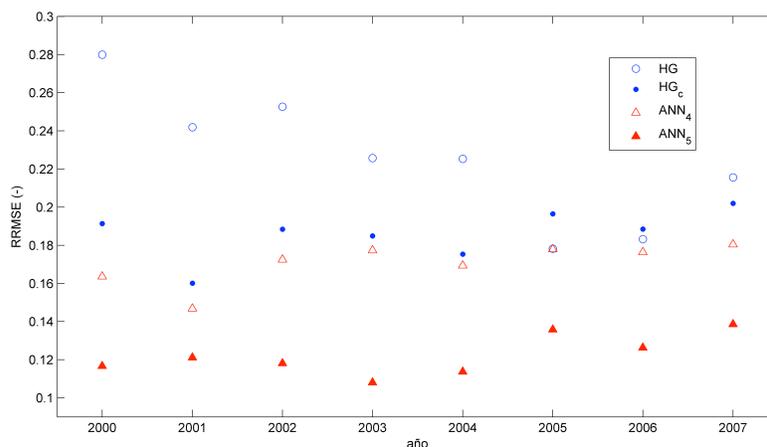


Figura 8: Comparativa de RRMSE por año en Benavites.

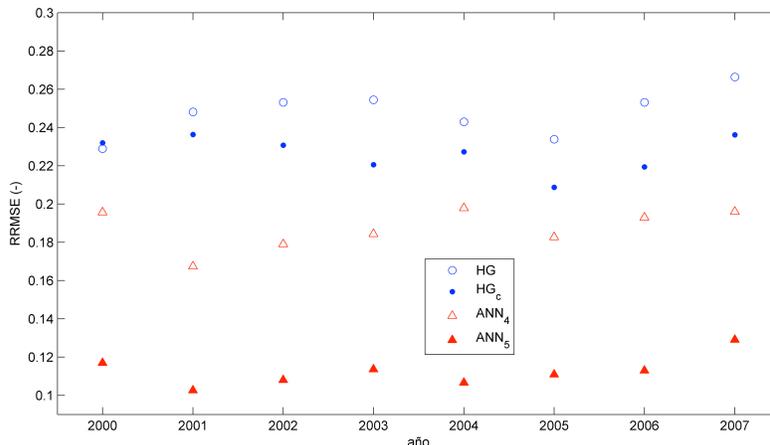


Figura 9: Comparativa de RRMSE por año en Turís.

7 Conclusiones

Se propone una actividad docente práctica para el estudio de la evapotranspiración de referencia mediante redes neuronales artificiales. Esta propuesta pretende introducir al alumno las redes neuronales artificiales como herramienta de modelización, no sólo contemplada como instrumento para uso científico y profesional, sino como recurso pedagógico útil para una mejor visualización y comprensión de fenómenos físicos estudiados en la asignatura. La actividad permite también al alumno llevar a cabo aplicaciones concretas mediante el software MATLAB[®], estudiado en asignaturas anteriores para cálculos matemáticos, para resolver problemas reales dentro del campo de competencias profesionales del futuro ingeniero. Finalmente, la vinculación de la actividad con líneas existentes de investigación permite dar éstas a conocer, así como promover una eventual colaboración de alumnos con la posible incorporación al equipo investigador del departamento de aquellos interesados.

Referencias

-  Allen, R. G., Pereira, L. S., Raes, D., Smith, M. (1998).
Crop evapotranspiration. Guidelines for computing water requirements.
FAO Irrigation and Drainage, paper 56. FAO, Roma.
-  IVIA, Instituto Valenciano de Investigaciones Agrarias.
Servicio de Tecnología del Riego.
www.riegos.ivia.es
-  Zanetti S. S., Sousa E. F., Oliveira V. P. S., Almeida F. T., Bernardo S. (2007).
Estimating evapotranspiration using artificial neural network and minimum climatological data.
Journal of Irrigation and Drainage Engineering, 133(2), 83–89.
-  Hargreaves, G. H., Samani, Z. A. (1985).
Reference crop evapotranspiration from ambient air temperature.
Applied Engineering in Agriculture, 1(2), 96–99.
-  Haykin, S. (Ed.) (1999).
Neural Networks. A comprehensive foundation.
Prentice Hall International Inc., New Jersey.
-  Bishop, C.M. (Ed.) (1995).
Neural Networks for Pattern Recognition.
Oxford University Press, Oxford.