

CALIBRACIÓN DE SENSORES DE HUMEDAD CAPACITIVOS USANDO REDES NEURONALES

J. Arriaga¹, K. Vanderlinden¹, J.L. Muriel¹, M. Morón¹, M.G. Ortega², F.R. Rubio²

¹ I.F.A.P.A., Centro “Las Torres-Tomejil” (Alcalá del Río, Sevilla), (javier.arriaga, karl.vanderlinden, josel.muriel, manuel.moron)@juntadeandalucia.es.

² Depto. Ingeniería de Sistemas y Automática, Universidad de Sevilla, E.T.S.I. Sevilla, (mortega,rubio)@esi.us.es.

RESUMEN. El estudio de la variabilidad espacial de la humedad del suelo a escala de parcela o cuenca agrícola requiere el uso de redes de sensores de humedad de bajo coste, que suelen mostrar una fiabilidad limitada y requieren de calibraciones específicas, especialmente en suelos con elevados contenidos en arcilla. El presente trabajo pretende plantear una calibración más fiable de sondas de humedad mediante un análisis mixto campo-laboratorio. Para la calibración de campo se dispone de datos gravimétricos; para la calibración en laboratorio se han usado columnas de suelo inalterado que tras ser saturadas fueron desecadas en un entorno controlado mientras se monitorizaba la evolución de su peso y la de su humedad volumétrica, medida con diferentes sondas capacitivas Decagon. Tras obtener curvas de secado y la relación entre la humedad gravimétrica y la volumétrica es posible realizar una calibración mejorada específica para cada tipo de suelo. Las redes neuronales son particularmente útiles para el modelado de procesos físicos y el ajuste de modelos. En este trabajo se propone el empleo de dichas herramientas para obtener calibraciones para las sondas analizadas en el tipo de suelo objeto de estudio. Los resultados muestran que dichas calibraciones permiten mejorar la precisión de las mediciones de humedad realizadas.

ABSTRACT. The study of the spatial variability of soil water content at agricultural plot or catchment scales requires the use of low-cost soil water content sensor networks, which usually show a limited reliability and require specific calibrations, specially for soils with a high clay content. This work proposes a more reliable calibration of soil water content probes with a laboratory analysis. Minimally disturbed soil columns were saturated with water and dried in a controlled environment while monitoring the evolution of their volumetric soil water content (with different capacitive Decagon Probes) and weights. After obtaining the drying curves and the relation between the volumetric and the measured gravimetric soil water contents it is possible to achieve an improved calibration specific for different kinds of soil. Neural networks are especially interesting for the modeling of physical processes and model adjustment. In this work, these tools were used in order to obtain improved calibrations for the analyzed probes in the studied soil type. Results show that this calibration improves the accuracy and precision of the obtained soil water content measurements.

La medición adecuada del contenido de agua en suelo resulta crítica para la estimación de los balances de agua y energía, así como para comprender los procesos biológicos y químicos en todo el sistema suelo-planta (Robinson et al., 2008; Vereecken et al., 2008).

Frente a la reflectometría en el dominio del tiempo (TDR), que se ha consolidado como método para la medida de humedad en suelo (Topp et al, 1980; Robinson et al., 2003), las técnicas de medida basadas en sondas de capacitancia y reflectometría en el dominio de la frecuencia (FDR) se han convertido en una alternativa viable debido a sus inherentes ventajas (Kizito et al., 2008): bajo coste, facilidad para almacenamiento de datos, posibilidad de monitorización continua y funcionamiento en un amplio rango de tipos de suelos.

El principal inconveniente de estas técnicas (Chen y Or, 2006) es que, al operar en un espectro de frecuencia en la zona baja del rango de los TDR o menor, son más sensibles a perturbaciones del entorno, como por ejemplo la temperatura, la textura o la conductividad eléctrica (Topp et al., 2000; Zhang et al., 2004; Bogena et al., 2007). La frecuencia de operación es el principal factor que afecta a las medidas de una sonda de capacitancia, provocando sensibilidad frente a cambios en las mencionadas condiciones del suelo.

Los sensores capacitivos Decagon (Decagon Devices, Inc., Pullman, WA) ha tenido un relativo éxito en el mercado; sin embargo, sucesivos trabajos de evaluación y calibración en laboratorio (Blonquist et al., 2005; Jones et al., 2005; Bogena et al. 2007, Bandaranayake et al., 2007, Sakaki et al., 2008, Kizito et al., 2008) han mostrado una gran sensibilidad al tipo de suelo, tensión de alimentación y conductividad eléctrica del suelo.

Las redes neuronales artificiales (RNA) son un modelo matemático estocástico que se inspira en las redes neuronales naturales (biológicas), esto es, pretenden modelar el funcionamiento del sistema nervioso animal. Su aparición se remonta al trabajo de McCulloch y Pitts (1943), que demostraron que un modelo simple con interruptores electrónicos es capaz de modelar con éxito una gran variedad de funciones analíticas.

Una RNA consta de un cierto número de nodos o “perceptrones” agrupados en dos o más capas comunicadas entre sí, de modo que cada nodo de una capa recibe la salida de todos los nodos de la capa anterior; cada perceptrón viene caracterizado por un conjunto de pesos y umbrales obtenidos en el proceso de entrenamiento.

Con la evolución de los computadores electrónicos,

1.- Introducción

matemáticos y neuropsicólogos avanzaron en la materia hasta que en 1958 se desarrolló en el M.I.T. la primera neurocomputadora viable. Minsky y Papert (1969) mostraron varias carencias en el modelo que detuvieron el desarrollo de las RNA hasta que Rumelhart et al. (1986) desarrollaron el método de propagación de errores hacia atrás. Desde ese momento, las RNA experimentaron un amplio desarrollo en multitud de ámbitos gracias a su simplicidad, rapidez y rendimiento; en la segunda mitad de la década de 1990 aparecen las primeras aplicaciones de RNA en los campos de agroecología e hidroecología: modelos de agroecosistemas (Schultz y Wieland, 1997), sistema de regulación de fertilización (Broner y Comstock, 1997). Por su naturaleza, las RNA resultan particularmente interesantes para el modelado de procesos no lineales, como por ejemplo la dinámica de la humedad y salinidad del suelo estudiada por Jahangir y Jagath (1998) o de la retención de agua y conductividad eléctrica del suelo propuesta por Schaap y Leij (1998). Más recientemente, Landeras et al. (2008) compararon el comportamiento de un modelo de evapotranspiración diaria basado en RNA con ecuaciones de modelado empíricas. Además, las RNA se han consolidado como herramienta válida para modelar el sistema dinámico de la evolución de humedad y salinidad en suelo, empleando para ello tanto RNA convencionales (Zou et al., 2010; Dai et al., 2011) como de alto orden (Elshorbagy y Parasuraman, 2008).

En este trabajo se persiguen dos objetivos: por un lado, proponer una mejora de la calibración en laboratorio, exponiendo un protocolo de actuación a tal efecto. Por el otro, evaluar el rendimiento de RNA en la calibración de sensores capacitivos en comparación con los métodos tradicionales de, dado que su utilidad para modelar procesos no lineales lo convierte en un método más prometedor que el ajuste funcional y su simplicidad de programación en un computador digital lo hace viable.

2.- Material y métodos

2.1.- Ámbito del ensayo

Se extrajeron cuatro columnas de suelo inalterado (105mm. de diámetro, 300mm. de altura) de una parcela experimental, situada en la finca experimental "Tomejil", en el término municipal de Carmona (Sevilla), donde se comparan desde 1982 distintos sistemas de manejo de suelo. Dos de las columnas provenían de parcelas elementales bajo siembra directa y otras dos columnas de parcelas bajo laboreo convencional. El suelo, formado sobre margas del mioceno, se clasifica como Typic Haploxerert (Soil Survey Staff, 1999) y tiene un contenido de arcilla entre el 50 y 64%. En dicha finca hay instalada una red de sensores capacitivos Decagon; puesto que la exactitud de esos sensores es limitada, la necesidad de una calibración adecuada de los sensores se vuelve un problema de gran importancia para el desarrollo del experimento.

2.2. – Recogida y tratamiento de muestras

Las cuatro columnas de suelo, contenidas en cilindros perforados de PVC, se saturaron desde la base.

Seguidamente, se insertaron de forma vertical tres sensores diferentes (EC-20, de 25 cm de longitud, operando a 5MHz; y 10HS y 5TE, de 15 y 10 cm. de longitud respectivamente, operando a 70 MHz) en forma aproximada de triángulo isósceles, a 25 mm. desde el centro de cada columna, tal como se muestra en la Fig. 1 (las tres sondas tienen una anchura aproximada de 3.2 cm), y se instalaron las columnas sobre cuatro balanzas de precisión x10000M (Mettler-Toledo, Inc., Columbus, OH) dentro de una estufa de aire forzada modelo 2003721 (JP Selecta S.A., Barcelona). Las balanzas se conectaron a un PC a través de puerto serie usando software de diseño propio para registrar simultáneamente y con una periodicidad de 5 minutos los datos de las cuatro balanzas. Los sensores fueron conectados a dataloggers Em50 (Decagon Devices, Inc., Pullman, WA) que registraron igualmente las mediciones en formato raw (sin procesar) cada 5 minutos. Se llevó a cabo un secado escalonado, alternando períodos de funcionamiento de la estufa a una temperatura constante de 30°C con períodos de inactividad, cada uno de ellos de aproximadamente 48 horas. Durante el proceso se monitorizó la temperatura tanto dentro de la columna (con el sensor 5TE) como del aire en la estufa con un sensor ECT (Decagon Devices, Inc., Pullman, WA). En paralelo a este proceso, se introdujeron en la estufa tres cilindros marcadores, en similares condiciones a las cuatro columnas de suelo bajo estudio, con el propósito de ir retirándolos paulatinamente en tres fases distintas del experimento (en los días 4, 8 y 12, esto es, una sesión completa de secado y reposo entre cada recogida) para estudiar la distribución espacial de la humedad en el interior.

Al terminar el proceso de secado se retiraron los sensores y se secaron las columnas a 105°C durante 48 h. Se obtuvieron un total de 22.612 registros con datos raw, masa y temperatura que se usaron en el análisis posterior.




Fig. 1. Diagrama de la columna de suelo y ubicación de sensores.

2.3.- Calibración

Se utilizó el software matemático Matlab tanto para el ajuste clásico de curvas por mínimos cuadrados basado en el algoritmo de Levenberg-Marquardt (Marquardt, 1963), como para el diseño, entrenamiento y prueba de RNA (Sivanadam y Sumathi, 2005).

El procedimiento a seguir fue unir todos los pares (tiempo, medida) de las cuatro columnas y separarlos por cada tipo de sensor. Empleando las muestras así agrupadas llevamos a cabo la calibración buscando la minimización del error cuadrático medio (RMSE) tanto con polinomios cúbicos como con redes neuronales. La elección de polinomios cúbicos para la comparación se debe a que las curvas de calibración de fábrica de las sondas bajo estudio

son polinómicas (lineal en el caso del EC-20, cúbicas en los otros dos). Se consideró que una calibración específica para este experimento sería siempre más precisa que la calibración de fábrica, lo que permite estudiar las ventajas del empleo de RNA en un contexto adecuado.

Obtenidos ya los dos modelos de calibración, se procedió a comparar la bondad de ambos modelos aplicando las salidas raw de cada uno de los sensores y comparando con la humedad de referencia obtenida de los datos gravimétricos. Para ello, se calculó la humedad gravimétrica a partir de la volumétrica conociendo el dato del volumen en saturación (humedad inicial) y en seco (humedad final); para los valores intermedios, se empleó un volumen calculado por interpolación lineal. Para la comparación de la bondad de las calibraciones se calculó el coeficiente de determinación R^2 y el error cuadrático medio RMSE como se muestra en la Ec. 1. En el último caso, se empleó para comprobar la mejora en los modelos el índice de mejora de la eficiencia de Nash-Sutcliffe, r^2 .

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [y_i - \hat{f}(x_i)]^2}$$

$$R^2 = \frac{\sum_{i=1}^n [y_i - \hat{f}(x_i)]^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad \text{donde } \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (1)$$

$$r^2 = \frac{R_2^2 - R_1^2}{1 - R_1^2}$$

Donde y_i son los n valores de humedad obtenidos a partir de los datos gravimétricos, x_i las medidas raw de los sensores, $\hat{f}(x_i)$ la salida del modelo y R_i^2 los coeficientes de determinación de dos modelos diferentes.

Finalmente, se propone un modelo diferente: puesto que en cada columna hay tres sensores muy próximos en un espacio reducido, se puede asumir de forma razonable que sus medidas de humedad han de ser la misma. Desde ese punto de vista puede ser interesante buscar una calibración múltiple: varios sensores para dar una única medida. Se diseñó una RNA con tres entradas y una salida y se comparó la referencia.

3.- Resultados

3.1.- Recopilación de datos

La tabla 1 muestra los datos recogidos de las cuatro columnas de suelo.

Tabla 1. Datos de las columnas de suelo usadas; LC: laboreo convencional, SD: siembra directa.

Columna	LC-1	LC-2	SD-1	SD-2
Tara (g)	397	373	402	387
Peso saturado (g)	3780	3697	3539	3692
Vol. agua saturado (cm ³)	1105	1101	992	1004
Volumen saturado (cm ³)	2675	2596	2547	2688
Volumen seco (cm ³)	2118	2196	1853	2034

La Fig. 2 muestra los resultados obtenidos de los diferentes sensores de humedad en suelo (medidas

volumétricas) junto a las medidas gravimétricas obtenidas y a las temperaturas tanto en la estufa como en el interior de dos de las columnas (una por manejo). Puede comprobarse cómo la temperatura en el interior del cilindro sigue una dinámica de primer orden con respecto a la temperatura ambiente de la estufa y que conforme el cilindro se va secando, la constante de tiempo de esa dinámica se va reduciendo.




Fig. 2. Medidas de humedad y temperatura en columnas de distinto manejo.

3.2.- Cálculo de las redes neuronales artificiales

Es relativamente fácil obtener una buena calibración para un sensor específico en unas circunstancias concretas. A título de ejemplo, la Fig. 3 muestra cómo una calibración por redes neuronales puede dar lugar a un ajuste prácticamente perfecto en contraste con una calibración polinómica: en el caso de un sensor EC20, cuya calibración de fábrica sigue una norma lineal, una red de tan sólo diez neuronas mejora sustancialmente los resultados de una calibración polinómica cuadrática.

Las tablas 2 y 3 ilustran el efecto de tratar de emplear RNA (20 nodos) entrenadas con un sensor para otro sensor del mismo tipo en cada una de las cuatro columnas de suelo; se resaltaron las diagonales de las matrices de resultados, correspondientes a probar una RNA con el sensor específico para el que fue entrenada.

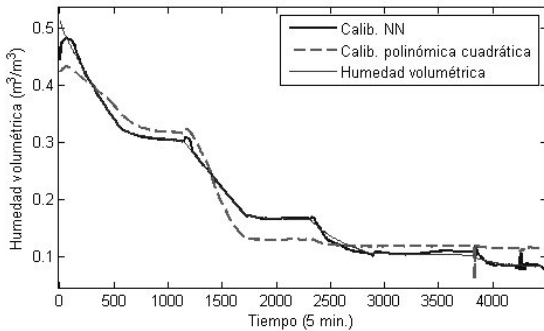


Fig. 3. Calibración específica para un único sensor EC-20.

Tabla 2. RMSE resultado de emplear una RNA entrenada con un sensor con los datos de los demás. Columna izquierda: sensor para el que se entrenó. Fila superior: columnas para las que se obtuvieron los datos.

Sensor	Red	Datos			
		LC-1	LC-2	SD-1	SD-2
EC20	LC-1	0,00504	0,0560	0,0682	0,0574
	LC-2	0,0442	0,00806	0,0281	0,0161
	SD-1	0,0613	0,0412	0,00556	0,0207
	SD-2	0,0436	0,0228	0,0182	0,00415
10HS	LC-1	0,00503	0,0556	0,0682	0,0574
	LC-2	0,0442	0,00806	0,0281	0,0161
	SD-1	0,0613	0,0412	0,00560	0,0207
	SD-2	0,0436	0,0228	0,0182	0,00415
5TE	LC-1	0,00484	0,107	0,0775	0,0800
	LC-2	0,0770	0,0143	0,0398	0,0417
	SD-1	0,0676	0,0411	0,0112	0,0240
	SD-2	0,0672	0,0428	0,0222	0,00965

Tabla 3. Coeficiente de determinación del modelo (análoga a Tabla 2)

Sensor	Red	Datos			
		LC-1	LC-2	SD-1	SD-2
EC20	LC1	0,998	0,682	0,428	0,490
	LC2	0,840	0,993	0,903	0,960
	SD1	0,693	0,828	0,996	0,933
	SD2	0,845	0,947	0,959	0,997
10HS	LC1	0,996	0,305	0,934	0,664
	LC2	0,611	0,977	0,530	0,375
	SD1	0,956	0,440	0,992	0,719
	SD2	0,856	0,314	0,912	0,995
5TE	LC1	0,998	0,917	0,955	0,968
	LC2	0,517	0,979	0,805	0,730
	SD1	0,627	0,829	0,985	0,911
	SD2	0,632	0,815	0,940	0,986

Puede comprobarse una gran variabilidad en el comportamiento de los distintos modelos, observando que el coeficiente de determinación (con excepciones: véase el efecto de la red del 10HS del LC-1 con los datos del LC-2) resulta más alto cuando se utilizan datos de columnas de suelo del mismo manejo, especialmente siembra directa.

A la vista de estos resultados, se propuso calcular una sola RNA para cada modelo de sensor: uniendo las medidas de varios sensores podremos obtener una calibración que sirva en distintas condiciones para distintos sensores; cuanto más diversas sean esas condiciones, mejor será esa calibración general. A cambio, perdemos la precisión que obtendríamos con la calibración específica. Para calcular las RNA correspondientes con los tres modelos de sensores se configuró la red (en los tres casos) para que tuviera una única capa oculta de 30 nodos y se empleó un 70% de las muestras para el entrenamiento y un 15% para las fases de

validación y pruebas. Para el cálculo de la red óptima se buscó la minimización del RMSE mediante el algoritmo de Levenbergh-Marquardt. La tabla 4 muestra los errores cuadráticos medios y el coeficiente de determinación de las tres redes; en ella puede apreciarse un $R^2 > 0,90$ en los tres casos, llegando a alcanzar el valor de 0,96 en el caso del EC20.

Tabla 4. Resultados del entrenamiento de las RNA agrupando los datos por tipo de sensor.

Sensor	RMSE (m³/m³)	R²
EC-20	0,0198	0,955
10HS	0,0318	0,903
5TE	0,0311	0,903

3.3.- Evaluación de resultados

Para poder evaluar la bondad de nuestros resultados, se llevó a cabo un ajuste polinómico de orden tres para cada uno de ellos, obteniendo las expresiones mostradas en la Ec. 2, y se procedió a comparar los resultados.

$$x_{ec20} = \frac{raw_{ec20} - 1157}{287,4}; x_{10hs} = \frac{raw_{10ec} - 1197}{168}; x_{5te} = \frac{raw_{5te} - 736}{407.1}$$

$$y_{ec20} = 0,187x_{ec20}^3 + 0,0203x_{ec20}^2 + 0,0583x_{ec20} + 0,173$$

$$y_{10hs} = 0,00065x_{10hs}^3 + 0,033x_{10hs}^2 + 0,0813x_{10hs} + 0,166 \text{ (Ec. 2)}$$

$$y_{5te} = 0,000749x_{5te}^3 - 0,0109x_{5te}^2 + 0,104x_{5te} + 0,208$$

Tabla 5. Resultado de emplear la calibración global de los sensores sobre los datos de cada sensor.

Columna	Sensor	RNA		Polinómica	
		RMSE (m³/m³)	R²	RMSE (m³/m³)	R²
Laboreo convencional 1	EC-20	0,0389	0,877	0,0411	0,862
	10HS	0,0294	0,930	0,0325	0,914
	5TE	0,0493	0,802	0,0592	0,714
Laboreo convencional 2	EC-20	0,0152	0,977	0,0192	0,963
	10HS	0,0144	0,951	0,0150	0,947
	5TE	0,0336	0,886	0,0358	0,870
Siembra directa 1	EC-20	0,0352	0,848	0,0339	0,858
	10HS	0,0661	0,768	0,0729	0,717
	5TE	0,0260	0,917	0,0283	0,902
Siembra directa 2	EC-20	0,0098	0,985	0,0096	0,986
	10HS	0,0276	0,882	0,0315	0,846
	5TE	0,0158	0,961	0,0193	0,942

La tabla 5 muestra cómo las RNA mejoran el resultado de los ajustes polinómicos en prácticamente todos los casos, llegando a una mejora sensible en casos concretos (5TE en el LC1, 10HS en el SD1) y siendo sólo mínimamente inferior para los casos del sensor LC-20 en siembra directa.

La Fig. 4 muestra la comparación gráfica entre ambas calibraciones en dos casos concretos: el EC20 en el cilindro 1 de laboreo convencional frente al 5TE en el cilindro 2 de siembra directa.

Con respecto a la distribución de humedad en la columna de suelo, podemos ver en la Fig. 5 (donde C1, C2 y C3 son los cilindros marcadores) cómo la variación de ésta en los cilindros marcadores con el diámetro de acuerdo con

las condiciones descritas en la sección anterior es lo bastante reducida como para asumir que no debería afectar a los resultados. Los sensores están insertados en puntos donde se mide el valor medio, que viene representado en la Fig. por las líneas horizontales. Los niveles medios de humedad cumplen que $\theta_{g1} > \theta_{g2} > \theta_{g3}$, lo que es coherente con las fechas de extracción.

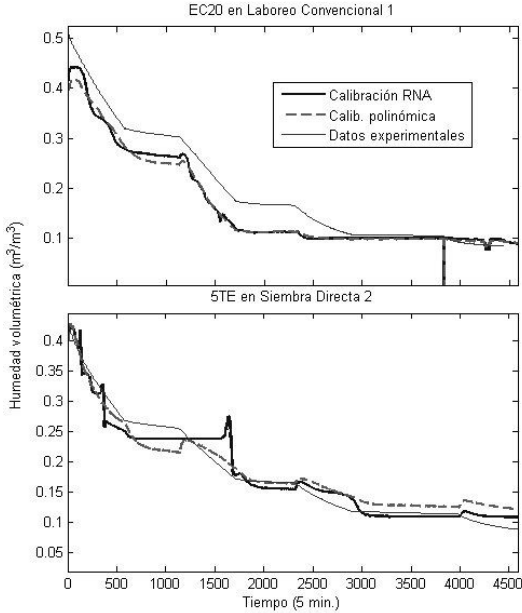


Fig. 4. Comparación gráfica de calibraciones (dos columnas: EC20 en LC1, 5TE en SD2).




Fig. 5. Distribución de humedad gravimétrica en columnas de suelo.

3.4.- Modelo de tres sensores.

Finalmente se diseñó una única RNA en similares condiciones a las anteriores: una capa oculta de 30 perceptrones, pero con la diferencia de ser una red multivariable (tres entradas, una salida); por ello la capa de entrada, que en origen tenía un nodo, ahora tendrá tres, y los nodos de la capa oculta tendrán tres pesos cada uno.

En estas condiciones se obtiene un coeficiente de determinación $R^2=0,991$ y un error cuadrático medio $RMSE=0,012 (m^3/m^3)^2$. La curva de regresión puede verse en la Fig. 6.

Los resultados para cada uno de los cuatro casos pueden verse en la tabla 6. Puede observarse que en los cuatro casos hemos logrado un error de calibración mínimo y el índice de mejora de la eficiencia de Nash-Sutcliffe con respecto a los

modelos obtenidos anteriormente supera el 57% para los sensores en columnas de siembra directa (86% en media) y el 91% para los de laboreo convencional (97% en media).




Fig. 6. Curva de regresión para RNA multivariable. “Target”: humedad obtenida a partir de los datos gravimétricos; “output”: salida del modelo de RNA.

Tabla 6. Resultado de aplicar el modelo multivariable a las columnas de suelo. r^2 : término de mejora de la eficiencia con respecto a los resultados de la tabla 5.

	RMSE (m³/m³)	R²	r² EC20	r² 10HS	r² 5TE
Lab. conv. 1	0,00453	0,998	0,985	0,975	0,991
Lab. conv. 2	0,00428	0,998	0,917	0,961	0,983
Siembra directa 1	0,0129	0,960	0,718	0,807	0,580
Siembra directa 2	0,00712	0,960	0,727	0,963	0,894

La Fig. 7 muestra las curvas de las cuatro columnas de suelo; en todos los casos, la red neuronal obtenida es capaz de llevar a cabo un seguimiento con error mínimo, especialmente para humedades volumétricas por debajo del 35%. La presencia de los mayores errores en humedades elevadas puede achacarse a que el entrenamiento se hizo con un subconjunto aleatorio del conjunto completo de medidas, en los que las humedades volumétricas obtenidas tienen en su mayoría valores bajos.

4.- Conclusiones

Se ha planteado un protocolo de calibración de sensores de humedad en suelo de la familia ECH₂O de Decagon consistente en extraer muestras inalteradas del suelo de la parcela a estudiar y trasladarlos al laboratorio para su tratamiento. De este modo se consigue una calibración específica para el tipo de suelo de la parcela sin la complejidad que acarrea una calibración en campo, al llevarse a cabo en un entorno controlado. La obtención de la humedad volumétrica a partir de los datos gravimétricos permite una calibración más fiable y eficiente de los sensores de humedad en suelo.

Las redes neuronales artificiales, por su versatilidad y simplicidad de implementación en un computador, pueden resultar útiles para la calibración de sensores. Los resultados mostraron una sustancial mejora en la calibración de los sensores 10HS y 5TE y escasa diferencia en la de los sensores EC-20 con respecto a una calibración basada en ajuste por polinomios cúbicos específica para el mismo problema. Finalmente, la

posibilidad de diseñar una RNA con varias entradas abre la puerta al empleo de varios sensores en un espacio limitado para obtener una medida fiable de la humedad volumétrica aunque las medidas de éstos sean diferentes.

Se plantea para futuros experimentos el uso de varios sensores del mismo tipo para evaluar el número de sensores necesarios para obtener una medida fiable, afrontando de este modo el problema del control de calidad de los datos. En nuestro caso, el empleo de tres sensores de diferentes modelos nos permitió obtener coeficientes de determinación que, en el peor de los casos posibles, eran superiores a 0,95, lo que muestra claramente la idoneidad del método.




Fig. 7. Calibración multisensor para las cuatro columnas de suelo.

Agradecimientos. Los autores desean agradecer al Ministerio de Ciencia e Innovación y FEDER por la financiación del proyecto AGL2009-12936-C03-03, así como a la CEIC (Junta de Andalucía) por la financiación del proyecto AGR-4782. Además, J. Arriaga desea agradecer al I.N.I.A. la beca predoctoral FPI-INIA 73 de 2008 y K. Vanderlinden agradece al Ministerio de Educación la ayuda de movilidad P2010-0191.

5.- Bibliografía

Bandaranayake, W.M., Parsons, L.R., Borhan, M.S. y Holeyton, J.D., 2007. Performance of a capacitance-type soil water probe in a well-drained sandy soil, *Soil Sci. Soc. Am. J.* 71: 993-1002.
 Blonquist, J.M., Jones, S.B. y Robinson, D.A., 2005. Standardizing characterization of electromagnetic water content sensors: Part 2, *Vadose Zone J.* 4: 1059-1069.
 Chen, Y. y Or, D., 2006. Geometrical factors and interfacial processes affecting complex dielectric permittivity of partially saturated porous

media, *Water Resour. Res.*, W06423.
 Bogen, H.R., Huisman, J.A., Oberdorster, C. y Vereecken, H., 2007. Evaluation of a low-cost soil water content sensor for wireless network applications, *J. Hydrol.* 344: 32-42
 Broner, I. y Comstock, R., 1997, *Combining expert systems and neural networks for learning site-specific conditions, Comp. and Electr. in Agriculture*, 19: 37-53.
 Dai, X., Huo, Z. y Wang, H., 2011. Simulation for response of crop yield to soil moisture and salinity with artificial neural network, *Field Crops Research* 121: 441-449.
 Elshorbagy, A. y Parasuraman, K., 2008. On the relevance of using artificial neural networks for estimating soil moisture content, *J. of Hydrology*, 362: 1-18.
 Jahangir, M. y Jagath, J.K., 1998. Application of artificial neural network and genetic algorithm in flow and transport simulations, *Advances in Water Resources* 22: 145-158.
 Landaras, G., Ortiz-Barredo, A. y Lopez, J.J., 2008. Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain), *Agric. Water Manag.*, 95: 553-565.
 Jones, S.B., Blonquist, J.M., Robinson, D.A., Rasmussen, V.P. y Or, D., 2005. Standardizing characterization of electromagnetic water content part I. Methodology, *Vadose Zone Journal* 4: 1048-1058.
 Kizito, F., Campbell, C.S., Cobos, D.R., Teare, B.L., Carter, B. y Hopmans, J.W., 2008. Frequency, electrical conductivity and temperature analysis of a low-cost capacitance soil moisture sensor, *J. of Hydrology* 352: 367-378.
 Marquardt, D., 1963. An algorithm for least-squares estimation of nonlinear parameters, *SIAM J. on Applied Math.*, 11, pp. 431-441.
 McCulloch, W.S. y Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity, *Bul. of Math. Biol.*, 5, pp. 115-133.
 Minsky, M. y Papert, S., 1969. *Perceptrons*, MIT Press, Cambridge, MA.
 Robinson, D.A., Jones, S.B., Wraith, J.A., Or, D. y Firedmen, S.P., 2003. A review of advances in dielectric and previous terreelectrical conductivity measurements in soils using time domain reflectometry, *Vadose Zone J.* 2: 444-475.
 Robinson, D.A., Campbell, C.S., Hopmans, J.W., Hornbuckle, B.K., Jones, S.B., Knight, R., Ogden, F., Selker, J. y Wendroth, O., 2008. Soil moisture measurement for ecological and hydrological watershed-scale observatories: A review. *Vadose Zone J.*, 7: 358-389.
 Rumelhart, D., Hinton, G. y Williams, R., 1986. Learning representations by back-propagating errors. *Nature*, 323: 533-536.
 Sakaki, T., Limsuwat, A., Smits, K.M. y Illangsekare, T.H., 2008. Empirical two-point a-mixing model for calibrating the ECH2O EC-5 soil moisture sensor in sands, *Water Resour. Res.* 44, W00D08.
 Schaap, M.G. y Leij, F.J., 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity, *Soil Till. Re.* 47: 37-42.
 Schultz, A. y Wieland, R., 1997. The use of neural networks in agroecological modeling, *Comp. and Electr. in Agriculture* 18: 73-90.
 Sivanadam, S.N. y Sumathi, S., 2005. *Introduction to neural network using MATLAB 6.0*, Tata McGraw-Hill.
 Soil Survey Staff. 1999. *Soil taxonomy: a basic system of soil classification for making and interpreting soil surveys, 2nd ed. Agric. Handbk. 436*. U.S. Gov. Print. Office, Washington, DC.
 Topp, G.C., Davis, J.L. y Annan, A.P., 1980. Electromagnetic determination of soil water content: measurements in coaxial transmission lines. *Water Resour. Res.* 16: 574-582.
 Topp, G.C., Zegelin, S. y White, I., 2000. Impacts of the real and imaginary components of relative permittivity on time domain reflectometry measurements in soils, *Soil Sci. Soc. Am. J.* 64: 1244-1252.
 Vereecken, H., Huisman, J.A., Bogen, H., Vanderborcht, J., Vrugt, J.A. y Hopmans, J.W., 2008. On the value of soil moisture measurements in vadose zone hydrology: a review, *Water Resour. Res.*, 44, W00D06.
 Zhang, N., Fan, G., Lee, K.H., Kluitenberg, G.J. y Loughin, T.M., 2004. Simultaneous measurement of soil water content and salinity using a frequency-response method, *Soil Sci. Soc. Am. J.* 68: 1515-1525.
 Zou, P., Yang, J., Fu, J., Liu, G. y Li, D., 2010. Artificial neural network and time series models for predicting soil salt and water content, *Agricultural Water Management*, 97: 2009-2019.