

## Control PI neuro-adaptable en tiempo real de la humedad en el suelo usando un modelo híbrido

Juan Gomez \*, Francisco Rossomando, Flavio Capraro, Carlos Soria

*Instituto de Automática (INAUT)-Universidad Nacional de San Juan - Consejo Nacional de Investigaciones Científicas y Técnicas. San Juan, Argentina*

**To cite this article:** Gomez, J., Rossomando, F., Capraro, F., Soria, C. 2023. Real-time neuro-adaptive PI control of soil moisture using a hybrid model. Revista Iberoamericana de Automática e Informática Industrial 20, 93-103. <https://doi.org/10.4995/riai.2022.17106>

### Resumen

En la agricultura que se desarrolla en los valles cordilleranos de Argentina, el uso eficiente del agua destinada para el riego es fundamental para el desarrollo y sustentabilidad de los emprendimientos agrícolas. A fin de abordar este desafío, se propone lograr un modelo híbrido que permita representar con la mayor fidelidad posible la dinámica del contenido de agua en un suelo bajo riego por goteo, incluyendo la extracción de agua por parte de un cultivo. Para esto, se cuenta con la formulación de un modelo matemático del proceso basado en la ecuación general de flujo, la cual ha sido resuelta mediante diferencias finitas. Se incorpora a esta estructura una red neuronal de base radial (RBF) para compensar de manera *off-line* la salida del modelo en un punto del suelo, identificando el error de salida. Además, este estudio incorpora el diseño de un controlador de riego de tipo adaptable para dinámicas desconocidas. El diseño está basado en superficies deslizantes en combinación PI y redes neuronales, siendo el objetivo de control mantener el contenido de agua en el suelo a determinado valor de referencia establecido.

*Palabras clave:* riego preciso, modelo de humedad del suelo, riego por goteo, control PI neuronal

### Real-time neuro-adaptive PI control of soil moisture using a hybrid model

#### Abstract

In the agriculture developed in the mountain valleys of Argentina, the efficient use of water for irrigation is essential for the development and sustainability of agricultural enterprises. In order to address this challenge, it is proposed to develop a hybrid model to represent as faithfully as possible the dynamics of water content in an irrigated soil, including water extraction by a crop. For this purpose, a mathematical model of the process is formulated based on the general flow equation, which has been solved by means of finite differences. A radial-based neural network is incorporated into this structure to compensate *off-line* the model output at a point on the ground, identifying the output error. In addition, this study incorporates the design of an adaptive irrigation controller for unknown dynamics. The design is based on sliding surfaces in combination with PI and neural networks, with the goal of control objective is to maintain the soil water content at reference values setting.

*Keywords:* precise irrigation, soil moisture model, drip irrigation, neural PI control.

### 1. Introducción

A escala global, el consumo de agua dulce por parte del sector agrícola es de aproximadamente el 70 % disponible a nivel mundial, convirtiéndose en el mayor consumidor de este recurso (Knox et al., 2012). Además, se estima que el 40 % del agua dulce utilizada para la agricultura en los países en desarrollo se

pierde, ya sea, por evaporación, derrames o filtración hacia las capas más profundas del suelo, fuera del alcance de las raíces de las plantas. Por otro lado, en países desarrollados, la industria llega a consumir hasta un 50 % del agua disponible para consumo humano (FAO, 2016).

De modo que, se hace necesario implementar nuevas metodologías, como el riego de precisión (Smith et al., 2010), que

\* Autor para correspondencia: [jgomez@inaut.unsj.edu.ar](mailto:jgomez@inaut.unsj.edu.ar)

permitan considerar las problemáticas actuales de derroche y escasez.

En un sistema de riego localizado (por ejemplo, el riego por goteo), resulta muy importante conocer la distribución de agua en el suelo para evitar pérdidas por percolación y conseguir un nivel de producción óptimo (Arbat et al., 2003). De esta manera, se tienen mejores bases para proyectar el riego y planear las prácticas de riego a nivel de parcelas. Para ello, es necesario que en el diseño del sistema de riego se pueda estimar las dimensiones del bulbo húmedo generado dentro del sistema radicular del cultivo (Prado Hernández et al., 2017).

Hasta el momento, se han realizado diversos trabajos para representar la forma de la zona húmeda en un suelo cuando se utilizan sistemas de riego por goteo, empleando diferentes estrategias de modelado. Entre los métodos usados se encuentran aquellos que emplean soluciones empíricas o semi-empíricas, analíticas o simplificaciones numéricas.

Existen dos modelos con buena aceptación en el área de recursos hídricos que simulan el flujo de agua en un medio insaturado mediante la ecuación de Richards. Esta ecuación se resuelve mediante el método de los elementos finitos en el modelo *HYDRUS-2D* (Simunek et al., 2018) y mediante el método de las diferencias finitas en el modelo *Drip-Irrigator* (Arbat et al., 2013).

La dinámica del proceso en cualquier sistema de riego agrícola, también puede ser descrita mediante un modelo de balance hídrico como la suma y resta de los flujos entrantes y salientes de dicho sistema en balance (Lozoya et al., 2014; Sahbani and Ferjani, 2018).

Otros trabajos han realizado el modelado de la dinámica hídrica en el suelo mediante redes neuronales artificiales. En (Capraro et al., 2008) se desarrolló un controlador de riego simplificando el modelo a la predicción de humedad a dos niveles de profundidad del suelo; mientras que en (Elnesr and Alazba, 2017) se ha integrado los datos generados con el modelo *Hydrus 2D/3D* convertidos en vectores de tres variables para generar elipses de humedad.

Por otra parte, con el uso de modernas técnicas de control automático, se han logrado importantes aportes en orden al riego de precisión, en donde se han desarrollado controladores de riego que suministran las aplicaciones de riego en el momento adecuado y con la cantidad de agua necesaria para el cultivo (Albertos and Mareels, 2010). A continuación, se detallan algunos de ellos.

La inteligencia artificial aplicada al control permite solucionar aquellos problemas que son complejos y no lineales. En (Vita Serman et al., 2012) se ha utilizado un controlador de riego inteligente en un olivar comercial; para determinar el riego se realimenta el nivel de humedad del suelo y se predice el efecto de futuras aplicaciones de riego mediante el uso de una red neuronal (RN) tipo feedforward. Con ello se logró la aplicación de riego eficiente y sin pérdida de agua por percolación, lo cual favoreció la calidad de las aceitunas a fin de la campaña.

En (Yahyaoui et al., 2017) se implementa lógica difusa dentro del sistema de control para la gestión del agua y energía durante el ciclo vegetativo del tomate, considerando un modelo detallado para la evapotranspiración y frecuencia de riego de los tomates, según las características del sitio y los cultivos.

En (Choudhary et al., 2019), se plantea un sistema de riego

automático basado en la técnica de inteligencia artificial *machine learning*, para identificar y predecir patrones de lluvia y cambios climáticos según datos históricos. De esta forma, los cultivos se riegan selectivamente solo cuando es necesario según el clima y las condiciones de humedad del suelo en tiempo real. El sistema se ha probado en un entorno controlado con una precisión del 80 %.

En el presente trabajo, se presenta un controlador automático de riego que sea capaz de adaptarse a los diferentes tipos de suelo que existen en la provincia de San Juan, Argentina. Para ello, se implementa un controlador inteligente que permita mantener los niveles de humedad alrededor de los valores deseados. Los sistemas inteligentes en riego han sido abordados por varios autores como se describió anteriormente, sin embargo, aquí se plantea el uso de un PI neuronal, con la ventaja de ser adaptable y de fácil implementación.

Los resultados del control son aplicados a un modelo de simulación que permita visualizar una estimación de la dinámica del área húmeda por debajo de la superficie cultivada e irrigada. El modelado se realiza a partir de las ecuaciones que describen la dinámica del suelo en el modelo *Drip-Irrigator*, incorporando la extracción por parte de un cultivo de olivo. El modelo matemático, se complementó con una red neuronal de base radial para identificar el error del modelo y con este ajustar el valor en un punto de interés donde se implementa el control.

## 2. Materiales y métodos

En esta sección se describe la formulación de un modelo matemático que permite conocer el nivel de humedad en ciertos lugares del bulbo húmedo que se genera en el suelo cuando es regado. Dicho modelo, presenta el inconveniente que requiere contar con parámetros precisos del suelo para alcanzar una buena estimación de la humedad en cada punto del perfil de humedad. Esto, en ocasiones es difícil de obtener o medir, como así también, la heterogeneidad en el perfil del suelo dificulta la parametrización.

Debido a ello, se ha planteado complementar el modelo matemático con una red neuronal para identificar el error debido al modelo y a las desviaciones producidas en los valores de los parámetros del suelo. De esta forma, combinando el modelo empírico y la RN, se logra ajustar la humedad en un punto característico dentro de la zona húmeda. El valor de humedad es utilizado por un controlador de riego para determinar las aplicaciones de agua de manera oportuna con el objetivo de mantenerla dentro de los valores requeridos por el cultivo.

### 2.1. Modelo de movimiento del agua en el suelo

El modelo *Drip-Irrigator* resuelve numéricamente la ecuación general de flujo usando un esquema de diferencias finitas basado en un método propuesto inicialmente por (Van der Ploeg and Benecke, 1974) y que posteriormente ha sido ampliado en (Armstrong and Wilson, 1983; Khatri, 1984; Ramirez de Cartagena Bisbe and Sáinz Sánchez, 1997; Pujolràs, 2006) con resultados satisfactorios. En todos estos trabajos se plantea el problema de conocer y asignar con precisión los parámetros del suelo dentro del modelo y los posibles errores de estimación asociados a la heterogeneidad que se presenta en el perfil del suelo.

La ecuación general de flujo de agua en el suelo (conocida también como ecuación de Richards) en condiciones de régimen variable y no saturado, para un sistema en cultivo adopta la expresión:

$$\frac{\partial \theta}{\partial t} = \nabla [K(\theta) \nabla \psi_h] - S \quad (1)$$

donde,  $\partial \theta / \partial t$  es la variación del contenido de agua volumétrico respecto del tiempo y la posición;  $\nabla$  vector operador diferencial, representando el gradiente tridimensional;  $K$  conductividad hidráulica;  $\psi_h$  potencial hidráulico;  $S$  extracción de agua por la planta.

Asumiendo simetría axial respecto al eje vertical que pasa por el gotero de riego, (1) queda simplificada según la siguiente expresión:

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial x} (K(\theta) \frac{\partial \psi_h}{\partial x}) + \frac{\partial}{\partial z} (K(\theta) \frac{\partial \psi_h}{\partial z}) - S \quad (2)$$

donde  $x, z$  son las direcciones en un plano horizontal y vertical, respectivamente.

La relación entre contenido de agua, conductividad y potencial de presión hidráulica representan relaciones constitutivas de la ecuación de Richards (1). Su caracterización se establece a partir de las ecuaciones de Mualem-Van Genuchten:

$$S_e = \frac{\theta - \theta_r}{\theta_s - \theta_r} = \left[ \frac{1}{1 + (\alpha \psi_h)^n} \right]^m \quad (3)$$

$$\theta(\psi_h) = \begin{cases} \theta_r + \frac{(\theta_s - \theta_r)}{[1 + (\alpha \psi_h)^n]^m} & \psi_h \geq 0 \\ \theta_s & \psi_h < 0 \end{cases} \quad (4)$$

$$K(S_e) = K_s S_e^l \left[ 1 - \left( 1 - S_e^{\frac{1}{m}} \right)^m \right]^2 \quad (5)$$

$$m = 1 - \frac{1}{n} \quad n > 1 \quad (6)$$

Donde,  $\theta(\psi_h)$  es la humedad volumétrica  $L^3 \cdot L^{-3}$ ;  $\theta_r$  es el contenido de agua residual  $L^3 \cdot L^{-3}$ ;  $\theta_s$  es el contenido de agua saturada  $L^3 \cdot L^{-3}$ ;  $K_s$  es la conductividad hidráulica saturada  $L \cdot T^{-1}$  y;  $\alpha, n$  y  $m$  son parámetros de ajuste característicos de cada tipo de suelo.

### 2.1.1. Resolución de términos diferenciales

Para resolver (2), en primer lugar, se define un cilindro en el suelo por debajo del suministro de agua (para el caso de un sistema de riego por goteo corresponde a un gotero insertado en la línea secundaria o manguera de riego). Luego, se divide el cilindro en anillos concéntricos de ancho  $\Delta_j$  y alto  $\Delta_i$ , ubicando en el centro de la parte superior, el gotero de riego y la base de la planta, como se representa en la (Figura 1). Las dimensiones del mallado deben ser tales que las paredes no limiten el movimiento del agua dentro del bulbo húmedo y otorgada por el gotero. Además, es necesario determinar las condiciones iniciales del contenido volumétrico de agua de todas las celdas ( $\theta_0$ ).




Figura 1: Representación geométrica del área de interés, dividida en anillos circulares concéntricos por debajo del cultivo. Fuente: (Ramírez de Cartagena Bisbe and Sáinz Sánchez, 1997)

Posteriormente, se calculan los caudales que fluirán desde o hacia la celda  $(i, j)$  a través de los contornos de las celdas vecinas. Los flujos laterales dependen de la posición en que se encuentre la misma dentro de la malla creada. De esta forma, se generan 9 zonas representativas, que se diferencian entre sí por la existencia o no de intercambio con los laterales, esto se representa en la (Figura 2).

En las zonas que se encuentran en los bordes no existe flujo de agua con el exterior, excepto en la región 1 donde el gotero (entrada del sistema) suministra un caudal de agua fijo y en la regiones inferiores. A diferencia del modelo *Drip-Irrigator*, en este trabajo se consideró drenaje libre en dicha región (7,8 y 9). Para resolver la impermeabilidad de los contornos se utilizaron nodos ficticios ubicados fuera del dominio de estudio. En la zona 5, que es la única interior, las transferencias de agua se realizan como se había advertido anteriormente con todas las celdas vecinas (11)-(14).




Figura 2: Mallado y división del suelo en regiones. Interacción entre celdas adyacentes. Fuente: (Ramírez de Cartagena Bisbe and Sáinz Sánchez, 1997)

El cálculo del caudal que fluye entre dos celdas es determinado por la siguiente expresión:

$$Q = qA \quad (7)$$

Donde,  $q$  es la densidad de flujo de agua y  $A$  es el área de interacción entre las celdas. De esta manera, aplicando la ley de Darcy:

$$Q = -K_n \frac{\Delta \psi_h}{\Delta L} A \quad (8)$$

Siendo,  $K_n$  la conductividad hidráulica neta en la celda considerada,  $\Delta \psi_h$  y  $\Delta L$  la diferencia de potencial hidráulico y la

distancia entre celdas adyacentes, respectivamente.

Para formular matricialmente los caudales de entrada y los que fluyen dentro del mallado creado, se describen de forma separada las ecuaciones que definen dichos flujos

El ingreso de agua al mallado se realiza por medio de las celdas contenidas dentro de la zona 1, cuyo caudal es el que aporta el gotero de riego ( $Q_{got}$ ) distribuido en la cantidad de celdas saturadas ( $p$ ), mientras el estado de la válvula ( $V$ ) sea activo.

$$Q_e = B \left( \frac{Q_{got}}{p} \right) V = Q_i V \quad (9)$$

Siendo,  $Q_e \in \mathbb{R}^{i \times j}$  la matriz de entrada de agua debido al riego por goteo;  $Q_i = B(Q_{got}/p)$ , donde,  $Q_i \in \mathbb{R}^{i \times j}$  y la matriz  $B \in \mathbb{R}^{i \times j}$  asigna un valor nulo a las celdas fuera de la región de ingreso de agua y cuyos elementos  $b_{ij}$  se definen como:

$$b_{ij} = \begin{cases} 1 & i = 1, 1 \leq j \leq p \\ 0 & \text{en otro caso} \end{cases} \quad (10)$$

Por otra parte, según (8) los flujos de caudal entre la celda genérica ( $i, j$ ) y sus celdas vecinas vienen dados por el siguiente conjunto de ecuaciones:

$$Q_{izq} = \left( \frac{K_{izq} + K}{2} \right) \left( \frac{\Psi_h - \Psi_{hizq}}{\Delta_j} \right) (2\pi R_j \Delta_i) \quad (11)$$

$$Q_{der} = \left( \frac{K_{der} + K}{2} \right) \left( \frac{\Psi_h - \Psi_{hder}}{\Delta_j} \right) (2\pi R_{j+1} \Delta_i) \quad (12)$$

$$Q_{sup} = \left( \frac{K_{sup} + K}{2} \right) \left( \frac{\Psi_h - \Psi_{hsup}}{\Delta_i} \right) \pi (R_{j+1}^2 - R_j^2) \quad (13)$$

$$Q_{inf} = \left( \frac{K_{inf} + K}{2} \right) \left( \frac{\Psi_h - \Psi_{hinf}}{\Delta_i} \right) \pi (R_{j+1}^2 - R_j^2) \quad (14)$$

Donde,  $Q_{izq}, Q_{der}, Q_{sup}, Q_{inf} \in \mathbb{R}^{i \times j}$ ; la conductividad hidráulica  $K_n$  se toma como la media aritmética entre los valores de conductividad de las celdas genéricas  $K \in \mathbb{R}^{i \times j}$  y sus vecinas  $K_{izq}, K_{der}, K_{sup}$  o  $K_{inf} \in \mathbb{R}^{i \times j}$ ;  $R_j$  y  $R_{j+1} \in \mathbb{R}^{i \times j}$  son el radio interior y exterior del anillo, respectivamente; y  $\Delta_{i,j}$  tienen el mismo significado que  $\Delta L$ .

Luego, el caudal neto  $Q_n \in \mathbb{R}^{i \times j}$ , en el paso actual, con excepción de las celdas contenidas en la zona 1, se obtiene haciendo un balance de (11)-(14):

$$Q_n = Q_{der} + Q_{izq} + Q_{inf} + C Q_{sup} \quad (15)$$

Donde, los elementos  $c_{ij}$  de la matriz  $C \in \mathbb{R}^{i \times j}$  se definen como:

$$c_{ij} = \begin{cases} 0 & i = 1, 1 \leq j \leq p \\ 1 & \text{en otro caso} \end{cases} \quad (16)$$

Siendo,  $p$  el total de celdas saturadas en la primera fila. El producto entre la matriz  $C$  y  $Q_{sup}$  asigna un aporte nulo de este término a las celdas saturadas de la primera fila.

Ahora, a partir de las matrices de caudal de ingreso y de flujo entre celdas, puede calcularse la variación del contenido volumétrico de agua de los anillos genéricos que forman el cilindro:

$$\dot{\theta} = \frac{Q_e + Q_n}{V_o} = \frac{Q_i V + Q_n}{\pi (R_{j+1}^2 - R_j^2) \Delta_i} \quad (17)$$

Siendo  $V_o \in \mathbb{R}^{i \times j}$  el volumen de los anillos concéntricos que forman el cilindro.

### 2.1.2. Término de extracción de agua por el cultivo

El ingreso de agua a la planta se realiza por medio de las raíces, proceso que es tan importante como la salida de esta por los poros de las hojas (estomas). Este proceso se llama transpiración y consiste en la pérdida de agua en forma de vapor desde la planta hacia la atmósfera.

La demanda de agua por parte de las plantas es variable, ya que depende de muchos factores como el clima, el tipo de planta, el estado fenológico, entre otros. Por otra parte, el suelo también posee la capacidad de retener agua y perderla por evaporación. La combinación de estos dos procesos de transpiración y evaporación dan origen a un indicador de cuánto ha sido la demanda atmosférica, conocido como la evapotranspiración de referencia ( $ET_0$ ), y en relación a ella, cuánta cantidad de agua debe reponerse al suelo para cubrir la demanda hídrica del cultivo ( $ET_c$ ) (Allen et al., 2006).

Existen distintos métodos para estimar la  $ET_0$ , entre ellos se encuentra la medición de las variables climáticas mediante una estación meteorológica. Las estaciones comerciales estiman de forma automática la evapotranspiración de referencia como dato común a cualquier tipo de cultivo. El cálculo de este índice se basa en el método Penman-Monteith (Allen et al., 2006) que precisa de la medición de distintas variables climáticas.

Luego, es necesario afectar el valor de  $ET_0$  por un coeficiente de cultivo  $K_c$ . De esta manera, se define la evapotranspiración de cultivo  $ET_c$  ( $L \cdot T^{-1}$ ), en su forma mas simple como:

$$ET_c = ET_0 K_c \quad (18)$$

En este sentido, se propone el modelo de absorción de agua por parte de las raíces presentado en (Vrugt et al., 2001). Se define la distribución espacial adimensional de la raíz con la profundidad  $\beta$  como:

$$\beta(z) = \left( \frac{1-z}{z_m} \right) e^{-\frac{p_z}{z_m} |z^* - z|} \quad (19)$$

Donde  $z_m$  es la profundidad máxima de enraizamiento  $L$ ;  $p_z(-)$  y  $z^*(L)$  son parámetros empíricos.

Para la caracterización de la intensidad de captación a lo largo de la dirección radial, se utiliza una expresión similar a (19):

$$\beta(r) = \left( \frac{1-r}{r_m} \right) e^{-\frac{p_r}{r_m} |r^* - r|} \quad (20)$$

Donde,  $\beta(r)$  denota la distribución espacial adimensional de la absorción de agua por parte de las raíces en la dirección radial;  $r_m$  es la longitud máxima de enraizamiento en la dirección radial ( $L$ );  $r$  es la distancia radial desde el origen de la planta ( $L$ ) y  $p_r$  y  $r^*$  son parámetros empíricos con unidades (-) y ( $L$ ), respectivamente.

La combinación de la intensidad de absorción a lo largo de la dirección  $z$  (19) con la intensidad de absorción a lo largo de la dirección  $r$  (20) conduce a un modelo bidimensional de absorción de agua por la raíz, expresada como:

$$\beta(r, z) = \left( \frac{1-z}{z_m} \right) \left( \frac{1-r}{r_m} \right) e^{-\frac{r}{z_m} |z^* - z| - \frac{r}{r_m} |r^* - r|} \quad (21)$$

Donde  $\beta(r, z)$  denota la distribución espacial bidimensional de la absorción de agua por las raíces.

Dado que la absorción potencial acumulada de agua por las raíces debe ser igual a la tasa de transpiración potencial  $T_{pot}$ , la distribución normalizada de la absorción de agua por las raíces  $S_m$  se calcula:

$$S_m = \frac{\pi R^2 \beta(r, z) T_{pot}}{2\pi \int_0^{r_m} \int_0^{z_m} r \beta(r, z) dr dz} \quad (22)$$

Denotando  $S_m$  el volumen de agua extraído por unidad de tiempo y volumen de suelo, suponiendo simetría axial. Los parámetros  $z_m$  y  $r_m$  se pueden actualizar ante el crecimiento de las raíces haciéndolos dependientes del tiempo durante una temporada de crecimiento.

Las condiciones de estrés debidas a sequedad o humedad del suelo pueden reducir el valor de (22). Por ello, se incluye una función de respuesta al estrés hídrico del suelo (Feddes et al., 2001) descrita en la (Figura 3).

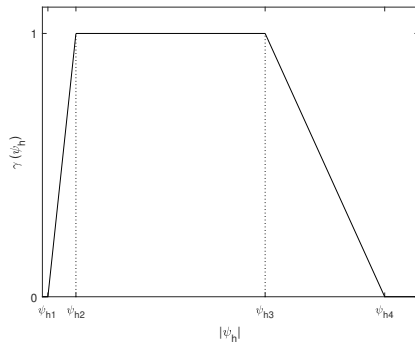


Figura 3: Coeficiente de reducción para la absorción de agua por las raíces  $\gamma$ , en función del potencial de presión del agua en el suelo  $\psi_h$  (L) (Feddes et al., 2001). La absorción de agua por debajo de  $\psi_{h1}$  (deficiencia de oxígeno) y por encima de  $\psi_{h4}$  (punto de marchitamiento) se establece en cero. Entre  $\psi_{h2}$  y  $\psi_{h3}$  (punto de reducción) la absorción de agua es máxima. El valor de  $\psi_{h3}$  varía con la tasa de transpiración potencial  $T_{pot}$ .

Finalmente, la tasa real de absorción de agua de la raíz se puede calcular a partir de:

$$S(\psi_h, r, z) = \gamma(\psi_h, r, z) S_m(r, z) \quad (23)$$

Siendo,

$$T_{pot} = K_c E T_o - E_s \quad (24)$$

Donde,  $E_s$  denota la evaporación desde el suelo  $L \cdot T^{-1}$

### 2.1.3. Contenido volumétrico de agua

Luego, teniendo en cuenta los aportes por riego y la extracción por parte del cultivo (23), la variación en el contenido volumétrico de agua (17) queda ahora expresada de la siguiente manera:

$$\dot{\theta} = \frac{Q_i V + Q_n}{V_o} - DS \quad (25)$$

La matriz  $D \in \mathbb{R}^{i \times j}$  asigna ceros a las zonas fuera de la raíz, lo que implica un consumo nulo en estas zonas. Los elementos de dicha matriz se definen de la siguiente manera:

$$d_{ij} = \begin{cases} 1 & 1 \leq j \leq r_m, 1 \leq i \leq z_m \\ 0 & \text{en otro caso} \end{cases} \quad (26)$$

Reordenando, resulta:

$$\dot{\theta} = \left[ \frac{Q_n(\theta)}{V_o} - DS(\psi_h(\theta)) \right] + \frac{Q_i}{V_o} V \quad (27)$$

En la (Figura 4) se presenta el bulbo húmedo resultante de simular una aplicación de riego (corte transversal del suelo); el punto de ingreso de agua es el punto (0,0), donde se ubica el gotero de riego. El gotero aporta agua, bajo un régimen de caudal constante, mientras la válvula de riego permanezca abierta. A partir del aporte de agua se genera el bulbo húmedo en el suelo. En la barra lateral, se referencia en una escala de color los niveles de porcentaje de humedad de cada celda.




Figura 4: Simulación de bulbo húmedo en el perfil de suelo agrícola.

### 2.2. Identificación del error de modelado mediante RBF. Modelo híbrido.

En este apartado, se describe el proceso de identificación del error del modelo descrito con anterioridad, través de una RBF, a fin de lograr la compensación de la salida del mismo. Para ello, la estructura neuronal se monta en paralelo al modelo matemático del sistema como un término aditivo que compense las desviaciones respecto de la realidad para formar un modelo híbrido, según se muestra en la (Figura 5).

Una red neuronal de función de base radial (RBF), como su nombre lo indica, utiliza funciones de base radial como funciones de activación. La arquitectura es muy similar a la del perceptrón multicapa, con la peculiaridad de que las RBF en su forma más básica tienen solo una capa oculta.

En las RBF la capa oculta realiza una transformación no-lineal del espacio de entrada y cada capa de salida se compone de la combinación lineal de las mismas, siendo excelentes aproximadores universales. De esta forma, una red con una única salida se define por:

$$\theta_a = \hat{\mathbf{w}}^T \xi(\mathbf{v}) = \sum_{i=1}^m \hat{w}_i^T \exp[-(\mathbf{v} - c_i)^T (\mathbf{v} - c_i) / \sigma_i] \quad (28)$$

Siendo,  $\theta_a$  la salida de la red de ajuste que compensa el modelo,  $m$  el número de entradas y  $w_i, v_j, c_i, \sigma_j$  los  $i$ -ésimos pesos

sinápticos, entradas, centros y varianzas de la RBF;  $\xi$  es la función de activación utilizada en cada neurona;  $\nu = [V, ET_0, \theta_a]$  el vector regresor de la red.

La elección de una red neuronal del tipo RBF se basa en sus propiedades de aproximador universal (Haykin, 1999; Park and Sandberg, 1993) de sistemas con dinámicas no-lineales y del cual se obtiene la mejor aproximación (Girosi and Poggio, 1990; Wray and Green, 1995; Liao et al., 2003).

Además, una red neuronal RBF puede ser utilizada para realizar una operación de aproximación de curvas en espacios multidimensionales; y su procedimiento de aprendizaje no posee problemas de mínimos locales (Van Yee and Haykin, 2001 - 2001). Esta última característica representa una ventaja evidente sobre otras estructuras de redes neuronales clásicas, como por ejemplo el Perceptrón multicapa (MLP), que suele presentar una superficie de error compleja con mínimos locales o regiones casi planas (Bianchini et al., 1995).

2.2.1. Entrenamiento de la RBF

En la (Figura 5), se muestra un diagrama que describe la configuración del entrenamiento de una red neuronal de base radial con una serie de datos. Las mediciones de humedad se comparan con la salida del modelo híbrido (formado por el modelo matemático y la red neuronal), y se retropropaga la señal de error para ajustar los parámetros de la RN.

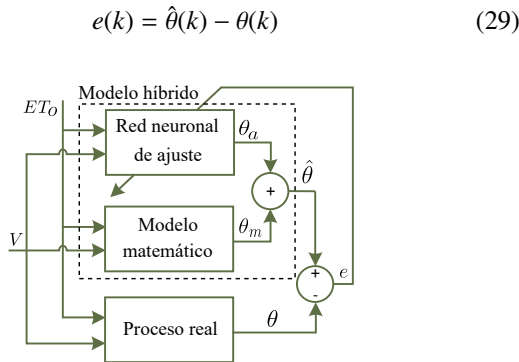


Figura 5: Esquema del proceso de entrenamiento *off-line* de la RBF.

El entrenamiento de la RBF fue realizado de manera *off-line* considerando una serie de datos obtenidos a partir de la ejecución de experimentos de riego (a lazo abierto) en suelo desnudo. La experimentación consistió en abrir y cerrar las válvulas de riego de forma aleatoria a fin de lograr que el nivel de humedad en el suelo varíe en el mayor rango posible, es decir, desde  $\theta_r$  (humedad residual) hasta  $\theta_s$  (humedad en saturación). De esa manera, obtener la mayor cantidad de información sobre la dinámica hídrica del suelo evaluado. El registro de datos incluyó las mediciones del nivel de humedad del suelo  $\theta$ , nivel de evapotranspiración  $ET_0$  y estado de la válvula de riego  $V$ .

Para cada ensayo, del total de muestras recolectadas se utilizó el 70 % para entrenamiento de la RN y el 30 % restante para validación, donde las muestras fueron presentadas cada 10min. Los resultados de la validación del modelo híbrido para un tipo de suelo de la provincia de San Juan, se detallan en la Figura 9 de la sección 3.

En la (Figura 6), se observa la estructura de la red neuronal que consta, como se mencionó, de una capa de entrada, una

capa oculta y una de salida. Se realizaron modificaciones en el número de neuronas de esta estructura aumentándolas hasta que no se obtuvieron mejoras sustanciales en la identificación. Finalmente, la misma quedó conformada por una salida correspondiente al ajuste de humedad, una capa oculta con 8 neuronas y un valor de retardo  $n = 3$  para cada entrada.




Figura 6: Estructura de la red neuronal RBF.

2.3. Controlador de riego realimentado

En la sección 2.1 y 2.2 se obtuvo la dinámica del riego para poder simular su comportamiento para un determinado tipo de suelo. En esta sección se plantea la ley de control adaptable para cuando las características del terreno son desconocidas. Se propone que la dinámica de irrigación del suelo posee la siguiente estructura:

$$\dot{\theta}(t) = F(\theta) + Gu + \delta(t) \tag{30}$$

El modelo representado en (27) es un sistema SISO, donde  $F(\theta) = Q_n(\theta)/Vo - DS(\psi_h(\theta))$  y  $G = Q_i/Vo$  es la dinámica del sistema de riego desconocida con  $\underline{g} < G(t) < \bar{g}$ , donde  $\underline{g}$  y  $\bar{g}$  son los límites inferiores y superiores de  $G(t)$  respectivamente; y  $\delta(t)$  representa las dinámicas no modeladas en la estructura; la acción de control PI neuronal  $u$  se parametriza para indicar el tiempo  $T_{on}$  que debe permanecer abierta la válvula  $V$  para cumplir los objetivos de control, de esta manera:

$$T_{on} = \frac{T_s}{Q_{got}} u \tag{31}$$

Y,

$$V = \begin{cases} 1 & t \leq T_{on} \\ 0 & T_{on} < t \leq T_s \end{cases} \tag{32}$$

Siendo,  $T_s$  el tiempo de muestreo y  $t$  varía en el rango  $0 \leq t \leq T_{on}$ .

El controlador neuronal PI recibe la diferencia entre la referencia deseada y el contenido de agua en el punto considerado, y a partir de esta envía la señal de apertura o cierre de la válvula de riego, según la (Figura 7). La señal de error de humedad se define como:



$$e(t) = \theta(t) - \theta_{ref}(t) \quad (33)$$

$$\dot{e}(t) = \dot{\theta} - \dot{\theta}_{ref}(t) \quad (34)$$

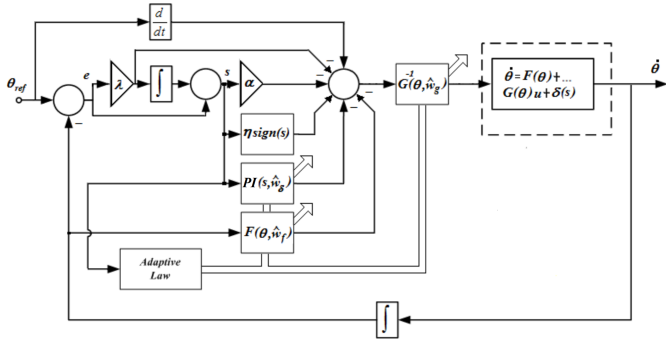


Figura 7: Arquitectura de control del sistema de riego.

### 2.3.1. Control por superficies deslizantes

El error de humedad del estado de salida se define como (33)-(34) y el objetivo de esta técnica es encontrar una ley de control tal que el estado  $\theta$  del sistema de lazo cerrado tenga el mismo valor que el estado deseado  $\theta_{ref}$ , en otras palabras, el error de humedad debe converger a cero.

El objetivo de la ley de control obtenida mediante la técnica de modo deslizante es seguir la referencia no lineal del sistema hasta una superficie preestablecida (definida por el diseñador) en el espacio de estado y mantenerla en esta superficie durante todo el tiempo posterior. Esta superficie se denomina superficie de deslizamiento. Cuando la referencia del sistema está por encima de la superficie de deslizamiento, la retroalimentación presenta una ganancia, y cuando la referencia del sistema está por debajo de la superficie, la retroalimentación utiliza una ganancia diferente.

Esta superficie de deslizamiento también se conoce como colector de deslizamiento porque, al menos en teoría, una vez que esta superficie es interceptada por la referencia del sistema, la ley de control impondría a la referencia del sistema seguir la superficie para todo el tiempo futuro (la referencia se deslizará sobre la superficie). La dinámica del proceso limitada a esta superficie denota el comportamiento del sistema controlado. El primer paso es diseñar la superficie de deslizamiento de acuerdo con el comportamiento deseado del sistema de lazo cerrado, como la convergencia al origen y la robustez de la variación paramétrica (Slotine et al., 1991), (Edwards and Spurgeon, 1998), (Utkin, 1992).

Se puede definir una superficie de deslizamiento para el sistema SISO en el estado de error  $s(\theta)$  de (33).

$$s(\theta) = \left( \frac{d}{dt} + \lambda \right) \int_0^t e(t) dt = e(t) + \lambda \int_0^t e(t) dt \quad (35)$$

La derivada de la superficie deslizante propuesta  $s(\theta)$  es:

$$\dot{s}(\theta) = \frac{d}{dt} \left( e(t) + \lambda \int_0^t e(\tau) d\tau \right) = \dot{e}(t) + \lambda e(t) \quad (36)$$

En los sistemas reales  $F(\theta)$ ,  $G(\theta)$ ,  $\delta(t)$  son desconocidos. Por tanto, es imposible generar la ley de control con estas funciones. Para superar estas dificultades, se utilizan sistemas neuronales y control PI para  $F(\theta, \mathbf{w}_f^*)$ ,  $G(\theta, \mathbf{w}_g^*)$ ,  $\delta(s, \mathbf{w}_\delta^*)$  y así, obtener la ley de control que permita aproximar a las funciones desconocidas  $F(\theta)$ ,  $G(\theta)$ ,  $\delta(t)$  respectivamente, y aplicando un término robusto de control que no es continuo y asegure la estabilidad del mismo  $u_s = \eta \text{sgn}(s)$  (siendo  $\text{sgn}$  la función signo y  $\eta$  una constante positiva definida por el diseñador). Por lo tanto, (30) puede ser aproximada en términos de los parámetros ajustables de la red neuronal. Siendo  $\mathbf{w}_f^*$ ,  $\mathbf{w}_g^*$ ,  $\mathbf{w}_\delta^*$ , los valores óptimos y desconocidos de los parámetros (pesos) de la red neuronal propuesta y  $\varepsilon$  el error de aproximación de la red, que es un valor acotado.

La estructura de la red RBF utilizada se muestra en la (Figura 8).

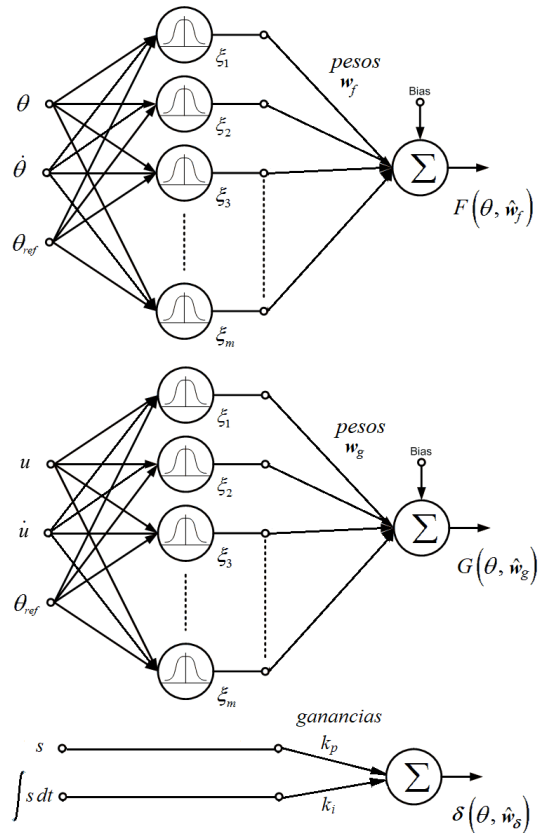


Figura 8: Estructura de la red RBF-PI

La función gaussiana que se utiliza como función de activación de cada neurona en la capa oculta de la red propuesta es la siguiente.

$$\xi_i(\boldsymbol{\psi}; c_i, \varsigma_i) = \exp[-\varsigma_i^2 (\boldsymbol{\psi} - c_i)^T (\boldsymbol{\psi} - c_i)] \quad (37)$$

Siendo  $\boldsymbol{\psi}_f = [\theta, \dot{\theta}, \theta_{ref}]$  y  $\boldsymbol{\psi}_g = [u, \dot{u}, \theta_{ref}]$  el vector regresor de la red y el subíndice  $i$  indica la  $i$ -ésima neurona de la capa oculta,  $c_i$  es la posición central de la  $i$ -ésima neurona, y  $\varsigma_i$  es el factor de dispersión de la función gaussiana.

Así, la ley de control puede ser aproximada por una RBF-RN a través del aprendizaje en línea y se escribirá como:

$$u = G^{-1}(\theta, \hat{\mathbf{w}}_g)[- \alpha s - F(\theta, \hat{\mathbf{w}}_f) - \delta(s, \hat{\mathbf{w}}_\delta) - \lambda e(t) + \dot{\theta}_{ref} + u_s] \quad (38)$$

Donde  $-\alpha s$  es un termino adicionado para acelerar la convergencia de la ley de control,  $\hat{\mathbf{w}}_f$  y  $\hat{\mathbf{w}}_g$  son los vectores de parámetros estimados de los pesos  $\mathbf{w}_f, \mathbf{w}_g \in \mathbb{R}^{m \times 1}$  asociada a la función de base radial  $\xi$ , cuyas reglas de ajuste se determinarán en el análisis de estabilidad. Se indica como  $m$  el número de neuronas. Por último  $u_s$  es el término no lineal  $u_s = \eta \text{sgn}(s)$ .

Sin embargo, los vectores de parámetros óptimos son desconocidos, por lo que es necesario estimar los valores. Para ello, se define las funciones de estimación  $F(\theta, \mathbf{w}_f^*)$  y  $G(\theta, \mathbf{w}_g^*)$  de la forma:

$$F(\theta, \hat{\mathbf{w}}_f) = \hat{\mathbf{w}}_f^T \xi(\psi_f) = \sum_{i=1}^m \hat{w}_{fi}^T \exp[-\hat{\zeta}_{fi}^2(\psi_f - c_{fi})^T(\psi_f - c_{fi})] \quad (39)$$

y

$$G(\theta, \hat{\mathbf{w}}_g) = \hat{\mathbf{w}}_g^T \xi(\psi_g) = \sum_{i=1}^m \hat{w}_{gi}^T \exp[-\hat{\zeta}_{gi}^2(\psi_g - c_{gi})^T(\psi_g - c_{gi})] \quad (40)$$

Además, se emplea un término de control PI para atenuar las dinámicas no modeladas o variaciones en el modelo externas  $\delta(s, \mathbf{w}_\delta^*)$ . El término de control PI puede ser expresado como:

$$\delta(s, \mathbf{w}_\delta^*) = \left\{ \begin{matrix} k_P & k_I \end{matrix} \right\} \left( \int_0^s s d\tau \right) = \hat{\mathbf{w}}_\delta^T \chi(s) \quad (41)$$

Donde las ganancias  $\hat{\mathbf{w}}_\delta^T = [k_P, k_I]$  son un parámetro de ajuste, y el vector  $\chi(s) = [s, \int_0^t s d\tau]^T$  es el vector regresivo del control PI.

La ley de control global viene dada por la ecuación (38), y definiendo el mínimo error de aproximación como:

$$\varepsilon = [F(\theta) - F(\theta, \mathbf{w}_f^*)] + [G(\theta) - G(\theta, \mathbf{w}_g^*)]u + [\delta(t) - \delta(s, \mathbf{w}_\delta^*)] \quad (42)$$

**Consideración 1:** esta variable está acotada por una constante  $\eta$  positiva, siendo:

$$|\varepsilon| \leq \eta \quad (43)$$

Ahora, utilizando (36) y considerando el modelo dinámico (30) se puede escribir como:

$$\begin{aligned} \dot{s} &= \lambda e(t) + \dot{\theta} - \dot{\theta}_{ref} \\ &= \lambda e(t) + [F(\theta) + Gu(t) + \delta(t)] - \dot{\theta}_{ref} \end{aligned} \quad (44)$$

Sustituyendo la acción de control propuesta (38) en (44):

$$\begin{aligned} \dot{s} &= -\alpha s + \lambda e(t) + [F(\theta) - F(\theta, \hat{\mathbf{w}}_f)] + [G(\theta) - G(\theta, \hat{\mathbf{w}}_g)]u(t) \\ &\quad + \delta(t) - \delta(s, \hat{\mathbf{w}}_\delta) - \lambda e(t) + \dot{\theta}_{ref} + u_s - \dot{\theta}_{ref} \\ &= -\alpha s + [F(\theta, \mathbf{w}_f^*) - F(\theta, \hat{\mathbf{w}}_f)] + [G(\theta, \mathbf{w}_g^*) - G(\theta, \hat{\mathbf{w}}_g)]u(t) \\ &\quad + \delta(s, \mathbf{w}_\delta^*) + \delta(s, \hat{\theta}_\delta) + \varepsilon + u_s \end{aligned} \quad (45)$$

Teniendo en cuenta que,

$$\begin{aligned} F(\theta, \mathbf{w}_f^*) - F(\theta, \hat{\mathbf{w}}_f) &= \mathbf{w}_f^{*T} \xi(\psi_f) - \hat{\mathbf{w}}_f^T \xi(\psi_f) = \tilde{\mathbf{w}}_f^T \xi(\psi_f) \\ G(\theta, \mathbf{w}_g^*) - G(\theta, \hat{\mathbf{w}}_g) &= \mathbf{w}_g^{*T} \xi(\psi_g) - \hat{\mathbf{w}}_g^T \xi(\psi_g) = \tilde{\mathbf{w}}_g^T \xi(\psi_g) \\ \delta(s, \mathbf{w}_\delta^*) - \delta(s, \hat{\mathbf{w}}_\delta) &= \mathbf{w}_\delta^{*T} \chi(s) - \hat{\mathbf{w}}_\delta^T \chi(s) = \tilde{\mathbf{w}}_\delta^T \chi(s) \end{aligned} \quad (46)$$

donde  $\tilde{\mathbf{w}}_f, \tilde{\mathbf{w}}_g, \tilde{\mathbf{w}}_\delta$  son definidos como:

$$\begin{cases} \tilde{\mathbf{w}}_f = \mathbf{w}_f^* - \hat{\mathbf{w}}_f \\ \tilde{\mathbf{w}}_g = \mathbf{w}_g^* - \hat{\mathbf{w}}_g \\ \tilde{\mathbf{w}}_\delta = \mathbf{w}_\delta^* - \hat{\mathbf{w}}_\delta \end{cases} \quad (47)$$

$\dot{s}$  puede ser aproximada por:

$$\dot{s} = -\alpha s + \tilde{\mathbf{w}}_f^T \xi(\psi_f) + \tilde{\mathbf{w}}_g^T \xi(\psi_g)V + \tilde{\mathbf{w}}_\delta^T \chi(s) + \varepsilon + u_s \quad (48)$$

**Teorema:** Considerando el sistema no lineal incierto (30) y las leyes de ajuste (55)-(57). Entonces, el controlador definido por (38) asegura la convergencia en tiempo finito del vector de error de seguimiento a la capa límite y su convergencia exponencial en la región cerrada  $\Lambda$ .

**Demostración:** sea una función candidata de Lyapunov  $L$  definida positiva como:

$$L = \frac{1}{2}[s^2 + \gamma_1^{-1}(\tilde{\mathbf{w}}_f^T \tilde{\mathbf{w}}_f) + \gamma_2^{-1}(\tilde{\mathbf{w}}_g^T \tilde{\mathbf{w}}_g) + \gamma_3^{-1}(\tilde{\mathbf{w}}_\delta^T \tilde{\mathbf{w}}_\delta)] \quad (49)$$

La presencia de un termino discontinuo en la ley de control conduce al conocido efecto "chattering". Para evitar estas indeseables oscilaciones de alta frecuencia de la variable controlada, se puede sustituir la función signo por una función de saturación, de forma similar a como lo hicieron (Hung and Chung, 2007). Esta sustitución suaviza la discontinuidad del control e introduce una fina capa límite  $\Lambda$  en la vecindad de la superficie de conmutación, por lo tanto, la función  $u_s = \eta \text{sign}(s)$  puede ser reemplazada por la función  $u_s = \eta \text{sat}(s/\Lambda)$ , siendo la función saturación expresada como:

$$\text{sat}\left(\frac{s}{\Lambda}\right) = \begin{cases} \text{sign}(s) & \text{if } |s| \geq \Lambda \\ (s/\Lambda) & \text{if } |s| < \Lambda \end{cases} \quad (50)$$

Donde  $\Lambda$  es una constante estrictamente positiva que representa el espesor de la capa límite.

Ahora, derivando (49) queda:

$$\dot{L} = s\dot{s} + \gamma_1^{-1}(\tilde{\mathbf{w}}_f^T \dot{\tilde{\mathbf{w}}}_f) + \gamma_2^{-1}(\tilde{\mathbf{w}}_g^T \dot{\tilde{\mathbf{w}}}_g) + \gamma_3^{-1}(\tilde{\mathbf{w}}_\delta^T \dot{\tilde{\mathbf{w}}}_\delta) \quad (51)$$

Sustituyendo (48) en (51) y considerando la situación en que  $|s| \geq \Lambda$  donde la función toma el valor  $\text{sat}(s/\Lambda) = \text{sign}(s)$  (50).

$$\begin{aligned} \dot{L} &= s[-\alpha s + \tilde{\mathbf{w}}_f^T \xi(\psi_f) + \tilde{\mathbf{w}}_g^T \xi(\psi_g)V + \tilde{\mathbf{w}}_\delta^T \chi(s) + \varepsilon - \\ &\quad \eta \text{sign}(s)] + \gamma_1^{-1}(\tilde{\mathbf{w}}_f^T \dot{\tilde{\mathbf{w}}}_f) + \gamma_2^{-1}(\tilde{\mathbf{w}}_g^T \dot{\tilde{\mathbf{w}}}_g) + \gamma_3^{-1}(\tilde{\mathbf{w}}_\delta^T \dot{\tilde{\mathbf{w}}}_\delta) \end{aligned} \quad (52)$$

Reordenando (52);

$$\begin{aligned} \dot{L} &= -\alpha s^2 + s\tilde{\mathbf{w}}_f^T \xi(\psi_f) + s\tilde{\mathbf{w}}_g^T \xi(\psi_g)V + s\tilde{\mathbf{w}}_\delta^T \chi(s) + s\varepsilon - \\ &\quad \eta |s| + \gamma_1^{-1}(\tilde{\mathbf{w}}_f^T \dot{\tilde{\mathbf{w}}}_f) + \gamma_2^{-1}(\tilde{\mathbf{w}}_g^T \dot{\tilde{\mathbf{w}}}_g) + \gamma_3^{-1}(\tilde{\mathbf{w}}_\delta^T \dot{\tilde{\mathbf{w}}}_\delta) \end{aligned} \quad (53)$$

Agрупando,



Tabla 1: Propiedades del suelo

$$\dot{L} = -\alpha s^2 + \tilde{\mathbf{w}}_f^T [s\xi(\psi_f) + \gamma_1^{-1} \tilde{\mathbf{w}}_f] + \tilde{\mathbf{w}}_g^T [s\xi(\psi_g)V + \gamma_2^{-1} \tilde{\mathbf{w}}_g] + \tilde{\mathbf{w}}_\delta^T [s\chi(s) + \gamma_3^{-1} \tilde{\mathbf{w}}_\delta] + s\varepsilon - \eta |s| \quad (54)$$

Si definimos las reglas de ajuste de la siguiente forma:

$$\tilde{\mathbf{w}}_f = -\gamma_1 s\xi(\psi_f) \quad (55)$$

$$\tilde{\mathbf{w}}_g = -\gamma_2 s\xi(\psi_g)V \quad (56)$$

$$\tilde{\mathbf{w}}_\delta = -\gamma_3 s\chi(s) \quad (57)$$

Reemplazando las ecuaciones (55), (56) y (57) en (54) se obtiene que:

$$\dot{L} = -\alpha s^2 - \eta |s| + \varepsilon s \leq 0 \quad (58)$$

Ahora, considerando la situación en que  $|s| < \Lambda$ , donde la función toma el valor  $\text{sat}(s/\Lambda) = s/\Lambda$  y haciendo el mismo análisis desde (52), (58) resulta en:

$$\begin{aligned} \dot{L} &= -(\alpha + \eta)s^2 + \varepsilon s && \leq 0 \\ &= -\alpha s^2 - \eta \frac{s^2}{\Lambda} + \varepsilon s && \leq 0 \\ &= -(\alpha + \frac{\eta}{\Lambda})s^2 + \varepsilon s && \leq 0 \end{aligned} \quad (59)$$

Se debe cumplir que:

$$\begin{aligned} s(\alpha + \frac{\eta}{\Lambda}) &> \varepsilon \\ s &> \frac{\varepsilon}{(\alpha + \frac{\eta}{\Lambda})} \end{aligned} \quad (60)$$

En ambos casos implica que  $L(t) \leq L(0)$ . A partir de la definición, se puede comprobar fácilmente que  $s$  está acotado. Considerando (35), se puede verificar que  $e$  también está acotado. Por lo tanto, implica que (36) también está acotado. Este resultado implica que la variable controlada tiende a cero aun cuando el modelo es totalmente desconocido.

### 3. Resultados y discusión

La datos que se usaron para la identificación de la dinámica del agua en el suelo y como información comparativa, se recolectaron en las instalaciones del Instituto Nacional de Tecnología Agropecuaria (INTA). Específicamente, en el INTA situado en la provincia de San Juan en el periodo 6/08 - 29/09 de 2007.

En la Tabla 1, se detallan las propiedades texturales e hídricas del suelo del INTA que permitirán parametrizar el modelo de suelo. En las primeras tres columnas se muestra el porcentaje de cada tipo de clase textural (arena, limo, arcilla), y en las siguientes sus propiedades hidráulicas, denotadas por sus siglas en inglés: capacidad de campo (FC - Field Capacity), punto de marchitamiento (WP - Wilting Point) y, por último, la densidad aparente (BD - Bulk density).

Texturales			Hídricas		
Arena	Limo	Arcilla	FC ( $\text{cm}^3 \cdot \text{cm}^{-3}$ )	WP ( $\text{cm}^3 \cdot \text{cm}^{-3}$ )	BD ( $\text{g} \cdot \text{cm}^{-3}$ )
35 %	33 %	32 %	39.18 %	18.31 %	1.28

Los valores porcentuales de arena, limo y arcilla, y la densidad aparente del suelo se ingresan en una red neuronal en la etapa de configuración del programa *Hydrus 2D*, y se obtienen los parámetros que se precisan para correr el modelo matemático del suelo. A partir de estos, los mismos se fueron ajustando, a prueba y error, a fin de obtener una mejor estimación.

En la Tabla 2, se detallan los parámetros mencionados, siendo: el contenido de agua residual y en saturación ( $\theta_r$  y  $\theta_s$ , respectivamente), la conductividad hidráulica en saturación  $K_s$  y los restantes son valores de ajuste correlacionados con la textura del suelo.

Tabla 2: Parámetros del modelo de suelo

	$\theta_r(\text{cm}^3 \cdot \text{cm}^{-3})$	$\theta_s(\text{cm}^3 \cdot \text{cm}^{-3})$	$\alpha(\text{cm}^{-3})$	n (-)	$K_s(\text{cm/day})$
Hydrus	0.0845	0.4683	0.012	1.4550	18.95
Ajuste	0.0845	0.4683	0.004	1.4550	86.4

Los valores de los parámetros correspondientes al modelo de extracción se obtuvieron aplicando el método de mínimos cuadrados, sabiendo que se conocen los valores de enraizamiento máximo en las direcciones radial y de profundidad. En la Tabla 3, se presenta los resultados de la optimización mediante el algoritmo *trust-region-reflective*.

Tabla 3: Parámetros del modelo de extracción

Parámetros	$z_m(\text{cm})$	$r_m(\text{cm})$	$z^*(-)$	$r^*(-)$	$p_z(-)$	$p_r(-)$
Valor	75	50	35	10	29.9251	0.0029

La matriz de celdas (Figura 2), se escoge de 20x20 en el eje vertical y horizontal, respectivamente, lo suficientemente amplia (en función del tamaño de cada celda) como para que las paredes laterales no influyan en la forma del bulbo. Los anillos que forman el cilindro debajo del gotero se eligen con un alto y ancho de  $\Delta_i = \Delta_j = 5\text{cm}$ . En cuanto al sistema de riego, se consideran una cinta de riego cuyos goteros otorgan un caudal fijo de  $4\text{l/h}$ ,

Las mediciones que se tomaron en campo se corresponden con: muestras del estado de la válvula  $V$ ; la evapotranspiración de referencia  $ET_o$ , proporcionada por una estación meteorológica Campbell; y las mediciones de humedad del suelo fueron tomadas a  $30\text{cm}$  de profundidad con sensores de humedad de tipo capacitivos (Capraro et al., 2011).

La simulación comienza asignando un valor inicial de humedad a cada celda del modelo de suelo. Para esto, se parte de la condición en que todas las celdas tienen el valor residual  $\theta_r$  y se riega hasta obtener uno que se considere adecuado.

En cuanto a los tiempos de simulación, se escoge un tiempo de muestreo  $T_s = 1h$  y tiempo entre instantes de aplicación de riego del modelo de suelo  $\Delta t = 10s$ .

Para validar el modelo híbrido de simulación se tomo un periodo de riego realizado en campo y se le aplicó la misma secuencia a dicho modelo; en la (Figura 9) pueden verse los resultados del riego. Se aprecia la similitud en la respuesta de las mediciones en campo y de simulación, con una leve diferencia, sobre todo en los picos (que que se corresponden con los inicios del riego) donde en la mayoría de los casos se sobreestima los valores reales.




Figura 9: Resultados de las mediciones en campo del contenido volumétrico de agua porcentual y en simulación ante una misma secuencia de riego, a 30cm de profundidad. Apertura manual de válvula en la parte inferior.

Ahora, a partir del modelo híbrido parametrizado y ajustado para un tipo de suelo de la provincia de San Juan, se aplica el control descrito en la sección 2.3 durante un periodo de riego y para un determinado cultivo.




Figura 10: Respuesta de simulación para un control PI-neuronal del contenido volumétrico de agua porcentual. Valor de referencia  $\theta_w = 21\%$ . Apertura de válvula con control PI en la parte inferior.

En la (Figura 10), se observa la humedad volumétrica resultante de aplicar las acciones de control del PI-neuronal al

modelo de simulación para un valor de referencia de 21% de humedad. Donde, se consideró la extracción de agua por parte de un olivo de 5 años de edad cuyas raíces se extienden según los parámetros detallados en la Tabla 3 y un valor de  $K_c$  constante en todo el ensayo. Puede notarse la respuesta estable del sistema de lazo cerrado para el modelo de simulación y la variación del contenido de agua en el punto de medición alrededor de la referencia dentro de valores permitidos. Además, la frecuencia de accionamiento es baja, lo que significa un alargamiento de la vida útil de la válvula.

Si bien, en este trabajo se muestra para un tipo de suelo, podría utilizarse para cualquier tipo de suelo, cultivo y para otras realidades climáticas, ya que el controlador se autoajusta por técnicas adaptables sin necesidad de conocer la dinámica del modelo utilizado.

#### 4. Conclusiones

En el presente trabajo se implementó un modelo matemático que representa la dinámica hídrica del suelo con la finalidad de ejecutar simulaciones que permitan conocer la variabilidad de la humedad para suelos agrícolas bajo riego por goteo en condiciones de no saturación. Dicho modelo, se caracterizó para un tipo de suelo existente en la provincia de San Juan.

Por otro lado, se propuso y entreno una red neuronal de base radial, con información recopilada desde una estación de medición automática, con el objetivo de contar con un segundo modelo de estimación que resultara de complemento al modelo matemático por primeros principios. Se evaluaron las estimaciones de humedad obtenida por ambos modelos combinados, logrando resultados satisfactorios, ya que se logró verificar una respuesta a la similar a las dinámicas reales del suelo registrada con las mediciones in-situ y dentro de los márgenes de error de estimación esperados.

Se desarrolló un controlador de riego basado en una técnica de superficies deslizantes en combinación con redes neuronales PI que permite adaptarse de manera adecuada y rápida a los parámetros reales del suelo, parámetros que pueden ser cambiantes durante las campañas de riego. Las simulaciones exhiben un comportamiento del contenido volumétrico de humedad dentro de los valores prefijados y con baja frecuencia de accionamiento de la válvula. El controlador de riego propuesto ejecuta en tiempo real una serie de acciones de apertura y cierre de la válvula de riego que resultan ser oportunas en cantidad, aplicándose así un riego variable, y atendiendo a las premisas de un riego de precisión donde las aplicaciones de agua se ajustan a la demanda hídrica del cultivo y a la dinámica de retención de humedad del suelo. Las aplicaciones de riego por exceso (saturación) y por defecto (estrés) no ocurren con este tipo de control optimizándose el uso del agua como recursos escaso.

#### Agradecimientos

Este trabajo ha sido realizado gracias al apoyo de la Universidad Nacional de San Juan y del Consejo Nacional de Investigaciones científicas y Técnicas (CONICET) de Argentina.

## Referencias

- Albertos, P., Mareels, I., 01 2010. Feedback and Control for Everyone. DOI: 10.1007/978-3-642-03446-6
- Allen, R. G., Pereira, L. S., Raes, D., Smith, M., 2006. Evapotranspiración del cultivo: guías para la determinación de los requerimientos de agua de los cultivos. FAO Roma, Italia, 298.
- Arbat, G., Puig, J., Poch, R., Ramírez de Cartagena, F., Barragán, J., 2003. Evaluation of numerical models of water flow in soil hydrus-2d and simdas under localized irrigation.
- Arbat, G., Puig-Bargués, J., Duran-Ros, M., Barragan, J., Cartagena, F., 10 2013. Drip-irriwater: Computer software to simulate soil wetting patterns under surface drip irrigation. Computers and Electronics in Agriculture 98, 183. DOI: 10.1016/j.compag.2013.08.009
- Armstrong, C., Wilson, T., 1983. Computer model for moisture distribution in stratified soils under a trickle source. Transactions - American Society of Agricultural Engineers 26 (6), 1704–1709, cited By 12.
- Bianchini, M., Frascioni, P., Gori, M., 1995. Learning without local minima in radial basis function networks. IEEE Transactions on Neural Networks 6 (3), 749–756. DOI: 10.1109/72.377979
- Capraro, F., Patiño, D., Tosetti, S., Schugurensky, C., April 2008. Neural network-based irrigation control for precision agriculture. In: 2008 IEEE International Conference on Networking, Sensing and Control. pp. 357–362.
- Capraro, F., Tosetti, S., Vita Serman, F., 2011. Real-time soil moisture control for very high frequency drip irrigation in olive groves. Acta horticulturae (888), 239.
- Choudhary, S., Gaurav, V., Singh, A., Agarwal, S., 2019. Autonomous crop irrigation system using artificial intelligence. International Journal of Engineering and Advanced Technology 8 (5 Special Issue), 46–51, cited By 0.
- Edwards, C., Spurgeon, S., 1998. Sliding Mode Control: Theory And Applications. Series in Systems and Control. Taylor & Francis.
- Elnesr, M., Alazba, P., 10 2017. Simulation of water distribution under surface dripper using artificial neural networks. Computers and Electronics in Agriculture 143, 90–99.
- FAO, 2016. Aquastat base de datos. Organización de las Naciones Unidas para la Alimentación y la Agricultura.
- Feddes, R., Hoff, H., Bruen, M., Dawson, T., De Rosnay, P., Dirmeyer, P., Jackson, R., Kabat, P., Kleidon, A., Lilly, A., Pitman, A., Dec. 2001. Modeling root water uptake in hydrological and climate models. Bulletin - American Meteorological Society 82 (12), 2797–2809.
- Girosi, F., Poggio, T., 1990. Networks and the best approximation property. Biological Cybernetics 63, 169–176.
- Haykin, S., 1999. Neural Networks: A Comprehensive Foundation. International edition. Prentice Hall.
- Hung, L.-C., Chung, H.-Y., 2007. Decoupled control using neural network-based sliding-mode controller for nonlinear systems. Expert Syst. Appl. 32, 1168–1182.
- Khatri, K. C., 1984. Simulation of soil moisture migration from a point source. Ph.D. thesis.
- Knox, J., Kay, M., Weatherhead, E., 2012. Water regulation, crop production, and agricultural water management understanding farmer perspectives on irrigation efficiency. Agricultural Water Management 108, 3–8, irrigation efficiency and productivity: scales, systems and science.
- Liao, Y., Fang, S.-C., Nuttle, H., 10 2003. Relaxed conditions for radial-basis function networks to be universal approximators. Neural networks : the official journal of the International Neural Network Society 16, 1019–28. DOI: 10.1016/S0893-6080(02)00227-7
- Lozoya, C., Mendoza, C., Mejía, L., Quintana, J., Mendoza, G., Bustillos, M., Arras, O., Solís, L., 2014. Model predictive control for closed-loop irrigation. IFAC Proceedings Volumes 47 (3), 4429 – 4434, 19th IFAC World Congress.
- Park, J., Sandberg, I. W., mar 1993. Approximation and radial-basis-function networks. Neural Comput. 5 (2), 305–316.
- Prado Hernández, J., Rivas, M., Lezama, A., Carrillo, M., Peña, V. M., Valenzuela, H., Paz, O., 10 2017. Modelo empírico del patrón de humedad en un suelo orgánico de México con riego por goteo superficial.
- Pujolràs, G. A., 2006. Desarrollo y validación de un modelo de simulación de la dinámica del agua en el suelo. aplicación al diseño agronómico y al manejo en riego localizado. Ph.D. thesis.
- Ramírez de Cartagena Bisbe, F., Sáinz Sánchez, M. A., 1997. Modelo de distribución de agua en suelo regado por goteo. Ingeniería del agua 4 (1).
- Sahbani, F., Ferjani, E., 06 2018. Identification and modelling of drop by drop irrigation system for tomato plants under greenhouse conditions. Irrigation and Drainage 67.
- Simunek, J., Šejna, M., Van Genuchten, M., 2018. New features of version 3 of the hydrus (2d/3d) computer software package. Journal of Hydrology and Hydromechanics 66 (2), 133–142, cited By 4.
- Slotine, J., Slotine, J., Li, W., 1991. Applied Nonlinear Control. Prentice Hall.
- Smith, R. J., Baillie, J. N., McCarthy, A. C., Raine, S. R., Baillie, C. P., 2010. Review of precision irrigation technologies and their application. Tech. rep.
- Utkin, V. I., 1992. Sliding modes in optimization and control problems.
- Van der Ploeg, R., Benecke, P., 1974. Unsteady, unsaturated, n-dimensional moisture flow in soil: A computer simulation program. Proc Soil Sci Soc Am 38 (6), 881–885, cited By 21.
- Van Yee, P., Haykin, S., 2001 - 2001. Regularized radial basis function networks : theory and applications / Paul Van Yee, Simon Haykin. Adaptive and learning systems for signal processing, communications, and control. John Wiley, New York.
- Vita Serman, F., Capraro, F., Tosetti, S., Cornejo, V., Carelli, A., Ceci, L., 05 2012. Intelligent irrigation control in olive groves (olea europaea l.): A novel approach for water resource optimization. Acta Horticulturae 949. DOI: 10.17660/ActaHortic.2012.949.50
- Vrugt, J., Hopmans, J., Simunek, J., Jiri, J., 07 2001. Calibration of a two-dimensional root water uptake model. Fluid Phase Equilibria 65, 1027–1037. DOI: 10.2136/sssaj2001.6541027x
- Wray, J., Green, G. G., 1995. Neural networks, approximation theory, and finite precision computation. Neural Networks 8 (1), 31–37.
- Yahyaoui, I., Tadeo, F., Segatto, M. V., 2017. Energy and water management for drip-irrigation of tomatoes in a semi- arid district. Agricultural Water Management 183, 4 – 15, special Issue: Advances on ICTs for Water Management in Agriculture.