



Universidad Nacional de San Juan
Facultad de Ingeniería
Instituto de Automática

Monitorización y análisis continuo de cultivos para optimización y control del riego basado en modelo

**Tesis Doctoral de
Juan Abel Gómez**

Monitorización y análisis continuo de cultivos para optimización y control del riego basado en modelo

Tesis doctoral de

Juan Abel Gomez

Aprobada por la
**Facultad de Ingeniería de la
Universidad Nacional de San Juan**

para el otorgamiento del grado académico de

**Doctor en Ingeniería de
Sistemas de Control**

Dirección de tesis:	Dr. Ing. Carlos Soria	Instituto de Automática Universidad Nacional de San Juan Argentina
	Dr. Ing. Flavio Capraro	Instituto de Automática Universidad Nacional de San Juan Argentina
Jurado de tesis:	Dr. Ing. Gustavo Scaglia	Instituto de Ingeniería Química Universidad Nacional de San Juan Argentina
	Dr. Ing. Rogelio Hecker	Facultad de Ingeniería Universidad Nacional de La Pampa Argentina

Fecha de la defensa oral: 30 de Julio de 2024

Gomez, Juan Abel

Monitorización y análisis continuo de cultivos para optimización y control del riego basado en modelo / Juan Abel

Gomez. - 1a ed. - San Juan: Instituto de Automática, 2024.

123 p. ; 21 x 15 cm.



ISBN: 978-631-90150-9-6

1. Riego por Goteo.

2. Modelado

I. Título. CDD 657.863

**MONITORIZACIÓN Y ANÁLISIS CONTINUO DE CULTIVOS PARA
OPTIMIZACIÓN Y CONTROL DEL RIEGO BASADO EN MODELO**

JUAN ABEL GOMEZ

Tesis de doctorado

Temas de Automática

Primera edición: Agosto 2024

Impreso en Argentina

Queda prohibida la reproducción total o parcial de esta tesis, su almacenamiento o transmisión por cualquier medio, ya sea electrónico, mecánico, fotocopiado o de cualquier otra índole, sin la autorización previa y por escrito del autor o de la institución a la que pertenece.

©2024 JUAN ABEL GOMEZ

Hecho el depósito que marca la ley.

Agradecimientos

Me cuesta poner nombres propios al momento de dar gracias, porque hubo una gran cantidad de personas que colaboraron de una forma u otra a la consecución de esta tesis. Algunos desde lo estrictamente académico, otros desde la gestión, otros desde lo emocional y algunas personas en cada uno de estos ámbitos. Cada uno puede estar seguro lo eternamente agradecido que estaré con ellos por sus aportes.

Agradecer a la institución que nos da cobijo durante toda la estadía de desarrollo de nuestros doctorados, el querido INAUT; a mis directores que me dieron la oportunidad de entrar en este universo; a los muchos compañeros de doctorado, que cada uno sabe lo que valoro sus grandes o pequeños aportes en mi estancia doctoral; a todo el personal de la UNSJ y CONICET que siempre estuvieron dispuestos a dar una mano desde su lugar; a mi familia, que disfrutan mis logros quizás mas de los que yo lo hago; y cerrar con un agradecimiento especial a Dios, que es quien nos da la oportunidad de todo, sin El nada tiene sentido.

PD: mención especial a Pancho Rossomando, que desde un lugar super desinteresado trajo luz a esta tesis.

RESUMEN

Monitorización y análisis continuo de cultivos para optimización y control del riego basado en modelo.

Juan Abel Gomez

El riego es un factor fundamental para aumentar la productividad agrícola. Sin embargo, este sector enfrenta desafíos significativos como la escasez de agua (exacerbada por el cambio climático) y la ineficiencia en su uso. Debido a esto, se destaca la necesidad de adoptar técnicas de riego de precisión, que permitan aplicar agua de manera óptima según las necesidades del cultivo y las condiciones del suelo. En este sentido, el sistema de riego debe considerar la naturaleza variante tanto espacial como temporal del sistema agua-suelo-clima-cultivo. El uso de modelos matemáticos para simular el movimiento del agua, en suelos cultivables, aceleró la necesidad de comprender aquellas variaciones temporo-espaciales, que afectan la interpretación de las variables del sistema. La utilización de modelos matemáticos que combinan características del suelo, del cultivo y del clima, integrados a sistemas de medición y control, logran la adecuada planificación, administración y gestión del riego. En orden a lo anterior, en esta tesis, se integra un modelo de distribución de agua en el suelo y un modelo de extracción de agua por parte de un cultivo. De esta manera, el primero de ellos modela el sistema agua-suelo y el restante el sistema planta-atmósfera. El modelo del sistema se prueba en simulación para el caso de ausencia y en presencia de cultivo. Los resultados, se contrastan contra mediciones obtenidas en campo para un tipo de suelo de la provincia de San Juan. Además, se desarrollan algoritmos de control adaptativos para considerar la variabilidad espacial y temporal de un suelo cultivado. Para ello, se diseñaron algoritmos basados en Redes Neuronales Artificiales (RNA) y en Control Predictivo basado en Modelo (MPC). Los controladores implementados con RNA se fundaron principalmente en dos estrategias de diseño. En la primera, se ajusta un controlador del tipo Proporcional-Integrativo (PI) en combinación con un control por superficies deslizantes. La segunda estrategia, contempla un controlador PI estático al que se le añade un termino de compensación empleando RNAs de base radial (RBF). Por último, se implementa un MPC que permita el control simultáneo de varias zonas de manejo de riego. En este caso, solo se atiende una de estas zonas, en función de la demanda hídrica de los cultivos.

ABSTRACT

Continuous crop monitoring and analysis for model-based irrigation optimization and control.

Juan Abel Gomez

Irrigation is a key factor in increasing agricultural productivity. However, this sector faces significant challenges such as water scarcity (exacerbated by climate change) and inefficient water use. Due to this, the need to adopt precision irrigation techniques that allow optimal water application according to crop needs and soil conditions stands out. In this sense, the irrigation system must consider both the spatial and temporal variant nature of the water-soil-climate-crop system. The use of mathematical models to simulate water movement in arable soils has accelerated the need to understand those temporal-spatial variations that affect the interpretation of system variables. The use of mathematical models that combine soil, crop and climate characteristics, integrated with measurement and control systems, achieves adequate irrigation planning, administration and management. In order to achieve this, in this thesis, a model of water distribution in the soil and a model of water extraction by a crop are integrated. Thus, the first one models the soil-water system and the other one the plant-atmosphere system. The system model is tested in simulation for the case of absence and presence of crop. The results are contrasted against measurements obtained in the field for a type of soil in the province of San Juan. In addition, adaptive control algorithms are developed to consider the spatial and temporal variability of a cultivated soil. For this purpose, algorithms based on Artificial Neural Networks (ANN) and Model Based Predictive Control (MPC) were designed. The controllers implemented with ANN were mainly based on two design strategies. In the first one, a Proportional-Integrative (PI) controller is fitted in combination with a sliding surface control. The second strategy involves a static PI controller to which a compensation term is added using radial-based ANNs (RBF). Finally, an MPC is implemented to allow simultaneous control of several irrigation management zones. In this case, only one of these zones is served, depending on crop water demand.

ÍNDICE GENERAL

Tabla de contenido	II
Lista de figuras	IV
Lista de tablas	V
1 Introducción	1
1.1 Justificación	1
1.2 Objetivos	8
1.2.1 Objetivo general	8
1.2.2 Objetivos específicos	8
1.3 Aportes y limitaciones	9
1.3.1 Aportes	9
1.3.2 Limitaciones	9
1.4 Difusión de los aportes de investigación	10
1.4.1 Publicaciones en revistas indexadas	10
1.4.2 Participación en congresos nacionales	10
1.5 Estructura de la tesis	10
2 Marco teórico	13
2.1 Modelo agua-suelo-clima-cultivo	14
2.1.1 Modelo para simular patrones de humedecimiento del suelo bajo riego por goteo superficial: <i>Drip-</i> <i>Irrewater</i>	14
2.1.2 Modelo bidimensional de absorción de agua por las raíces	20
2.2 Sistemas de control de riego	22
2.2.1 Redes neuronales artificiales de base radial	24
2.2.2 Control predictivo basado en modelo	27
3 Modelo agua-suelo-clima-cultivo	35
3.1 Estado del arte	35
3.2 Formulación matricial	41

3.2.1	Flujo de entrada	41
3.2.2	Flujo interno	42
3.2.3	Término sumidero	45
3.3	Simulaciones	46
3.3.1	Resultados	48
3.4	Conclusiones	51
4	Sistema de decisión de riego	55
4.1	Sistema de decisión de riego	55
4.1.1	Estado del arte	55
4.1.2	Generalidades	62
4.2	Control PI neuro-adaptable por superficies deslizantes . .	63
4.2.1	Diseño del controlador	63
4.2.2	Resultados	73
4.2.3	Conclusiones	75
4.3	Control PI con compensación	76
4.3.1	Diseño del controlador	77
4.3.2	Resultados	88
4.3.3	Conclusiones	93
4.4	Control MPC	94
4.4.1	Diseño del controlador	94
4.4.2	Resultados	99
4.4.3	Conclusiones	101
5	Conclusiones y trabajos futuros	105
	Bibliografía	123

ÍNDICE DE FIGURAS

1.1	Factores productivos de un cultivo (Alocén, 2007).	1
1.2	Consumo de agua por sector a nivel mundial.	2
1.3	Consumo de agua por sector a nivel nacional.	3
2.1	Representación geométrica del área de interés. Fuente: Ramirez de Cartagena Bisbe y Sáinz Sánchez, 1997.	16
2.2	Mallado y división del mismo en regiones. Interacción entre celdas adyacentes. Fuente: (Ramirez de Cartagena Bisbe & Sáinz Sánchez, 1997)	17
2.3	Transferencias de agua y distancias desde el centro del cilindro en dirección horizontal.	18
2.4	Coefficiente de reducción para la absorción de agua por las raíces γ , en función del potencial de presión del agua en el suelo ψ_h (L) (Feddes et al., 2001).	23
2.5	Estructura RBF	24
2.6	Estrategia de horizonte deslizante	29
2.7	Esquema MPC	30
3.1	Evapotranspiración de referencia.	49
3.2	Mediciones en campo y en simulación del contenido volumétrico de agua porcentual ante una misma secuencia de riego.	49
3.3	Mediciones en campo y en simulación del contenido volumétrico de agua porcentual ante una misma secuencia de riego.	50
3.4	Extracto de la secuencia de riego considerando un suelo cultivado, incorporando respuesta sin modelo de extracción.	51
3.5	Error absoluto de la respuesta de simulación del modelo.	52
3.6	Evolución del bulbo húmedo generado bajo la superficie irrigada.	54
4.1	Arquitectura de control del sistema de riego.	64
4.2	Estructura de la red RBF-PI	66

4.3	Contenido volumétrico de agua porcentual controlador PI-neuronal. Valor de referencia $\theta_{ref} = 22\%$. Suelo 1. . .	74
4.4	Contenido volumétrico de agua porcentual controlador PI-neuronal. Valor de referencia $\theta_{ref} = 22\%$. Suelo 2. . .	74
4.5	Respuesta del controlador PI neuronal ante perturbaciones aleatorias.	76
4.6	Esquema de la estrategia de control PI neuroadaptativa propuesta, incluida la ley de aprendizaje.	80
4.7	Respuestas de humedad ante un controlador PID tradicional y un PI neuronal. $\theta_{ref} = 22\%$. Tipo de suelo 1. . . .	90
4.8	Respuestas de humedad ante un controlador PID tradicional y un PI neuronal. $\theta_{ref} = 22\%$. Tipo de suelo 2. . . .	91
4.9	Respuestas de humedad ante un controlador PID tradicional y un PI neuronal. $\theta_{ref} = 22\%$. Tipo de suelo 3. . . .	91
4.10	Respuesta del controlador PI neuronal ante perturbaciones aleatorias.	93
4.11	Estructura del control predictivo del proceso.	98
4.12	Ensayo 1. a) Respuestas de contenido de humedad a 30cm de profundidad. b) Salidas MPC. c) Accionamiento de las válvulas	102
4.13	Ensayo 2. a) Respuestas de contenido de humedad a 30cm de profundidad. b) Salidas MPC. c) Accionamiento de las válvulas	102

ÍNDICE DE TABLAS

3.1	Propiedades del suelo	47
3.2	Parámetros del modelo de suelo	47
3.3	Parámetros del modelo de extracción	47
3.4	Parámetros y variables del modelo	53
4.1	Nomenclatura del diseño del controlador	72
4.2	Propiedades texturales e hídricas	73
4.3	Parámetros del modelo de suelo	73
4.4	Parámetros del modelo de extracción	73
4.5	Comparación entre el controlador PI neuronal y el PID .	75
4.6	Nomenclatura del diseño del controlador	89
4.7	Propiedades texturales e hídricas	89
4.8	Parámetros del modelo de suelo	90
4.9	Comparación entre el controlador PI neuronal y el PID .	92
4.10	Nomenclatura del controlador	99
4.11	Propiedades texturales e hídricas	100
4.12	Parametros del modelo de suelo	100
4.13	Parámetros modelo extracción	101

INTRODUCCIÓN

1.1 Justificación

El potencial productivo de un cultivo viene determinado por la interacción de distintas variables, según puede verse en la Figura 1.1. Así, factores de producción tales como: semillas, control de plagas, nutrientes, cosecha, comercialización, riego, etc., forman un conjunto indivisible que puede llevar a un sistema productivo a tener mayor sostenibilidad. Esto implica mayor productividad, rentabilidad, estabilidad y elasticidad (Alocén, 2007).




Figura 1.1: Factores productivos de un cultivo (Alocén, 2007).




Figura 1.2: Consumo de agua por sector a nivel mundial.

El riego, factor en el que se focaliza en esta tesis, se presenta como un medio más para potenciar la capacidad productiva del sistema de producción en relación a otros factores también importantes.

El agua, es un insumo fundamental para la producción agrícola y desempeña un papel importante en *la seguridad alimentaria*. La agricultura de regadío, representa el 20 % del total de la superficie cultivada y aporta el 40 % de la producción total de alimentos en el mundo. En promedio, es al menos el doble de productiva por unidad de tierra que la agricultura de secano, lo que permite una mayor intensificación de la producción y diversificación de los cultivos (BM, 2006).

A escala global, el consumo por parte del sector agrícola es de aproximadamente 70 % del agua dulce disponible, siendo el mayor consumidor de este recurso. En Argentina, este porcentaje se encuentra levemente por encima de la media mundial. Esto puede visualizarse en los gráficos de torta de la Figura 1.2 y la Figura 1.3 en relación al uso del recurso hídrico por parte de otros sectores de la economía (FAO, 2015, 2016).

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 absorción por las capas más profundas del suelo, más allá del alcance de




Figura 1.3: Consumo de agua por sector a nivel nacional.

las raíces de las plantas.

El cambio climático amenaza con exacerbar la situación con una reducción prevista de los recursos hídricos (Falloon & Betts, 2010) y un aumento en la demanda de agua para la agricultura (Rodríguez Díaz et al., 2007).

En ese sentido, la actual crisis hídrica que atraviesa Argentina, particularmente en la región cuyana, es una de las más acentuadas y prolongadas en el tiempo. Los estudios remarcan la presencia de una mega-sequía regional desde 2010 y que continúa hasta el día de hoy (Boisier et al., 2018). Algunos autores señalan que esta sequía comenzó para el río San Juan en 2009.

En la provincia de San Juan, las prácticas agrícolas constituyen el principal uso consuntivo del sistema de irrigación dependiente del río homónimo (Rojas, 2021), alcanzando aproximadamente el 92 % del uso del agua. Según indican los datos preliminares del último censo agropecuario 2018 (INDEC, 2023), se registran 3253 explotaciones agropecuarias, abarcando un área de 57019ha que se riegan efectivamente, de las que solo el 42 % utiliza como sistema el riego por goteo. Ese porcentaje aún es bajo teniendo en cuenta que San Juan depende de la nieve en cordillera para tener agua y que este recurso cada vez es más escaso.

Los nuevos desarrollos agrícolas extensivos, la megaminería y el crecimiento turístico son actividades en auge en la provincia. Sin embargo, estas actividades requieren de un creciente consumo de agua en un contexto de escasez derivada de procesos de variabilidad climática y deficiencias en la distribución del recurso hídrico entre sectores sociales, actividades y territorios. De hecho, se ha detallado un incremento de la demanda de agua, una afectación de la seguridad hídrica y un aumento de la vulnerabilidad y de las disputas territoriales por el agua (Rojas, 2021).

Esto, ocurre en sintonía con lo que avisoraba a nivel mundial el BM, 2006 en vistas del crecimiento demográfico y la urbanización de las ciudades, donde se esperaba un aumento de la competencia por los recursos hídricos, impactando particularmente en la agricultura. Asimismo, en este orden de cosas, en los países desarrollados las industrias llegan a consumir hasta un 50 % del agua disponible para consumo humano. En países como Bélgica ese consumo llega a ser hasta de un 80 % (FAO, 2016).

Debido a esa creciente demanda propia y por parte de otros sectores, el agua para riego es también cada vez menor. Por lo que, se hace necesaria la adopción de técnicas de monitoreo y control del riego tendientes a reducir el derroche de agua y aumentar la productividad de las plantaciones. El problema de la gestión eficiente del recurso hídrico en la agricultura es ampliamente reconocido como un desafío importante a tener en cuenta.

En este sentido, un concepto ampliamente difundido a nivel mundial es el denominado *riego de precisión*. Algunos investigadores lo definen como el uso de sistemas de aplicación de riego eficientes, mientras que otros lo ven como la aplicación variable de riego basada en mapas predefinidos o retroalimentación de sensores (Raine et al., 2007).

Una definición alternativa, indica que involucra la determinación y cuantificación precisa de las necesidades de agua del cultivo y la aplicación precisa de un volumen de agua óptimo en el tiempo requerido.

Por tanto, el riego de precisión puede definirse como: *la gestión sostenible de los recursos hídricos que implica la aplicación de agua en el momento, cantidad, lugar y manera correcta al cultivo, lo que ayuda a gestionar la variabilidad del agua en el campo, lo que a su vez aumenta la productividad del cultivo y el agua. Utilizar la eficiencia junto con la reducción del costo de energía en el riego* (Smith et al., 2010).

Por tanto, en un suelo cultivado se hace necesario considerar la variabilidad espacial y temporal para lograr la caracterización del mismo (Pandey, Pandey et al., 2010). La variabilidad en las propiedades del suelo es mayor cuando éste es sometido a uso por parte del sector agrícola en comparación con su estado natural (Jaramillo J., 2012). Además, la variabilidad del rendimiento y calidad del cultivo puede explicarse a través del cambio en las propiedades espaciales del suelo.

Las propiedades hídricas y texturales del suelo y, las características del terreno como la topografía, factores abióticos y de manejo (compactación, labranza, etc.), varían espacialmente en un campo. Por tanto, estos tienen una influencia directa en la capacidad de retención de agua del suelo (Smith et al., 2010). La distribución espacial del agua en el suelo se relaciona estrechamente con la demanda de agua de los cultivos, ya que esta es la única fuente disponible para extracción por parte de las raíces.

Además, las características de una zona cultivada variarán con el tiempo. Las propiedades que suelen variar dentro de una misma estación y entre estaciones son: el crecimiento de los cultivos, el suelo (debido a la adición de nutrientes y otros procesos de gestión) y el clima. Esto influirá directamente en el volumen y el momento de riego para un crecimiento óptimo del cultivo (Smith et al., 2010).

Khosla et al., 2010 y Woo et al., 2022, discuten la importancia de cuantificar y manejar la variación espacial en los campos cultivados. En el primer trabajo, se implementa una gestión de riego sitio específica, mediante unidades de manejo de riego (MZ - siglas en inglés). Esto requiere de un conocimiento preciso de la heterogeneidad dentro del campo. Las zonas de manejo de riego son un grupo de unidades homogéneas con características similares de retención de agua en el suelo (HMZ) (Hedley & Yule, 2009).

El sistema debe ser capaz de controlar el caudal de riego aplicado a cada HMZ definida dentro de un campo (Pierce, 2010). De esta manera, empleando una metodología de riego de tasa variable (VRI, por sus siglas en inglés (Monaghan et al., 2013)) se puede incrementar la eficiencia y sostenibilidad en el uso del agua.

Para implementar este tipo de metodología es necesario contar con un sistema de riego tecnificado. Un sistema de riego tecnificado, es la prác-

tica que se emplea para aprovechar de forma más eficiente el agua. En algunos países también es conocido como riego mecanizado o presurizado. Básicamente este método aprovecha la presión para llevar agua a través de conductos cerrados y distribuirla mediante aspersión o goteo. Existen distintos tipos de riego y la clasificación varía, pero la mayoría de los autores reconocen estos tipos de sistema de riego tecnificado: goteo, aspersión, microaspersión, exudado y nebulización. A su vez, la aplicación de agua al cultivo puede realizarse a través de sistemas móviles o fijos.

Se ha logrado la adaptación de los sistemas de riego fijos para la aplicación de agua a tasa variable (Coates & Delwiche, 2008). La implementación de VRI en estos sistemas se consigue mediante el control individual de los emisores de agua o por HMZs (Pierce, 2010). Modina et al., 2021 diseñaron un sistema VRI, obteniendo durante el año que duró el experimento una reducción de la cantidad de agua aplicada del 20 % en un viñedo y del 50 % en un peral con respecto al riego por goteo tradicional.

El uso de modelos matemáticos para simular el movimiento del agua, en suelos cultivables, aceleró la necesidad de comprender aquellas variaciones temporo-espaciales, que afectan la interpretación de las variables del sistema (Bramley, 2009).

Según se presenta en (Capraro et al., 2008), la utilización de modelos matemáticos que combinan características del suelo, del cultivo y del clima, integrados a sistemas de medición y control, logran la adecuada planificación, administración y gestión del riego (en tiempo y volumen). De esta manera, optimizar la cantidad de agua empleada, un crecimiento óptimo de la planta, el adecuado seguimiento vegetativo, y finalmente una alta productividad acorde con las demandas del mercado nacional e internacional.

A su vez, en un sistema de riego localizado o por goteo, de amplio uso en la provincia de San Juan, 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). Además, el conocimiento del movimiento del agua en el suelo (frente de humedecimiento) puede ofrecer mejores bases para proyectar el riego y para planear las prácticas de riego a nivel parcelario (Prado Hernández et al., 2017).

En Argentina, las técnicas de agricultura de precisión han sido incorpora-

das y atendidas con mayor énfasis en cultivos como la soja, maíz, girasol, trigo y otros; en provincias como Buenos Aires, Santa Fe, Córdoba, La Pampa y San Luis (Mendez et al., 2014).

Sin embargo, en la región cordillerana, en particular, en las provincias de San Juan, Mendoza, La Rioja y Catamarca, se presenta una realidad distinta a la del resto del país. Allí, los campos son de menor extensión y los cultivos que predominan son la vid, olivos, frutales y las hortalizas.

A su vez, en estos lugares, se requiere la implementación de sistemas de riego presurizado, debido a la alta demanda hídrica del cultivo y al reducido aporte de agua por lluvia, que ronda entre los 90 a 110mm anuales.

Las tecnologías de medición, comunicación y adquisición actuales permiten obtener mejores estimaciones de las variables del sistema y de manera más accesible. La integración de estas herramientas en la agricultura juega un rol importante, debido a que brinda información objetiva y confiable sobre el estado de los cultivos y sobre indicadores del estado de los procesos que permiten el guiado continuo y la ejecución de acciones correctivas durante la campaña.

Según plantearon Lee et al., 2010, a ello también se integran los dispositivos de hardware portátiles y software embebido que permiten brindar a los usuarios herramientas de manejo de información actualizada, acceso y manejo remoto de los sistemas, y registros de datos graficados históricamente.

Por este motivo, los agricultores demandan la incorporación de nuevas tecnologías que atiendan sus necesidades en base al tipo de agricultura y problemática regional; particularmente en orden a optimizar el uso de recursos (especialmente el agua para riego y energía eléctrica), monitorizar el desarrollo de los cultivos y mejorar la producción en cantidad y calidad según los requerimientos tanto en el mercado local como internacional sobre sus productos (Vita Serman et al., 2012).

Actualmente, en la provincia de San Juan, los métodos empleados para llevar a cabo la programación de las operaciones de riego se limitan a estimar la cantidad de agua requerida en base a datos climáticos históricos. La evapotranspiración del cultivo a lo largo de una o más temporadas de

cosecha se toma como punto de partida. El operador es quien corrige los volúmenes proporcionados por el equipo de riego en base a la presencia de síntomas de estrés hídrico en el cultivo o por observación del contenido de agua en el suelo.

Es necesario que el productor cuente con una serie de herramientas de decisión y de gestión que permitan evolucionar de un manejo “a ojo” hacia un manejo basado en información del intersistema suelo-agua-clima-cultivo. De manera particular, en el riego de precisión, es requerido un control sitio específico y variante en el tiempo y que se ajuste tanto a las necesidades hídricas del cultivo como a la disponibilidad de agua, lo que hace que se precisen algoritmos que permitan tener en cuenta estas situaciones.

1.2 Objetivos

A partir de lo expuesto anteriormente, se definieron los siguientes objetivos para esta tesis:

1.2.1 Objetivo general

Proponer estrategias de control eficientes que consideren la variabilidad del sistema usando un modelo reparametrizado de la dinámica hídrica de un suelo cultivado sometido a riego localizado.

1.2.2 Objetivos específicos

- Reparametrizar las ecuaciones que describen el intersistema agua-suelo-clima-cultivo.
- Analizar e implementar diferentes estrategias de control a fin de cumplir con los requerimientos de riego del cultivo y de eficiencia del uso del agua.
- Difundir las investigaciones y resultados mediante la publicación de los logros alcanzados en congresos y revistas científicas afines a la temática.

1.3 Aportes y limitaciones

1.3.1 Aportes

Las principales contribuciones de esta tesis doctoral son:

1. La integración de un modelo de distribución de agua en el suelo (denominado *Drip-Irrigation*) y un modelo de extracción de agua por parte de las raíces de un cultivo. Abordando los sistemas agua-suelo y clima-cultivo en forma conjunta.
2. El desarrollo de algoritmos de control adaptativos neuronales que consideran la variabilidad espacial y temporal de un suelo cultivado.
 - Diseño de un controlador proporcional-integral neuro adaptable en combinación con un control por superficies deslizantes.
 - Diseño de un controlador proporcional-integral estático modificado mediante la adición de un término de compensación empleando redes neuronales de base radial (RBF).
3. El desarrollo de un algoritmo de control predictivo basado en modelo (MPC), que considera la información de varias zonas de manejo de riego para el control simultáneo de las mismas.

1.3.2 Limitaciones

En esta tesis, no se tiene en cuenta las variaciones del suelo debidas al aporte de fertilizantes y la evapotranspiración en el mismo campo y; en relación a los cultivos, las vinculadas a infestación de plagas y enfermedades. Por otra parte, el perfil del suelo se considera homogéneo a lo largo de toda la profundidad.

Los datos experimentales en campo, fueron tomados de un suelo situado en la provincia de San Juan, específicamente en el Instituto Nacional de Tecnología Agropecuaria (INTA).

1.4 Difusión de los aportes de investigación

1.4.1 Publicaciones en revistas indexadas

- J. A. Gomez, F. Rossomando, F. Capraro, and C. Soria, “Neural compensator for PI soil moisture control,” *Neural Comput Appl*, vol. 35, no. 26, pp. 19131–19144, 2023.
- J. A. Gomez, F. Rossomando, F. Capraro, and C. Soria, “Real-time neuro-adaptive PI control of soil moisture using a hybrid model,” *Revista Iberoamericana de Automática e Informática industrial*, 2023, vol. 20, no 1, p. 93-103.

1.4.2 Participación en congresos nacionales

- J. A. Gomez, F. Capraro, M. Peña, and C. Soria, “Control de la humedad del suelo en una parcela cultivada basado en MPC” in *XX Reunión de Trabajo en Procesamiento de la Información y Control*, Nov. 2023.
- J. A. Gomez, F. Rossomando, F. Capraro, and C. Soria, “Control PID neuronal para humedad en el suelo” in *XIX Reunión de Trabajo en Procesamiento de la Información y Control*, Nov. 2021.
- Ing. J. Abel Gomez, Ing. F. Capraro, Ing. C. Soria, and Ing. M. Peña, “Design of an Irrigation Controller Based on a Water Movement Model in the Soil” in *2018 Argentine Conference on Automatic Control (AADECA)*, 2018, pp. 1–6.
- Ing. F. Capraro, J. Abel Gomez, F. Amarfil, and S. Tosetti, “Sistema de medición de nivel en tanque evaporímetro con recarga automática y de acceso remoto” in *2016 Argentine Conference on Automatic Control (AADECA)*, 2016.

1.5 Estructura de la tesis

A continuación, se presenta la estructura de esta tesis, que consta de 5 capítulos organizados de la siguiente forma:

- **Capítulo 1:** se realiza la justificación del tema de tesis y se proponen los objetivos de la misma. Además, se detallan los aportes,

limitaciones y la divulgación de los mismos.

- **Capítulo 2:**
 - **Sección 1:** se describen las ecuaciones que modelan la distribución del agua en el suelo y se caracteriza la formulación de la extracción de agua por parte de las raíces de un cultivo.
 - **Sección 2:** se detallan las técnicas de control consideradas.
- **Capítulo 3:** se presentan los aportes en lo relacionado a lograr un modelo conjunto del intersistema agua-suelo y clima-cultivo.
- **Capítulo 4:** se exhiben los aportes en cuanto a las estrategias de control del riego empleadas.
- **Capítulo 5:** se exponen las conclusiones de esta tesis, la concreción de los objetivos propuestos y posibles trabajos futuros.
- **Bibliografía**

MARCO TEÓRICO

2.1	Modelo agua-suelo-clima-cultivo	14
2.1.1	Modelo para simular patrones de humedecimiento del suelo bajo riego por goteo superficial: <i>Drip-Irrewater</i>	14
2.1.2	Modelo bidimensional de absorción de agua por las raíces	20
2.2	Sistemas de control de riego	22
2.2.1	Redes neuronales artificiales de base radial . . .	24
2.2.2	Control predictivo basado en modelo	27

En este capítulo, se realiza una introducción a los conceptos teóricos básicos de los tópicos más relevantes de esta tesis: modelado y control. En primer lugar, se presentan las ecuaciones descritas en el modelo *Drip Irrewater* (Arbat et al., 2013). Estas, modelan la distribución de agua en el suelo resolviendo, por diferencias finitas, la ecuación de Richards, 1931. A continuación, se incorpora la formulación de la extracción de agua por parte de las raíces de un cultivo, teniendo en cuenta su distribución espacial en el tiempo (Vrugt et al., 2001). Por último, se reseñan diferentes estrategias de control aplicadas a riego y que servirán de base para esta tesis. Por un lado, técnicas de control basadas en redes neuronales artificiales y, por otro lado, en técnicas de control predictivo basado en modelo.

2.1 Modelo agua-suelo-clima-cultivo

En esta sección, en primer lugar, se caracteriza el sistema *agua-suelo* según el modelo *Drip-Irrewater*. El resto de elementos no fueron incluidos por los autores en ese trabajo. Luego, se presentan los elementos faltantes (*clima-cultivo*), describiendo el trabajo realizado por Vrugt et al., 2001, donde se modela la extracción de agua por parte de las raíces de un cultivo.

2.1.1 Modelo para simular patrones de humedecimiento del suelo bajo riego por goteo superficial: *Drip-Irrewater*

La infiltración del agua y su redistribución en el suelo, bajo una fuente de goteo, pueden estudiarse mediante la ecuación de Richards (o ecuación general de flujo). La misma, en condiciones variables y no saturadas, en ausencia de cultivo toma la forma:

$$\frac{\partial \theta}{\partial t} = \nabla [K(\theta) \nabla \psi_h] \quad (2.1)$$

donde, $\partial \theta / \partial t$ es la variación del contenido volumétrico de agua respecto del tiempo; ∇ vector operador diferencial, representando el gradiente tridimensional; K conductividad hidráulica y ψ_h el potencial hidráulico.

Si se considera simetría axial respecto al eje vertical que pasa por el gotero de riego (y la base de la planta), entonces (2.1) queda simplificada según la siguiente expresión:

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial x} \left(K(\theta) \frac{\partial \psi_h}{\partial x} \right) + \frac{\partial}{\partial z} \left(K(\theta) \frac{\partial \psi_h}{\partial z} \right) \quad (2.2)$$

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

Las ecuaciones constitutivas de la ecuación de Richards (2.1) forman la relaciones entre el contenido de agua, la conductividad y el potencial de presión hidráulica. Su caracterización se establece a partir de las ecuacio-

nes de Mualem-Van Genuchten (Van Genuchten, 1980):

$$S_e = \frac{\theta - \theta_r}{\theta_s - \theta_r} = \left[\frac{1}{1 + (\alpha\psi_h)^n} \right]^m \quad (2.3)$$

$$\theta(\psi_h) = \begin{cases} \theta_r + \frac{(\theta_s - \theta_r)}{[1 + (\alpha\psi_h)^n]^m} & \psi_h \geq 0 \\ \theta_s & \psi_h < 0 \end{cases} \quad (2.4)$$

$$K(S_e) = K_s S_e^l \left[1 - \left(1 - S_e^{\frac{1}{m}} \right)^m \right]^2 \quad (2.5)$$

$$m = 1 - \frac{1}{n} \quad n > 1 \quad (2.6)$$

donde, $\theta(\psi_h)$ es la humedad volumétrica; θ_r es el contenido de agua residual; θ_s es el contenido de agua saturada; K_s es la conductividad hidráulica saturada y; α , n y m son parámetros de ajuste característicos de cada tipo de suelo.

Resolución de términos diferenciales

La ecuación (2.2), se resuelve por métodos numéricos, específicamente, empleando el método de diferencias finitas. Para ello, se comienza definiendo un cilindro en el suelo por debajo del suministro de agua, con anillos concéntricos de anchura Δ_j y altura Δ_i (formando una malla interna), Figura 2.1. El gotero de riego (y la base de la planta) se colocan en el centro de la parte superior del cilindro. Además, las dimensiones del mallado deben ser tales que las paredes no limiten el movimiento del agua, otorgada por el gotero, afectando la forma del bulbo húmedo.

Una vez, definida la geometría del suelo, se calculan los caudales que fluirán desde o hacia la celda genérica (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 del mallado creado. De esta forma, se generan 9 zonas representativas, que se diferencian entre sí por la existencia o no de intercambio con los laterales, como se representa en la Figura 2.2.

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. En la zona 5, que es la única interior, las transferencias de agua se realizan como se había advertido anteriormente




Figura 2.1: Representación geométrica del área de interés. Fuente: Ramirez de Cartagena Bisbe y Sáinz Sánchez, 1997.

con todas las celdas vecinas (2.9)-(2.12).

El caudal que fluye desde o hacia la celda genérica (i, j) y una celda adyacente, se expresa como:

$$Q = qA \quad (2.7)$$

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:

$$Q = -K(\theta) \frac{\Delta\psi_h}{\Delta L} A \quad (2.8)$$

siendo, $K(\theta)$ la conductividad hidráulica en la celda considerada, $\Delta\psi_h$ y ΔL la diferencia de potencial hidráulico (definido negativo para suelos no saturados) y la distancia entre celdas adyacentes, respectivamente. Ahora, considerando el anillo asociado a una celda genérica (i, j) dentro del dominio de flujo y sus cuatro celdas vecinas $(i, j - 1)$, $(i - 1, j)$, $(i, j + 1)$, $(i + 1, j)$ y aplicando (2.8), los caudales a lo largo de los contornos del




Figura 2.2: Mallado y división del mismo en regiones. Interacción entre celdas adyacentes. Fuente: (Ramírez de Cartagena Bisbe & Sáinz Sánchez, 1997)

anillo asociado con la celda (i, j) se calculan como:

$$Q_1 = Q_{i,j-1} = K_{i,j-1}^{i,j} \frac{\psi_{h_{i,j-1}} - \psi_{h_{i,j}}}{\Delta_j} (2\pi R_j \Delta_i) \quad (2.9)$$

$$Q_2 = Q_{i,j+1} = K_{i,j+1}^{i,j} \frac{\psi_{h_{i,j+1}} - \psi_{h_{i,j}}}{\Delta_j} (2\pi R_{j+1} \Delta_i) \quad (2.10)$$

$$Q_3 = Q_{i-1,j} = K_{i-1,j}^{i,j} \frac{\psi_{h_{i-1,j}} - \psi_{h_{i,j}}}{\Delta_i} [\pi(R_{j+1}^2 - R_j^2)] \quad (2.11)$$

$$Q_4 = Q_{i+1,j} = K_{i+1,j}^{i,j} \frac{\psi_{h_{i+1,j}} - \psi_{h_{i,j}}}{\Delta_i} [\pi(R_{j+1}^2 - R_j^2)] \quad (2.12)$$

donde, Q_1 y Q_2 son los flujos horizontales de agua y, Q_3 y Q_4 los flujos verticales, a través del anillo asociado a la celda genérica; $K_{subndice}^{superndice}$ es la conductividad hidráulica media de las celdas indicadas en el subíndice y el superíndice; R_j y R_{j+1} son el radio interior y exterior del anillo (Figura 2.3).

Cuando el signo de (2.9), (2.10), (2.11), (2.12) es negativo, el caudal de agua es saliente respecto de la celda genérica (i, j) y, por el contrario, entrante cuando es positivo.




Figura 2.3: Transferencias de agua y distancias desde el centro del cilindro en dirección horizontal.

El caudal neto (ΔQ) de la celda genérica (i, j) , puede obtenerse mediante la suma de los caudales que fluyen entre la celda genérica y cada una de las celdas vecinas. Del balance de caudales, resulta:

$$\Delta Q_{i,j} = Q_1 + Q_2 + Q_3 + Q_4 \quad (2.13)$$

Entonces, la variación del contenido volumétrico de agua para el anillo correspondiente a la celda genérica (i, j) en un tiempo Δt se calcula de la siguiente forma:

$$\Delta \theta_{i,j} = \frac{\Delta Q_{i,j}}{V_{i,j}} \Delta t \quad (2.14)$$

Siendo, $V_{i,j}$ el volumen del anillo (i, j) , entonces, (2.14) queda expresada:

$$\Delta \theta_{i,j} = \frac{\Delta Q_{i,j}}{\pi(R_{j+1}^2 - R_j^2)\Delta_i} \Delta t \quad (2.15)$$

Por último, el contenido de agua, en cada iteración, será actualizado según la siguiente expresión:

$$\theta_{i,j}(t + \Delta t) = \theta_{i,j}(t) + \Delta \theta_{i,j} \quad (2.16)$$

Para los cálculos, se debe considerar que el caudal neto de cada celda esta sujeta a las condiciones de contorno, según la zona en que se encuentre (Figura 2.2), como se mencionó más arriba.

Zona 1: $i = 1, 1 \leq j \leq N(t)$

$$\Delta Q_{i,j} = \frac{Q_{got}}{N(t)} + Q_{i,j+1}^{i,j} + Q_{i+1,j}^{i,j} \quad (2.17)$$

donde, $N(t)$ es el número de celdas saturadas (puede abarcar celdas que habían sido de la zona 2); Q_{got} es el caudal que otorga el gotero de riego.

Zona 2: $i = 1, 1 < j < j_{max}$

$$\Delta Q_{i,j} = Q_{i,j+1}^{i,j} + Q_{i+1,j}^{i,j} + Q_{i,j-1}^{i,j} \quad (2.18)$$

Zona 3: $i = 1, j = j_{max}$

$$\Delta Q_{i,j} = Q_{i+1,j}^{i,j} + Q_{i,j-1}^{i,j} \quad (2.19)$$

Zona 4: $1 < i < i_{max}, j = 1$

$$\Delta Q_{i,j} = Q_{i-1,j}^{i,j} + Q_{i,j+1}^{i,j} + Q_{i+1,j}^{i,j} \quad (2.20)$$

Zona 5: $1 < i < i_{max}, 1 < j < j_{max}$

$$\Delta Q_{i,j} = Q_{i-1,j}^{i,j} + Q_{i,j+1}^{i,j} + Q_{i+1,j}^{i,j} + Q_{i,j-1}^{i,j} \quad (2.21)$$

Zona 6: $1 < i < i_{max}, j = j_{max}$

$$\Delta Q_{i,j} = Q_{i-1,j}^{i,j} + Q_{i+1,j}^{i,j} + Q_{i,j-1}^{i,j} \quad (2.22)$$

Zona 7: $i = i_{max}, j = 1$

$$\Delta Q_{i,j} = Q_{i-1,j}^{i,j} + Q_{i,j+1}^{i,j} \quad (2.23)$$

Zona 8: $i = i_{max}, 1 < j < j_{max}$

$$\Delta Q_{i,j} = Q_{i-1,j}^{i,j} + Q_{i,j+1}^{i,j} + Q_{i,j-1}^{i,j} \quad (2.24)$$

Zona 9: $i = i_{max}, j = j_{max}$

$$\Delta Q_{i,j} = Q_{i-1,j}^{i,j} + Q_{i,j-1}^{i,j} \quad (2.25)$$

donde, i_{max} y j_{max} son la cantidad máxima de celdas en dirección vertical y horizontal, respectivamente.

2.1.2 Modelo bidimensional de absorción de agua por las raíces

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. A las hojas del cultivo llega gran cantidad de agua absorbida por las raíces, pero sólo una pequeña parte se utiliza en la fotosíntesis. 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). Este índice, afectado por un parámetro K_c , que depende del tipo de cultivo considerado, da como resultado la evapotranspiración de cultivo (ET_c). El mismo, es función de la cantidad de agua que debe reponerse al suelo para cubrir la demanda hídrica del cultivo (Allen et al., 2006).

La influencia de los sistemas planta-raíz en el movimiento del agua y de los productos químicos puede comprenderse mejor utilizando modelos de simulación del agua del suelo, siempre que se incluyan distribuciones espaciales y temporales precisas de la captación de agua por las raíces (Musters & Bouten, 1999; Musters et al., 1998). El enfoque más común es el macroscópico. Donde, para modelizar la captación de agua por las raíces, en flujo no saturado, se introduce un término de sumidero S , en la ecuación de Richards (Clausnitzer & Hopmans, 1994; Molz, 1981; Whisler et al., 1968), que describe el flujo de agua transitorio multidimensional:

$$\frac{\partial \theta}{\partial t} = \nabla[K(\theta)\nabla\psi_h] - S \quad (2.26)$$

siendo, S una función tanto del tiempo como del espacio.

Para determinar el término de sumidero, se parte de la premisa de considerar la distribución de las raíces como no lineal. Por tanto, se define la distribución espacial adimensional de la raíz con la profundidad $\beta(z)$ como:

$$\beta(z) = \left(\frac{z_m - z}{z_m} \right) e^{-\frac{p_z}{z_m}|z^* - z|} \quad (2.27)$$

Donde z_m es la profundidad máxima de enraizamiento; p_z y z^* son parámetros empíricos. Estos parámetros, se incluyeron para prever una absorción nula de agua por las raíces en $z \geq z_m$, para tener en cuenta la absorción no simétrica de agua por las raíces con la profundidad y para permitir la absorción máxima de agua por las raíces a cualquier profundidad.

Para la caracterización de la intensidad de captación a lo largo de la dirección radial, se utiliza una expresión similar a (2.27):

$$\beta(x) = \left(\frac{x_m - x}{x_m} \right) e^{-\frac{p_x}{x_m}|x^* - x|} \quad (2.28)$$

donde, $\beta(x)$ denota la distribución espacial adimensional de la absorción de agua por parte de las raíces en la dirección radial; x_m es la longitud máxima de enraizamiento en la dirección radial; x es la distancia radial desde el origen de la planta y p_x y x^* son parámetros empíricos.

La combinación de la intensidad de absorción a lo largo de la dirección z (2.27) y la dirección radial (2.28), conduce a un modelo bidimensional de absorción de agua por la raíz, expresado:

$$\beta(x, z) = \left(\frac{z_m - z}{z_m} \right) \left(\frac{x_m - x}{x_m} \right) e^{-(\frac{p_z}{z_m}|z^* - z| + \frac{p_x}{x_m}|x^* - x|)} \quad (2.29)$$

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

Denotando la absorción normalizada de agua por las raíces S_m , como el volumen de agua extraída por unidad de tiempo y volumen de suelo y asumiendo simetría axial, se deduce que:

$$S_m = \frac{\pi R^2 \beta(r, z) T_{pot}}{2\pi \int_0^{r_m} \int_0^{z_m} r \beta(r, z) dr dz} \quad (2.30)$$

donde, $S_m(r, z)$ denota la tasa normalizada de absorción de agua por las raíces y R es el tamaño del dominio de flujo en la dirección r . Si $r_m < R$, entonces el valor de R en la Ecuación (2.30) es automáticamente igual a r_m . T_{pot} es la tasa de transpiración potencial.

Las condiciones de estrés debidas a sequedad o humedad del suelo pueden reducir el valor de (2.30). Por ello, se incluye una función de respuesta al estrés hídrico del suelo descrita en la Figura 2.4 (Feddes et al., 2001). La absorción de agua por debajo de ψ_{h1} (deficiencia de oxígeno) y por encima de ψ_{h4} (punto de marchitamiento) se establece en cero. Entre ψ_{h2} y ψ_{h3} (punto de reducción) la absorción de agua es máxima.

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

$$S(\psi_h, r, z) = \gamma(\psi_h, r, z) S_m(r, z) \quad (2.31)$$

Siendo,

$$T_{pot} = K_c E T_o - E_s \quad (2.32)$$

Donde, E_s denota la evaporación desde el suelo.

2.2 Sistemas de control de riego

Las características de un sistema de cultivo varían tanto en el tiempo como en el espacio. Dentro de un sistema de cultivo, las propiedades que suelen variar dentro de una misma estación y entre estaciones son: el crecimiento de los cultivos, las propiedades del suelo (debido a la adición




Figura 2.4: Coeficiente de reducción para la absorción de agua por las raíces γ , en función del potencial de presión del agua en el suelo ψ_h (L) (Feddes et al., 2001).

de nutrientes y otros procesos de gestión) y el clima. Todo ello influye directamente en el momento y el volumen de riego necesarios para un crecimiento óptimo del cultivo (Smith et al., 2010).

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 & Mareels, 2010).

A continuación, se detallan los fundamentos de las técnicas de control empleadas en esta tesis. Primeramente, se aborda la teoría esencial y las principales aplicaciones de las estructuras conexionistas feed-forward, denominadas redes neuronales de función de base radial (RBF), según lo descrito en Strumillo y Kamiński, 2003a. Luego, se presenta la teoría del control predictivo basado en modelo (MPC) de acuerdo al marco conceptual establecido por Camacho y Bordons Alba, 2004.

2.2.1 Redes neuronales artificiales de base radial

Las redes neuronales de función de base radial (RBF, por sus siglas en inglés), son estructuras *feed-forward* que comprenden una única capa oculta de funciones linealmente independientes $\xi_1, \xi_2, \dots, \xi_m$ que forman una base para un espacio de funciones m-dimensional (Broomhead & Lowe, 1988). Una amplia clase de mapeos no lineales $f_m : R^N \rightarrow R$ que pertenecen a un espacio lineal generado, es decir, $f_m \in \text{span}(\xi_1, \xi_2, \dots, \xi_m)$ puede obtenerse mediante la estructura de red RBF que puede observarse en la Figura 2.5. Su función de transferencia viene dada por la siguiente regresión lineal:

$$f_m(\mathbf{x}) = \sum_{k=1}^m w_k \xi_k(\mathbf{x}) + w_0 \quad (2.33)$$




Figura 2.5: Estructura RBF

donde, $\xi_k(\mathbf{x}) = \xi(\|\mathbf{x} - \mathbf{c}_k\|/s_k)$ son las funciones de base (también denominadas los núcleos), siendo estas, dilataciones trasladadas de una función prototipo radialmente simétrica $\xi : R^N \rightarrow R$ y; $w_k, k = 0, 1, \dots, m$ son los coeficientes de ponderación ajustables de la regresión lineal (2.33).

Debido a la simetría radial de las constantes de los núcleos, $\mathbf{c}_k \in R^N$ se denominan centros y $\|\cdot\|$ es una norma (no necesariamente euclidiana, por ejemplo, Mahalonobis) en R^N que define la distancia $r = \|\mathbf{x} - \mathbf{c}_k\|$ entre la entrada $\mathbf{x} \in R^N$ y el centro $\mathbf{c}_k$. La norma adoptada puede escalarse adicionalmente mediante factores de dilatación $s_k \in R$ que se asignan

individualmente a cada una de las funciones de base o se hacen iguales para todas ellas, es decir, $S_1 = S_2 = \dots = S_m = S > 0$. La elección adecuada de los kernels para las funciones de base fue investigada por (Micchelli, 1986). En el caso de las redes RBF, se considera que los de mayor interés son:

Gauss:

$$\xi(r) = \exp(-r^2)$$

Multicuádrica inversa:

$$\xi(r) = \frac{1}{\sqrt{r^2 + 1}}$$

Lineal:

$$\xi(r) = r$$

Spline de placa fina:

$$\xi(r) = r \log r$$

Multicuádrica:

$$\xi(r) = \sqrt{r^2 + 1}$$

Cúbica:

$$\xi(r) = r^3$$

Las funciones gaussianas y multicuádrica inversa, se denominan funciones localizadas ya que $\xi(r) \rightarrow 0$ para $r \rightarrow \infty$ mientras que las restantes RBF's se consideran como no localizadas (es decir, $\xi(r)$ es ilimitado para $r \rightarrow \infty$). Los núcleos localizados tienen una analogía importante con los campos receptivos observados en sistemas neuronales biológicos (por ejemplo en la superficie retiniana del sistema visual), que son sensibles a estímulos situados dentro de un rango acotado del espacio de entrada. Sin embargo, Powell, 1987 indica que las RBF no locales son más eficientes en la aproximación de mapeados suaves de entrada-salida que las RBF localizadas (ver también los trabajos de Duch y Jankowski, 1999; Strumillo y Kaminski, 2001).

El paradigma de la aproximación de las redes neuronales RBF proviene de la teoría de las funciones potenciales (Ajzernan et al., 1976) y de

la interpolación multivariante en espacios de alta dimensión estudiada por Powell, 1987. El ha demostrado que para un conjunto dado de P coordenadas de interpolación $\{(x_i, y_i) \in R^d \times R\}_{i=1}^P$, es decir, valores escalares y_i dados (por ejemplo, medidos) en coordenadas x_i , existe una función de interpolación $f_m(\mathbf{x}) = \sum_{i=1}^{m=P} w_i \xi(\|x - x_i\|)$ que satisface la condición de interpolación $f_m(x_i) = y_i, i = 1, 2, \dots, m = P$. Debe notarse, que la función de interpolación es una superposición lineal de un número de RBFs que es igual al número de coordenadas de interpolación que coinciden con los centros del núcleo $c_i = x_i$. Insertando la condición de interpolación en la ecuación de la función de interpolación se obtiene $\Xi \mathbf{w} = \mathbf{y}$, donde $\mathbf{w} = [w_1, w_2, \dots, w_P]$, $\mathbf{y} = [y_1, y_2, \dots, y_P]$ y la matriz cuadrada $\Xi = \{\xi(\|x_j - x_i\|), (j, i) = 1, 2, \dots, P\}$ (la matriz de interpolación) es no singular para distintos x_i y una clase de RBFs adecuadamente elegidas (Micchelli, 1986). Por tanto, la solución del problema de interpolación se obtiene fácilmente como $\mathbf{w} = \Xi^{-1} \mathbf{y}$.

Redes RBF como aproximadores universales

La idea básica propuesta por Broomhead y Lowe, 1988 y Moody y Darken, 1989 que condujo al concepto de redes neuronales RBF se basaba en reformular la condición de interpolación estricta (con tantos núcleos RBF como puntos de datos) en un problema de aproximación de funciones, en el que el número de núcleos RBF es intencionadamente inferior al número de puntos de disponibles, es decir, $m < P$. Muchas tareas de modelización de señales y sistemas (por ejemplo, predicción de series temporales, identificación de sistemas dinámicos) pueden definirse en términos de aproximación de funciones (Strumillo, 2001), (Strumillo & Kamiński, 2003b), (Whitehead & Choate, 1996).

La justificación teórica del uso de redes RBF como aproximadores de funciones se dio en (Park & Sandberg, 1993) donde se formuló el teorema de aproximación universal para topologías de redes RBF (Figura 2.5). A saber: *para cualquier función continua de mapeo entrada-salida $f(x)$, existe una red RBF con m núcleos acotados integrables, tal que la función de mapeo $f_m(x)$ dada por (2.34) se aproxime a $f(x)$ de forma arbitraria en la norma L^P para cada $p \in [1, \infty)$ (donde L^P es un espacio de funciones que satisfacen $\int_{R^N} |f(x)|^p dx < \infty$).*

Obsérvese, también, que una red RBF con múltiples salidas puede dividirse

en un conjunto de redes separadas de salida única, cada una de las cuales comparte el mismo conjunto de RBF (tal como se define en (2.34) y se muestra en la Figura 2.5). Por lo tanto, las redes RBF pueden considerarse aproximadores universales MIMO. Además, Hunt et al., 1996 observó una equivalencia funcional entre las redes RBF y los sistemas de inferencia difusa (cada núcleo RBF puede servir como una función de membresía difusa).

Un área de amplia aplicación de las capacidades de aproximación de las redes RBF es la identificación de sistemas dinámicos no lineales, el control y la predicción de series temporales. Las relaciones entre las entradas del sistema $\mathbf{u}(t)$ y las respuestas del sistema $\mathbf{y}(t)$ se modelizan mediante una ecuación de predicción de un paso por delante:

$$\mathbf{y}(t+1) = S[\mathbf{y}(t), \mathbf{y}(t-1), \dots, \mathbf{y}(t-k); \dots \mathbf{u}(t+1), \mathbf{u}(t), \dots, \mathbf{u}(t-n)] \quad (2.34)$$

donde, $S(\cdot)$ es la función multivariante, definida en $k+m+1$ entradas vectoriales dimensionales, que necesita ser aproximada por la red. Whitehead y Choate, 1996 adoptaron este enfoque de modelado de sistemas en la tarea de aproximación de redes RBF para la identificación de sistemas no lineales estacionarios y variables en el tiempo (Yingwei et al., 1998). Otras aplicaciones de RBF en tareas de aproximación de funciones son la predicción de series temporales no lineales (Chng et al., 1996), el control (Fabri & Kadiramanathan, 1996; Luo et al., 1996), la estimación no paramétrica (Krzyzak et al., 1996) y las telecomunicaciones (Chen et al., 1993).

2.2.2 Control predictivo basado en modelo

El Control Predictivo Basado en Modelo (MBPC) o *Model Based Predictive Control (MPC)* constituye un campo muy amplio de métodos de control desarrollados en torno a ciertas ideas comunes e integra diversas disciplinas como control óptimo, control estocástico, control de procesos con tiempos muertos, control multivariable o control con restricciones.

Las ideas que aparecen en mayor o menor medida en toda la familia de controladores predictivos son básicamente:

1. Uso explícito de un modelo para predecir la salida del proceso en

- futuros instantes de tiempo (horizonte).
2. Cálculo de las señales de control minimizando una cierta función objetivo.
 3. Estrategia deslizante, de forma que en cada instante el horizonte se va desplazando hacia el futuro, lo que implica aplicar la primera señal de control en cada instante y desechar el resto, repitiendo el cálculo en cada instante de muestreo.

En la actualidad existen numerosas aplicaciones de controladores predictivos funcionando con éxito, tanto en la industria de procesos como en control de motores o robótica. El buen funcionamiento de estas aplicaciones muestra la capacidad del MPC para conseguir sistemas de control de elevadas prestaciones capaces de operar sin apenas intervención durante largos periodos de tiempo.

Pero, lógicamente, también presenta inconvenientes. Uno de ellos es la carga de cálculo necesaria para la resolución de algunos algoritmos. Pero quizás el mayor inconveniente venga marcado por la necesidad de disponer de un modelo apropiado del proceso. El algoritmo de diseño está basado en el conocimiento previo del modelo y es independiente de éste, pero resulta evidente que las prestaciones obtenidas dependerán de las discrepancias existentes entre el proceso real y el modelo usado.

Estrategia

La metodología de todos los controladores pertenecientes a la familia del MPC se caracteriza por la estrategia siguiente, representada en la Figura 2.6:

- En cada instante t y haciendo uso del modelo del proceso se predicen las futuras salidas para un determinado horizonte N , llamado horizonte de predicción. Estas salidas predichas, $\hat{y}(t + k|t)$ para $k = 1, \dots, N$ dependen de los valores conocidos hasta el instante t (entradas y salidas pasadas) y de las señales de control futuras $u(t + k|t)$, $k = 0, \dots, N - 1$ que se pretenden mandar al sistema y que son las que se quieren calcular.
- El conjunto de señales de control futuras se calcula optimizando un determinado criterio en el que se pretende mantener el proceso lo más próximo posible a la trayectoria de referencia $y_{ref}(t + k)$

(que puede ser directamente el *setpoint* o una suave aproximación a éste). Este criterio suele tomar la forma de una función cuadrática de los errores entre la salida predicha y la trayectoria de referencia también predicha, incluyendo en muchos casos el esfuerzo de control. Si el criterio es cuadrático, el modelo es lineal y no existen restricciones se puede obtener una solución explícita, en otro caso se debe usar un método iterativo de optimización. Adicionalmente, se hace alguna suposición sobre la estructura de la ley de control futura, como por ejemplo que va a ser constante a partir de cierto instante.

- La señal de control $u(t|t)$ es enviada al proceso mientras que las siguientes señales de control calculadas son desechadas, puesto que en el siguiente instante de muestreo ya se conoce $y(t+1)$ y se repite el paso 1 con este nuevo valor y todas las secuencias son actualizadas. Se calcula, por tanto, $u(t+1|t+1)$ (que en principio será diferente al $u(t+1|t)$ al disponer de nueva información), haciendo uso del concepto de horizonte deslizante.




Figura 2.6: Estrategia de horizonte deslizante

Para llevar a cabo esta estrategia, se usa una estructura como la mostrada en la Figura 2.7. Se hace uso de un modelo para predecir las salidas futuras del proceso, basándose en las futuras señales de control propuestas. Estas señales son calculadas por el optimizador teniendo en cuenta la función de costo (donde aparece el futuro error de seguimiento) así como las restricciones. Por tanto, el modelo juega un papel decisivo en el controlador. El modelo elegido debe ser capaz de capturar la dinámica del proceso para poder predecir las salidas futuras al mismo tiempo que debe ser sencillo

de usar y de comprender.

El optimizador es otra parte fundamental de la estrategia, ya que proporciona las acciones de control. Si la función de costo es cuadrática, el mínimo se puede obtener como una función explícita de las entradas y salidas pasadas y de la trayectoria de referencia. Sin embargo, cuando existen restricciones de desigualdad la solución debe ser calculada por métodos numéricos con más carga de cálculo.




Figura 2.7: Esquema MPC

Elementos básicos

Todos los controladores predictivos poseen elementos comunes y para cada uno de estos elementos se pueden elegir diversas opciones, dando lugar a distintos algoritmos. Estos elementos son:

- Modelo de predicción
- Función objetivo
- Obtención de la ley de control

La piedra angular del MPC es el modelo; un diseño completo debe incluir los mecanismos necesarios para la obtención del mejor modelo posible, el cual debe ser lo suficientemente rico para capturar al máximo la dinámica del proceso y debe ser capaz de permitir el cálculo de las predicciones a

la vez que sea intuitivo y permita un análisis teórico. El uso del modelo del proceso viene determinado por la necesidad del cálculo de la salida predicha en instantes futuros $\hat{y}(t + k|t)$.

Las diferentes estrategias de MPC pueden usar distintos modelos para representar la relación de las salidas con las entradas medibles, algunas de las cuales serán variables manipuladas y otras se pueden considerar como perturbaciones medibles, que pueden ser compensadas por acción *feedforward*. Además, se tendrá en cuenta un modelo de las perturbaciones, para intentar describir el comportamiento que no aparece reflejado en el modelo del proceso, englobándose aquí el efecto de las entradas no medibles, el ruido y los errores de modelado.

Los diversos algoritmos de MPC proponen distintas funciones de costo para la obtención de la ley de control. En general, se persigue que la salida futura en el horizonte considerado siga a una determinada señal de referencia al mismo tiempo que se puede penalizar el esfuerzo de control requerido para hacerlo. La expresión general de tal función objetivo será:

$$J(N_1, N_2, N_u) = \sum_{j=N_1}^{N_2} \delta(j) [\hat{y}(t + j|t) - y_{ref}(t + j)]^2 + \sum_{j=1}^{N_u} \lambda(j) [\Delta u(t + j - 1)]^2 \quad (2.35)$$

En algunos métodos, el segundo sumando, que considera el esfuerzo de control, no se tiene en cuenta, mientras que en otros también aparecen directamente los valores de la señal de control (no sus incrementos). En la función objetivo se pueden considerar:

- Parámetros: N_1 y N_2 son los horizontes de predicción mínimo y máximo, denotando los límites de los instantes en que se desea que la salida siga a la referencia; N_u es el horizonte de control, que puede no coincidir con N_2 . Así, si se toma un valor grande de N_1 es porque no importa que haya errores en los primeros instantes, lo que provocará una respuesta suave del proceso. Los coeficientes $\delta(j)$ y $\lambda(j)$ son secuencias que ponderan el compor-

tamiento futuro. Generalmente, se consideran valores constantes o secuencias exponenciales. Por ejemplo, se puede conseguir un peso exponencial de $\delta(j)$ a lo largo del horizonte usando:

$$\delta(j) = \alpha^{N_2-j} \quad (2.36)$$

Si α está comprendido entre 0 y 1 indica que hay una mayor penalización para los errores más alejados del instante t que a los más próximos. Esto, da lugar a un control más suave y con menor esfuerzo. Si, por el contrario, $\alpha > 1$ se penalizan los primeros errores, provocando un control más brusco.

- Trayectoria de referencia: Una de las ventajas del control predictivo es que si se conoce *a priori* la evolución futura de la referencia, el sistema puede empezar a reaccionar con anticipación. En el criterio de minimización (2.35), la mayoría de los métodos suelen usar una trayectoria de referencia $y_{ref}(t+k)$ que no necesariamente coincide con la referencia real. Generalmente, será una suave aproximación desde el valor actual de la salida $y(t)$ a la referencia conocida mediante un sistema de primer orden:

$$\begin{aligned} y_{ref}(t) &= y(t) \\ y_{ref}(t+k) &= \alpha w(t+k-1) + (1-\alpha)r(t+k) \\ k &= 1, \dots, N \end{aligned} \quad (2.37)$$

donde, α es un parámetro comprendido entre 0 y 1 (mientras más próximo a 1, más suave será la aproximación) que constituye un valor de ajuste que influirá en la respuesta dinámica del sistema. Para valores pequeños de α , se tiene un seguimiento rápido, mientras que si aumenta, la trayectoria de referencia da lugar a una respuesta más suave.

- Restricciones: En la práctica, todos los procesos están sujetos a restricciones. Los actuadores tienen un campo limitado de acción así como una determinada velocidad de cambio (*slew rate*), como es el caso de las válvulas, limitadas por las posiciones de totalmente abierta o cerrada y por la velocidad de respuesta. Asimismo, razones constructivas, de seguridad o medioambientales o bien los propios alcances de los sensores pueden causar límites en las variables del proceso. Además, las condiciones de operación vienen

definidas por la intersección de ciertas restricciones por motivos fundamentalmente económicos, con lo que el sistema de control operará cerca de los límites. Lo expuesto anteriormente, hace necesaria la introducción de restricciones en la función a minimizar. Los límites se pueden considerar en la amplitud y el *slew rate* de la señal de control y en las salidas.

$$u_{min} \leq u(t) \leq u_{max} \quad \forall t \quad (2.38)$$

$$du_{min} \leq u(t) - u(t-1) \leq du_{max} \quad \forall t \quad (2.39)$$

$$y_{min} \leq y(t) \leq y_{max} \quad \forall t \quad (2.40)$$

La adición de estas restricciones a la función objetivo, resulta en una minimización más compleja, no pudiendo obtenerse la solución analíticamente como en el caso sin restringir.

Ley de control

Para obtener los valores $u(t+k|t)$ será necesario minimizar el funcional J de la ecuación (2.35). Para ello, se calculan los valores de las salidas predichas $\hat{y}(t+k|t)$ en función de valores pasados en entradas y salidas, y de señales de control futuras. Para el criterio cuadrático, si el modelo es lineal y no existen restricciones, se puede obtener una solución analítica, en otro caso se debe usar un método iterativo de optimización.

La obtención de la solución, no resulta trivial ya que existirán $N_2 - N_1 + 1$ variables independientes, valor que puede ser elevado. Para reducir estos grados de libertad, se puede proponer cierta estructura a la ley de control. Además, dicha estructuración de la ley de control produce una mejora en la robustez y en el comportamiento general del sistema. Esto, debido, fundamentalmente, a que el hecho de permitir la libre evolución de las variables manipuladas (sin estructurar) puede conducir a señales de control de alta frecuencia no deseables e incluso a la inestabilidad.

Esta estructura de la ley de control, se plasma en el uso del concepto de horizonte de control (N_u), que consiste en que tras un cierto intervalo $N_u < N_2$, no hay variación en las señales de control propuestas, es decir:

$$\Delta u(t+j-1) = 0 \quad j > N_u \quad (2.41)$$

esto, es equivalente a dar pesos infinitos a los cambios en el control, a partir de cierto instante. El caso límite, sería considerar $N_u = 1$, con lo que todas las acciones futuras serían iguales a $u(t)$.

MODELO AGUA-SUELO-CLIMA-CULTIVO

3.1	Estado del arte	35
3.2	Formulación matricial	41
3.2.1	Flujo de entrada	41
3.2.2	Flujo interno	42
3.2.3	Término sumidero	45
3.3	Simulaciones	46
3.3.1	Resultados	48
3.4	Conclusiones	51

En este capítulo, se hará una revisión del estado del arte respecto al modelado de un suelo sometido a riego y en presencia de un cultivo. Luego, se retomarán las ecuaciones descritas en la sección 2.1.1 y en la sección 2.1.2 estableciendo un modelo conjunto de ambas formulaciones. De esta manera, se presenta el sistema agua-suelo-clima-cultivo de forma completa y se propone un planteamiento matricial de las ecuaciones involucradas. Por último, se prueba en simulación el modelo con y sin cultivo y los resultados se contrastan con mediciones obtenidas en campo para un tipo de suelo de la provincia de San Juan.

3.1 Estado del arte

La representación matemática de un cultivo, sometido a riego, que describa fielmente el sistema físico real fue la base que permitió dar asistencia a los sistemas de toma de decisiones de riego (DSS) (Delgoda et al., 2016a). La formulación está basada en diversos métodos entre los que se encuentran aquellos que emplean soluciones empíricas o semi-empíricas, analíticas o simplificaciones numéricas.

Los modelos de cultivos que consideran limitaciones en la disponibilidad de agua para el crecimiento de la planta tratan los flujos de agua en el suelo y la interacción con la atmósfera fundamentalmente de dos maneras diferentes. La primera estrategia consiste en aproximar al suelo como una sucesión de capas apiladas donde se define una función de flujo. De esta forma, la dinámica del proceso, en cualquier sistema de riego agrícola, puede ser descripta mediante un modelo de balance hídrico (Lozoya et al., 2014). Este modelo, considera un perfil unidimensional y establece que un cambio en el almacenamiento de agua durante un periodo de tiempo en un sitio específico es el resultado de los flujos entrantes y salientes de agua (Allen et al., 2006).

Entonces, la dinámica del balance hidrológico, puede definirse como:

$$\dot{\theta}(t) = I(t) + P(t) + AC(t) - ET_c(t) - R(t) - PP(t) \quad (3.1)$$

donde, $\dot{\theta}(t)$ es la variación del contenido volumétrico de agua; $I(t)$ la irrigación; $P(t)$ la precipitación; $AC(t)$ el ascenso capilar; $ET_c(t)$ la evapotranspiración de cultivo; $R(t)$ la escorrentía y $PP(t)$ la percolación profunda.

Este enfoque es implementado por los modelos de cultivos STICS (Brisson et al., 1998), SUCROS (Spitters et al., 1989), y especialmente el CERES (Basso et al., 2016; Jones et al., 1986) y su sucesor el DSSAT (Hoogenboom et al., 2019). El Sistema de Apoyo a las Decisiones para la Transferencia de Agrotecnología (DSSAT) es un programa de aplicación informática que comprende modelos de simulación de cultivos para más de 42 cultivos (a partir de la versión 4.8.2). Los modelos de simulación de cultivos simulan el crecimiento, el desarrollo y el rendimiento en función de la dinámica suelo-planta-atmósfera. Estos, requieren datos meteorológicos diarios, información sobre la superficie y el perfil del suelo y una gestión detallada de los cultivos. Otros ejemplos de uso de (3.1), pero aplicados a un lazo cerrado de control se encuentran en (Lozoya et al., 2016b; Sahbani & Ferjani, 2018).

La segunda estrategia, consiste en emplear la ecuación de Richards, 1931 para describir los flujos de agua en suelos no saturados. Esta ecuación, puede ser resuelta en forma analítica y ser aplicada para el caso de riego por goteo, según se desprende de (Philip, 1984; Raats, 1971; Revol et al.,

1997; Warrick, 1974). La resolución requiere asumir ciertas hipótesis como la forma de la fuente, de las funciones hidráulicas del suelo o, en algunos casos, las condiciones de estado estacionario (Arbat et al., 2013). Si se realiza una comparativa, estos métodos son preferibles respecto de las soluciones numéricas debido a su rapidez (Cook et al., 2006; Cook et al., 2003). Sin embargo, la capacidad de computo actual es lo suficientemente alta como para que esto no sea un impedimento para escoger entre una u otra opción.

Además, los métodos numéricos permiten dar tratamiento al dominio del flujo, las condiciones de contorno y las propiedades del suelo de una manera mas realista (Warrick, 2003). En las últimas décadas, se han publicado numerosos artículos en tal sentido que analizan el flujo de agua en un suelo bajo riego por goteo (Annandale et al., 2003; Armstrong & Wilson, 1983; Brandt et al., 1971; Ghali, 1986; Lafolie et al., 1989; Ramirez de Cartagena Bisbe & Sáinz Sánchez, 1997; Taghavi et al., 1984; Van der Ploeg & Benecke, 1974) y, más recientemente, los modelos *HYDRUS-2D/3D* (Simunek et al., 2006) y *Drip-Irrigator* (Arbat et al., 2013).

Según el modo de resolución numérica de la ecuación de *Richards*, se pueden distinguir entre modelos basados en métodos de diferencias finitas, elementos finitos y elementos finitos de contorno. Este último método, ha resultado de mayor utilidad para el estudio del riego sub-superficial y análisis del efecto de la forma de la fuente sobre el bulbo (Vigo García, 2020).

Los modelos basados en diferencias finitas fueron los primeros en ser implementados en este campo por su sencillez conceptual. Esto, debido a que el espacio de resolución de las ecuaciones es el mismo que el espacio físico del medio poroso. Por su parte, los modelos basados en métodos de elementos finitos resuelven las ecuaciones en un espacio matemático distinto al espacio físico-euclídeo, es decir, el espacio de Banach, también conocido como el espacio de las soluciones. Para el primer caso, un modelo representativo es el modelo *Drip-Irrigator* (Arbat et al., 2013) y, para el segundo, el modelo de Simunek et al., 2006 el más representativo de este grupo, ya que se comercializa como un software conocido como *HYDRUS-2D/3D*.

Los modelos basados en técnicas de resolución por elementos finitos

son posteriores a los modelos de diferencias finitas y más complejos de desarrollar. Si el fenómeno de estudio es particularmente simple, el esfuerzo de cálculo para la resolución de algoritmos complejos en el espacio de las soluciones no está justificado. Sin embargo, cuando el sistema está condicionado por fenómenos que afectan a la dinámica del flujo como son la difusión y convección del calor, evaporación o procesos de osmosis, aparece un acoplamiento entre la ecuación de *Richards* y otras ecuaciones diferenciales involucradas como son la ecuación de calor y las ecuaciones de transporte osmótico. En estos casos, los modelos de elementos finitos resultan ser más eficientes, ya que la solución de estas ecuaciones acopladas suele tener menor costo computacional dentro del espacio de Banach (Vigo García, 2020).

Los modelos de caja negra, también fueron utilizados para representar suelos cultivados sometidos a riego. Elnesr y Alazba, 2017, desarrollaron un modelo de predicción con una red neuronal artificial basado en los datos del modelo *Hydrus-2D/3D*. La rejilla de datos de simulación de este software fueron convertidos en elipses de humedad de vectores de 3 variables más simples. Asimismo, en otro estudio se utilizaron métodos de redes neuronales artificiales (RNA) y de regresión no lineal (RNL) para desarrollar ecuaciones para la estimación de las áreas mojadas hacia arriba y hacia abajo alrededor de la posición de instalación del gotero (Karimi et al., 2020). En otro trabajo, Adeyemi et al., 2018 presentaron un enfoque de red neuronal dinámica para modelar los flujos temporales de humedad del suelo y generar una predicción con un día de antelación. Las predicciones se hacen en función de la humedad del suelo, la precipitación y las mediciones climáticas pasadas. Por último, Capraro et al., 2008 modelaron los cambios en los niveles de humedad en el área de las raíces como una función diferencial no lineal para ser identificado por una RNA. Dicho modelo dinámico, fue dependiente de la cantidad de agua suministrada, el consumo del cultivo y las características del suelo.

En lo referido a trabajos que particularizan en el cultivo, a continuación, se detallan algunos de ellos. MAESTRO (Medlyn et al., 2004; Wang & Jarvis, 1990) es un modelo espacialmente explícito que integra parámetros fisiológicos, morfológicos, de emplazamiento (espaciado entre plantas, pendiente, aspecto, etc.) y aerodinámicos del dosel. MAESTRO se desarrolló para predecir la absorción de radiación, la fotosíntesis y la transpiración

por las copas individuales de los árboles en un rodal y por el rodal en su conjunto. Raes et al., 2012, presentan un modelo de cultivos de la FAO, *AquaCrop*. Este, simula los rendimientos alcanzables de los principales cultivos herbáceos en función del consumo de agua en condiciones de secano, riego suplementario, deficitario y pleno riego.

En esta misma línea, otros autores se centran en el papel de la vegetación subterránea y la importancia de la estructura de la zona radicular en los efectos sobre la superficie terrestre (Feddes et al., 2001). La extracción de agua de las raíces es un proceso clave en el ciclo hidrológico porque controla en gran medida la división de la lluvia que se infiltra en evaporación, transpiración y lixiviación (Li et al., 2006).

Los modelos hidrológicos, de ecosistemas, de superficie terrestre y de cultivos requieren una descripción cuantitativa de la absorción de agua por las raíces de las plantas (Feddes & Raats, 2004). Se han desarrollado dos enfoques, uno microscópico y otro macroscópico, para simular la absorción de agua por las raíces de las plantas. El enfoque microscópico simula el movimiento del agua hacia raíces individuales (Doussan et al., 1998; Nobel & Alm, 1993; Pagès et al., 1989; Personne et al., 2003; Steudle, 1994). Este enfoque tiene una base física, pero la dinámica y la geometría detallada del sistema radicular son difíciles de medir (Vrugt et al., 2001). En contraste, el enfoque macroscópico trata el sistema radicular como un objeto abstracto cuya distribución vertical se describe a lo largo del perfil del suelo.

En general, la extracción macroscópica de agua está representada por un término de sumidero dependiente de la profundidad, que puede incorporarse a la ecuación de *Richards* de flujo de agua del suelo. Si bien, este enfoque no brinda una visión completa de los procesos físicos de absorción de agua por las raíces, solo necesita los parámetros del suelo y de la planta que están fácilmente disponibles. En consecuencia, el uso de módulos macroscópicos de absorción de agua por las raíces generalmente se prefiere en muchos modelos hidrológicos orientados a aplicaciones (Li et al., 2006).

Un estudio realizado por Feddes et al., 2001, propuso un esquema macroscópico de absorción de agua por las raíces en el que la transpiración potencial se distribuye en la zona radicular y, luego, se reduce la absorción

real mediante una función de reducción del estrés hídrico del suelo. A partir de esta conceptualización, se han desarrollado numerosos módulos de absorción de agua por las raíces. Aunque estos módulos difieren en la forma en que se distribuye la transpiración potencial y/o se reduce la transpiración potencial por el estrés hídrico, todos tienen el mismo inconveniente de que se requieren parámetros empíricos para ejecutar estos módulos (Li et al., 2006).

La distribución de la transpiración potencial se ha basado en la distribución de las raíces únicamente (Feddes et al., 2001; Li et al., 1999; van Dam et al., 1997) o tanto en la distribución de las raíces como en la disponibilidad de agua en el suelo (Li et al., 2001). Se han utilizado diversas funciones de distribución de las raíces, ya sean lineales (Hayhoe & De Jong, 1988; Hoogland et al., 1981; Prasad, 1988) o no lineales (Jarvis, 1989; Raats, 1974; Tiktak & Bouten, 1992; Vrugt et al., 2001) en la conceptualización de la absorción de agua por las raíces.

Las funciones lineales, que requieren una mínima cantidad de datos (por ejemplo, la profundidad de enraizamiento) son menos precisas que las funciones no lineales, que requieren al menos un parámetro empírico, obtenida mediante el ajuste con los datos de distribución medidos de la raíz. La mayoría de las funciones de distribución radicular se derivan de mediciones locales, basadas normalmente en un número limitado de cultivos o tipos de vegetación. En consecuencia, estos módulos tienen una utilidad limitada a escala regional y mundial, donde se requiere una función de distribución de raíces para varios biomas y cultivos.

En cuanto a las funciones de reducción por estrés hídrico, la comunidad de modelización agua-suelo-cultivo, habitualmente, utiliza tres alternativas propuestas respectivamente por Feddes et al., 2001; Tiktak y Bouten, 1992; Van Genuchten, 1980. Las tres funciones, contienen parámetros de punto de reducción determinados empíricamente y, por lo tanto, requieren calibración y validación si no se encuentran valores apropiados en la bibliografía. En el caso de las simulaciones a escala regional y mundial, la calibración y validación de estos parámetros no sólo requiere mucho tiempo, dada la gran variabilidad espacial del suelo y la vegetación, sino que a menudo resulta imposible en algunas zonas debido a la falta de disponibilidad de datos medidos.

3.2 Formulación matricial

Dado el marco teórico realizado en la Sección 2.1.1, en la Sección 2.1.2 y la revisión bibliográfica de la sección anterior, se describe a continuación un modelo combinado del movimiento de agua en el suelo y la extracción de la misma por parte de un cultivo.

Debido a que en esta tesis, se considera un flujo de agua bajo un único gotero superficial y, que los efectos térmicos y osmóticos no serán objetos de estudio, se ha decidido emplear un modelo que resuelve la ecuación de *Richards* mediante el método de las diferencias finitas, según lo detallado en la Sección 2.1.1.

A su vez, para tener en cuenta la absorción de agua por la raíz, se emplea un enfoque macroscópico añadiendo un término de sumidero en la ecuación de *Richards*, según se describe en la Sección 2.1.2. Asimismo, se emplea la función de reducción por estrés hídrico enunciada por Feddes et al., (2001).

Partiendo de (2.2) y (2.8), los caudales que fluyen dentro del mallado se pueden expresar matricialmente según se verá en lo que sigue.

3.2.1 Flujo de entrada

El caudal de entrada al sistema (Q_{got}), es decir, aquel aplicado mediante riego, ingresa por las celdas saturadas de la primera fila. Por tanto, se define la matriz $B \in \{0, 1\}^{i_m \times j_m}$ que asigna un valor nulo a las celdas fuera de la región de ingreso de agua; con i_m y j_m el número máximo de celdas en las direcciones vertical y horizontal, respectivamente:

$$B = \begin{pmatrix} b_{11} & b_{12} & \cdots & b_{1j_m} \\ 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & \cdots & 0 \end{pmatrix} \quad (3.2)$$

donde, los elementos b_{1j} toman un valor unitario o nulo, según el número

de celdas saturadas (p), con $1 \leq p \leq j_m$:

$$b_{1j} = \begin{cases} 1 & 1 \leq j \leq p \\ 0 & p > j \end{cases} \quad (3.3)$$

Entonces, el caudal de entrada al sistema, se puede expresar matricialmente como:

$$Q_e = B \left(\frac{Q_{got}}{p} \right) V = Q_{in} V \quad (3.4)$$

siendo, $V \in \{0, 1\}$ el estado de la válvula; $Q_{in} = B(Q_{got}/p)$, con $Q_{in}, Q_e \in \mathbb{R}^{i_m \times j_m}$, denotando el ingreso superior de un flujo de caudal de agua a las celdas saturadas de la primera fila.

3.2.2 Flujo interno

El flujo del caudal interno, se expresa redefiniendo las ecuaciones (2.9), (2.10), (2.12) y (2.11). De esta manera, en forma matricial:

$$Q_{j-1} = \left(\frac{K_{j-1} + K}{2} \right) \left(\frac{\Psi_h - \Psi_{hj-1}}{\Delta_j} \right) (2\pi R_j \Delta_i) \quad (3.5)$$

$$Q_{j+1} = \left(\frac{K_{j+1} + K}{2} \right) \left(\frac{\Psi_h - \Psi_{hj+1}}{\Delta_j} \right) (2\pi R_{j+1} \Delta_i) \quad (3.6)$$

$$Q_{i-1} = \left(\frac{K_{i-1} + K}{2} \right) \left(\frac{\Psi_h - \Psi_{hi-1}}{\Delta_i} \right) \pi (R_{j+1}^2 - R_j^2) \quad (3.7)$$

$$Q_{i+1} = \left(\frac{K_{i+1} + K}{2} \right) \left(\frac{\Psi_h - \Psi_{hi+1}}{\Delta_i} \right) \pi (R_{j+1}^2 - R_j^2) \quad (3.8)$$

donde, $Q_{j-1}, Q_{j+1}, Q_{i+1}, Q_{i-1} \in \mathbb{R}^{i_m \times j_m}$; R_j y $R_{j+1} \in \mathbb{R}^{i_m \times j_m}$ contienen los valores del radio interior y exterior de los anillos concéntricos, respectivamente; la conductividad hidráulica se toma como la media aritmética entre los valores de conductividad de la matriz genérica $K \in \mathbb{R}^{i_m \times j_m}$ y sus equivalentes desplazadas K_{j-1} , K_{j+1} , K_{i+1} o $K_{i-1} \in \mathbb{R}^{i_m \times j_m}$; se define la matriz de potencial hidráulico $\Psi_h \in \mathbb{R}^{i_m \times j_m}$ y sus equivalentes desplazadas Ψ_{hj-1} , Ψ_{hj+1} , Ψ_{hi-1} , $\Psi_{hi+1} \in \mathbb{R}^{i_m \times j_m}$. A continuación, se especifican los elementos de dichas matrices desplazadas, ya sea, en la dirección horizontal o vertical:

$$K_{j-1} = \begin{pmatrix} k_{11} & k_{11} & k_{12} & \cdots & k_{1j_m-1} \\ k_{21} & k_{21} & k_{22} & \cdots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ k_{i_m 1} & k_{i_m 1} & k_{i_m 2} & \cdots & k_{i_m j_m-1} \end{pmatrix} \quad (3.9)$$

$$K_{j+1} = \begin{pmatrix} k_{12} & k_{13} & \cdots & k_{1j_m} & k_{1j_m} \\ k_{22} & k_{23} & \cdots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ k_{i_m 2} & k_{i_m 3} & \cdots & k_{i_m j_m} & k_{i_m j_m} \end{pmatrix} \quad (3.10)$$

$$K_{i-1} = \begin{pmatrix} k_{11} & k_{12} & \cdots & k_{1j_m} \\ k_{11} & k_{12} & \vdots & k_{1j_m} \\ k_{21} & k_{22} & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ k_{(i_m-1)1} & k_{(i_m-1)2} & \cdots & k_{(i_m-1)j_m} \end{pmatrix} \quad (3.11)$$

$$K_{i+1} = \begin{pmatrix} k_{21} & k_{22} & \cdots & k_{2j_m} \\ k_{31} & k_{32} & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ k_{i_m 1} & k_{i_m 2} & \cdots & k_{i_m j_m} \\ k_{i_m 1} & k_{i_m 2} & \cdots & k_{i_m j_m} \end{pmatrix} \quad (3.12)$$

$$\Psi_{j-1} = \begin{pmatrix} \psi_{11} & \psi_{11} & \psi_{12} & \cdots & \psi_{1j_m-1} \\ \psi_{21} & \psi_{21} & \psi_{22} & \cdots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \psi_{i_m 1} & \psi_{i_m 1} & \psi_{i_m 2} & \cdots & \psi_{i_m j_m-1} \end{pmatrix} \quad (3.13)$$

$$\Psi_{j+1} = \begin{pmatrix} \psi_{12} & \psi_{13} & \cdots & \psi_{1j_m} & \psi_{1j_m} \\ k_{22} & k_{23} & \cdots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \psi_{i_m 2} & \psi_{i_m 3} & \cdots & \psi_{i_m j_m} & \psi_{i_m j_m} \end{pmatrix} \quad (3.14)$$

$$\Psi_{i-1} = \begin{pmatrix} \psi_{11} & \psi_{12} & \cdots & \psi_{1j_m} \\ \psi_{11} & \psi_{12} & \vdots & \psi_{1j_m} \\ \psi_{21} & \psi_{22} & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \psi_{(i_m-1)1} & \psi_{(i_m-1)2} & \cdots & \psi_{(i_m-1)j_m} \end{pmatrix} \quad (3.15)$$

$$\Psi_{i+1} = \begin{pmatrix} \psi_{21} & \psi_{22} & \cdots & \psi_{2j_m} \\ \psi_{31} & \psi_{32} & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \psi_{i_m 1} & \psi_{i_m 2} & \cdots & \psi_{i_m j_m} \\ \psi_{i_m 1} & \psi_{i_m 2} & \cdots & \psi_{i_m j_m} \end{pmatrix} \quad (3.16)$$

En las zonas que se encuentran en los bordes no existe flujo de agua con el exterior, excepto en las celdas saturadas de las regiones superior. A fin, de determinar la interacción de los laterales con el exterior se utilizaron nodos ficticios ubicados fuera del dominio de estudio. De esta manera, la impermeabilidad se resolvió replicando las filas o columnas laterales de las matrices, como se desprende de (3.9), (3.10), (3.11), (3.12), (3.13), (3.14), (3.15), (3.16).

Luego, haciendo un balance de caudales, resulta:

$$Q_n = Q_{j-1} + Q_{j+1} + Q_{i-1} + Q_{i+1} \quad (3.17)$$

donde, $Q_n \in \mathbb{R}^{i_m \times j_m}$ contiene el caudal neto de cada elemento del mallado.

Ahora, a partir (3.4) y (3.17), puede calcularse la variación del contenido volumétrico de agua de los anillos genéricos que forman el cilindro:

$$\dot{\Theta} = \frac{Q_e + Q_n}{V_o} = \frac{Q_{in}V + Q_n}{\pi(R_{j+1}^2 - R_j^2)\Delta_i} \quad (3.18)$$

denotando, $\Theta, V_o \in \mathbb{R}^{i_m \times j_m}$.

3.2.3 Término sumidero

Finalmente, incluyendo el término de extracción en (3.18), la variación del contenido volumétrico de agua queda expresada en forma matricial, según:

$$\dot{\Theta} = \frac{Q_{in}V + Q_n}{V_o} - S' \quad (3.19)$$

donde, $S' \in \mathbb{R}^{i_m \times j_m}$ es la matriz de extracción de agua por la planta; siendo $S' = \Gamma S'_m$ con $\Gamma, S'_m \in \mathbb{R}^{i_m \times j_m}$.

Cabe señalar que, para la obtención de cada elemento γ_{ij} se empleo la función de respuesta al estrés presentada en la Figura 2.4, a diferencia de la que empleo Vrugt et al., 2001. Entonces, la matriz de respuesta al estrés hídrico, queda definida como:

$$\Gamma = \begin{pmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} & \cdots & \gamma_{1j_m} \\ \gamma_{21} & \gamma_{22} & \gamma_{23} & \cdots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \gamma_{i_m 1} & \gamma_{i_m 2} & \gamma_{i_m 3} & \cdots & \gamma_{i_m j_m} \end{pmatrix} \quad (3.20)$$

$$\gamma_{ij} = \begin{cases} 0 & \psi_{h_{ij}} > \psi_{h_4} \\ (\psi_{h_4} - \psi_{h_{ij}})/(\psi_{h_4} - \psi_{h_3}) & \psi_{h_3} \leq \psi_{h_{ij}} \leq \psi_{h_4} \\ 1 & \psi_{h_2} < \psi_{h_{ij}} < \psi_{h_3} \\ (\psi_{h_{ij}} - \psi_{h_1})/(\psi_{h_2} - \psi_{h_1}) & \psi_{h_1} < \psi_{h_{ij}} \leq \psi_{h_2} \\ 0 & \psi_{ij} \leq \psi_{h_1} \end{cases} \quad (3.21)$$

El factor de reducción de la absorción de agua por la raíz es una función lineal por partes que varía entre 0 y 1. Se describen cinco fases de absorción de agua, delimitadas por cuatro valores de la altura de presión ($\psi_{h_1} > \psi_{h_2} > \psi_{h_3} > \psi_{h_4}$). El valor de ψ_{h_1} delimita la fase de deficiencia completa de aireación y de absorción nula en un suelo casi saturado (fase anóxica). Entre ψ_{h_1} y ψ_{h_2} , la fase hipóxica, la absorción aumenta linealmente a medida que aumenta la porosidad llena de aire. En el rango entre ψ_{h_2} y ψ_{h_3} (fase de tasa constante), no hay estrés hídrico ni estrés por aireación y la absorción es igual a la absorción potencial. Entre ψ_{h_3} y ψ_{h_4} (fase de tasa decreciente), la absorción disminuye linealmente hasta cero. Por debajo de ψ_{h_4} , que delimita la fase de marchitamiento permanente, la absorción es igual a cero.

Ahora, reordenando (3.19), resulta la expresión de un modelo no lineal afín SISO del sistema agua-suelo-clima-cultivo en forma matricial:

$$\dot{\Theta} = \left[\frac{Q_n(\theta)}{V_o} - S'(\psi_h(\theta)) \right] + \frac{Q_{in}}{V_o} V \quad (3.22)$$

La Tabla 3.4, indica los parámetros y variables del modelo con sus respectivas descripciones y unidades.

3.3 Simulaciones

En lo que sigue, se verifican en simulación los modelos del sistema agua-suelo y clima-cultivo para un periodo de riego. En primer lugar, se ejecuta el caso de un suelo desnudo sometido a riego y, luego, considerando la integración de ambos modelos, es decir, en presencia de un cultivar. Los resultados obtenidos se contrastan con mediciones realizadas en campo ante eventos idénticos de aplicación de agua.

Para la experimentación se tuvo en cuenta un tipo de suelo existente en la provincia de San Juan, más precisamente en las instalaciones del Instituto Nacional de Tecnología Agropecuaria (INTA). En la Tabla 4.11, 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).

Tabla 3.1: Propiedades del suelo

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

Los valores porcentuales de arena, limo y arcilla, y la densidad aparente del suelo se introducen en el programa *Rosetta* para determinar los parámetros del modelo. *Rosetta* implementa las funciones de pedotransferencia que predicen los parámetros de retención de agua de Van Genuchten y la conductividad hidráulica saturada (Schaap et al., 2001). A partir de los valores obtenidos, por ensayo y error, se ajustaron para obtener una mejor estimación.

En la Tabla 3.2, se detallan los parámetros mencionados, siendo: el contenido de agua residual y en saturación (θ_r y θ_s , respectivamente), la conductividad hidráulica en saturación K_s y los restantes son valores de ajuste correlacionados con la textura del suelo.

Tabla 3.2: Parámetros del modelo de suelo

	$\theta_r (cm^3 \cdot cm^{-3})$	$\theta_s (cm^3 \cdot cm^{-3})$	$\alpha (cm^{-3})$	n (-)	$K_s (cm/day)$
Rosetta	0.0845	0.4683	0.012	1.4550	18.95

Los valores de los parámetros correspondientes al modelo de extracción se obtuvieron aplicando el método de mínimos cuadrados, para un conjunto de mediciones obtenidas en campo. Teniendo en cuenta que, los valores de enraizamiento máximo en las direcciones radial y de profundidad son conocidos, en la Tabla 3.3 se presentan los resultados del ajuste mediante el algoritmo *trust-region-reflective*.

Tabla 3.3: Parámetros del modelo de extracción

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

Las dimensiones de la matriz de celdas (Figura 2.2), se escoge de 20×20 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 considera una cinta de riego cuyos goteros otorgan un caudal fijo de $4l/h$,

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 θ_r y se riega hasta obtener uno que se considere adecuado. El tiempo entre instantes de aplicación de riego del modelo de suelo se escogió $\Delta_t = 10s$.

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 30cm de profundidad con sensores de humedad de tipo capacitivos (Capraro et al., 2011).

En la Figura 3.1, se presentan las mediciones de ET_o obtenidas para el periodo que será considerado en los experimentos tanto en este capítulo como en los subsiguientes.

3.3.1 Resultados

Para evaluar la similitud entre los modelos y las mediciones realizadas en el terreno, se aplicó la misma secuencia de riego a ambos, analizando las respuestas correspondientes en cada caso.

En la Figura 3.2, se observan las mediciones del contenido volumétrico de agua en la profundidad considerada ante eventos de riego aleatorios, para el caso sin cultivo.

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 se corresponden con los inicios del riego) donde en la mayoría de los casos se sobreestima los valores reales. El modelo reparametrizado reproduce con una fidelidad más que aceptable a los valores reales.




Figura 3.1: Evapotranspiración de referencia.




Figura 3.2: Mediciones en campo y en simulación del contenido volumétrico de agua porcentual ante una misma secuencia de riego.

Luego, en la Figura 3.3 se muestran las mediciones del contenido de agua pero incorporando las ecuaciones de absorción de agua por parte de un cultivo. En este caso, los eventos de riego aplicados en campo y al modelo fueron para mantener los valores de humedad volumétrica alrededor de una referencia mediante un control a lazo abierto.




Figura 3.3: Mediciones en campo y en simulación del contenido volumétrico de agua porcentual ante una misma secuencia de riego.

Se observa, en ambos casos, un seguimiento de la referencia establecida para el control de lazo abierto. El modelo muestra una respuesta más suave que las mediciones reales ante una aplicación de riego pero, también, se observa la influencia de la dinámica de absorción de agua introducida por el término de sumidero.

En este sentido, en la Figura 3.4, se toma una ventana de tiempo del contenido volumétrico de agua de la secuencia de riego visualizada en la Figura 3.3. En la misma, también se presenta el resultado de simular el modelo del movimiento de agua en el suelo pero, sin incluir las ecuaciones de extracción de agua, a modo de visualizar los efectos de incorporar dichas ecuaciones. Se observa la mejora del ajuste del modelo para aproximar los datos reales al incorporar el término de extracción.

La Figura 3.5, presenta el error en términos absolutos. Del análisis de la gráfica, se desprende que los errores máximos de aproximación se dan en los momentos de riego, debido a un retardo en la respuesta del modelo a




Figura 3.4: Extracto de la secuencia de riego considerando un suelo cultivado, incorporando respuesta sin modelo de extracción.

estos eventos.

Por último, en la Figura 3.6 se muestra la evolución del bulbo húmedo generado bajo la superficie de un suelo cultivado sometido a riego localizado. De esta manera, se puede visualizar la forma y el valor del contenido de agua en el suelo en todo momento del periodo de riego. Esta monitorización permite observar que el perfil de humedad no sobrepase ciertos límites y se mantenga dentro de ciertos valores requeridos. En este caso, la simulación se corrió durante 24 días hasta obtener la imagen de la esquina inferior derecha.

3.4 Conclusiones

Se logró integrar un modelo de distribución de agua en el suelo y un modelo de extracción de agua por parte de las raíces de un cultivo. Se verificaron las simulaciones del modelo conjunto reparametrizado ante mediciones obtenidas en campo para un tipo de suelo y cultivo existente




Figura 3.5: Error absoluto de la respuesta de simulación del modelo.

Tabla 3.4: Parámetros y variables del modelo

Simbolo	Descripción	Unidad
θ	Contenido volumétrico de agua	
θ_s	Contenido de agua en saturación	$cm^3 \cdot cm^{-3}$
θ_r	Contenido de agua residual	
ψ_h	Potencial hidráulico	cm
K	Conductividad hidráulica	
K_s	Conductividad hidráulica en saturación	$cm \cdot s^{-1}$
α		cm^{-3}
n	Parámetros de ajuste característicos	-
m		
Q_i	Caudal entrante	$cm^3 \cdot s^{-1}$
Q_n	Caudal neto	
V	Estado de la válvula	-
R_j	Radio del anillo	
Δ_i	Altura del anillo	cm
Δ_j	Ancho del anillo	
V_o	Volumen del anillo	cm^3
ET_0	Evapotranspiración de referencia	
ET_c	Evapotranspiración de cultivo	$cm \cdot s^{-1}$
T_{pot}	Tasa de transpiración potencial	
E_s	Evaporación del suelo	
K_c	Coeeficiente de cultivo	
$\beta(z)$	Distribución espacial vertical de la raíz	-
$\beta(x)$	Distribución espacial horizontal de la raíz	
$\gamma(\psi_h, x, z)$	Coeeficiente de reducción por las raíces	
z_m	Profundidad máxima de enraizamiento	
x_m	Enraizamiento máximo en dirección radial	cm
R	Dominio de flujo en dirección radial	
p_z		-
p_x	Parámetros empíricos	
z^*		cm
p^*		
S	Extracción de agua por las raíces	s^{-1}
S_m	Distribución normalizada	




Figura 3.6: Evolución del bulbo húmedo generado bajo la superficie irrigada.

en la provincia de San Juan.

El modelo matemático obtenido sirve de base para la monitorización del bulbo húmedo generado bajo la superficie del suelo. Además, permite simular las aplicaciones de riego proporcionadas por los controladores de riego propuestos en esta tesis doctoral.

SISTEMA DE DECISIÓN DE RIEGO

4.1	Sistema de decisión de riego	55
4.1.1	Estado del arte	55
4.1.2	Generalidades	62
4.2	Control PI neuro-adaptable por superficies deslizantes .	63
4.2.1	Diseño del controlador	63
4.2.2	Resultados	73
4.2.3	Conclusiones	75
4.3	Control PI con compensación	76
4.3.1	Diseño del controlador	77
4.3.2	Resultados	88
4.3.3	Conclusiones	93
4.4	Control MPC	94
4.4.1	Diseño del controlador	94
4.4.2	Resultados	99
4.4.3	Conclusiones	101

4.1 Sistema de decisión de riego

4.1.1 Estado del arte

Un sistema de apoyo a la toma de decisiones (DSS), para la gestión y la programación del riego, proporciona un marco para incorporar diversas herramientas y técnicas para las decisiones de riego sitio-específicas. La adopción comercial generalizada del *riego de precisión* dependerá del desarrollo de DSS robustos y óptimos (Smith & Baillie, 2009).

Un amplio número de DSS programan el riego a intervalos y volúmenes predefinidos. Estos, no incorporan ninguna forma de retroalimentación de los sensores, ya sea, sobre el estado hídrico de las plantas, el estado hídrico del suelo y las variables climáticas (Lozoya et al., 2014). Esta estrategia de "lazo abierto" se diseña en gran medida basándose en la heurística y en datos históricos. Además, se sugiere que se trata de un enfoque ineficaz que a menudo conduce a un riego excesivo y al desperdicio de fertilizantes y otros insumos suplementarios para los cultivos (Mareels et al., 2005).

Las estrategias de riego en lazo cerrado tienen como objetivo regar: i) cuando el contenido de humedad del suelo alcanza un determinado umbral (Dabach et al., 2013; Liu et al., 2012; Vellidis et al., 2008); ii) cuando los sensores de la planta indican un determinado umbral de estrés (Erdem et al., 2010; Erdem et al., 2005; O'Shaughnessy et al., 2012); iii) con la retroalimentación de modelos de simulación de cultivos, con el fin de alcanzar un determinado rendimiento, respuesta fisiológica del cultivo u objetivo económico (McCarthy et al., 2014).

Se ha demostrado que estas estrategias de riego en lazo cerrado mejoran la eficiencia del uso del agua en la producción de cultivos hortícolas en entornos protegidos (Bennis et al., 2008). A este respecto, Belayneh et al., 2013 implementaron una red de sensores inalámbricos de humedad del suelo para el control del riego en lazo cerrado en un vivero de macetas. El sistema consiguió una reducción significativa del consumo de agua con un periodo de amortización de 2,7 años. En otro trabajo, Chappell et al., 2013 también informaron un ahorro de agua, en este caso, del 83 % para un sistema de control de riego de circuito cerrado implementado en un sistema de producción de cultivos protegidos. Los autores, observaron que había menos enfermedades de las plantas en el vivero debido a la eliminación del exceso de riego. Por último, Saavoss et al., 2016 reportaron un incremento del 65 % en los beneficios debido a la implantación de un sistema de control de lazo cerrado basado en una red de sensores inalámbricos en un vivero. Allí, se señaló que el aumento de los beneficios se debía a la mejora de la calidad y el rendimiento de los cultivos como resultado del control preciso en las aplicaciones de riego.

Por otra parte, en la producción de cultivos a escala de campo, las necesidades de los cultivos varían en el tiempo y el espacio debido a factores bióticos y abióticos (Al-Karadsheh et al., 2002). Esto, trae como conse-

cuencia que en estos sistemas de producción de cultivos, las estrategias de lazo cerrado sean incapaces de dar cuenta de la dinámica desconocida de los cultivos, la naturaleza estocástica de las variables climáticas y la respuesta de los cultivos, y la naturaleza variable en el tiempo del sistema agua-suelo-planta-atmósfera. Esto último se debe especialmente al crecimiento de los cultivos, su gestión y la infestación de plagas y enfermedades (McCarthy et al., 2013). Por otro lado, tampoco pueden tener en cuenta el equipo y otras limitaciones operativas (Adeyemi et al., 2017).

McCarthy et al., 2010 concluyeron que un sistema óptimo de apoyo a la toma de decisiones debe ser “adaptativo”, con capacidad para acomodarse a la variabilidad temporal y espacial dentro del campo. El DSS, también debe tener la capacidad de modificar las decisiones de riego en respuesta a la fisiología del cultivo, las incertidumbres en los aportes climáticos, el suelo, los sistemas de riego y las limitaciones del suministro de agua, las consideraciones económicas y la calidad de la retroalimentación de los sensores.

Un DSS adaptativo es capaz de reajustar continuamente el algoritmo de programación del riego para mantener el rendimiento deseado del sistema (McCarthy et al., 2010). El DSS puede utilizar datos históricos o de sensores en tiempo real para establecer el momento y volumen de riego que tenga en cuenta adecuadamente la variabilidad temporal y espacial en el campo (McCarthy et al., 2010). En la teoría del control, un sistema de control adaptativo es capaz de ajustar sus parámetros basándose en la retroalimentación de los sensores de un proceso, de forma que el proceso controlado se comporte de una manera deseable (Smith et al., 2010). Un DSS para el riego puede estar *basado en sensores*, si utilizan mediciones directas de sensores para la estrategia de riego, o *basado en modelos*, si utilizan un modelo de simulación calibrado para ayudar en las decisiones de riego (McCarthy et al., 2014).

Diversos sistemas de riego propuestos se basan en modelos físicos, incorporando la representación fisiológica y morfológica de la planta en la herramienta de decisión (Delgoda et al., 2016b). Barnard y Bauerle, 2015 describieron un sistema de programación del riego basado en el modelo biofísico espacialmente explícito, MAESTRA (Multi-Array Evaporation Stand Tree Radiation A). Se informó que la herramienta aplicaba entre un 18 % y un 56 % más de agua que un método basado en sensores para

programar el riego en cuatro especies. Sin embargo, los autores señalaron que el enfoque basado en modelos produjo un mayor crecimiento de los árboles. En otro trabajo, se describió un modelo mecanicista capaz de inferir las necesidades hídricas de los cultivos. El modelo emplea datos de temperatura de la hoja como entrada para determinar las características aerodinámicas del cultivo, que luego se utilizan en la ecuación de Penman-Monteith para calcular la ET_0 real del cultivo (Ben Asher et al., 2013).

La inteligencia artificial se ha implementado como DSS de riego adaptativo en la forma de redes neuronales artificiales, lógica difusa y sistemas expertos (Jones et al., 2003; M.K et al., 2012).

Capraro et al., 2008 reentrenaron una RNA para obtener un modelo mejorado de la humedad de los suelos, dando al sistema de riego la capacidad de adaptarse a las características cambiantes del suelo y a las necesidades hídricas del cultivo. Karasekreter et al., 2013 utilizaron una RNA para determinar los niveles de riego adecuados y los intervalos de tiempo en un huerto de fresas, consiguiendo un 20,46 % de ahorro de agua y un 23,9 % de ahorro de energía.

Lyu et al., 2022 diseñaron un sistema de control de riego por goteo, basado en tecnología inalámbrica remota LoRa, y una red neuronal dinámica. El modelo entrenado utiliza mediciones pasadas de humedad del suelo, precipitaciones y clima para predecir el contenido de humedad de los suelos de los viñedos en función de un tiempo preestablecido, calculando así la cantidad de riego y determinando el momento de riego.

Asimismo, un enfoque de RN dinámica se presenta en (Adeyemi et al., 2018) para modelar los flujos temporales de humedad del suelo y generar una predicción con un día de antelación. Dichas predicciones se realizaron en función de la humedad del suelo, la precipitación y las mediciones climáticas pasadas. Los resultados se demostraron en simulación en el programa AQUACROP para una temporada de cultivo de papa con ahorros entre el 20 % y 46 % del consumo de agua.

Glória et al., 2021 estudiaron algoritmos de Machine Learning para predecir el mejor momento del día para la administración de agua al cultivo. La solución propuesta fue eficaz y logró hasta un 60 % de ahorro de agua.

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 %.

Thakur et al., 2023 desarrollaron un modelo de decisión utilizando un sistema de inferencia neuro-fuzzy adaptativo (ANFIS) y una RNA para cultivos de brassica. El sistema sensible de riego de cultivos (SCIS) propuesto alcanzó una precisión del 91 % y 99 % para los modelos ANFIS y RNA, respectivamente.

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

Hu y You, 2022 propusieron un sistema de control difuso de riego inteligente basado en un algoritmo PSO mejorado. Los resultados de la simulación mostraron que el algoritmo de control de riego propuesto logró un mejor rendimiento transitorio y precisión de control. Asimismo, Pazouki, 2023 utilizó un algoritmo evolutivo especial para extraer el conocimiento como sistema experto difuso. Los resultados obtenidos en este trabajo muestran que el conocimiento descubierto puede mejorar la productividad en un 30 % y disminuir el agua utilizada en un 30 %.

Goumopoulos et al., 2014 desarrollaron una plataforma DSS adaptativa basada en un sistema experto para el riego sitio específico de plantas de frutilla. El sistema incluye una red inalámbrica de sensores de suelo, clima y planta que proporcionan información al DSS. También, incluye un proceso de aprendizaje automático capaz de inferir nuevas reglas y ampliar la base de conocimientos a partir de conjuntos de datos registrados. El sistema redujo el consumo de agua de riego en torno a un 20 %. En Kohanbash et al., 2013 se describe un sistema experto híbrido basado en datos de humedad del suelo en tiempo real con capacidad para incorporar modelos de plantas.

Analizando los trabajos citados, se observan algunas desventajas del uso de las estrategias empleadas, como se concluye en Adeyemi et al., 2017: por un lado, las RNA requieren grandes conjuntos de datos para su entrenamiento y no pueden describir la dinámica física de un sistema cuando se utilizan para tomar decisiones basadas en la identificación de modelos. Por otro lado, la precisión de los sistemas de lógica difusa depende en gran medida de un conocimiento profundo del sistema. Además, carecen de una estructura mecánica interna y su ámbito de aplicabilidad se limita a la gama de datos de entrenamiento utilizados para configurarlos. Por último, el rendimiento de un sistema experto depende en gran medida de la eficacia del proceso de adquisición de conocimientos. Un error en este proceso afectará a la fiabilidad del sistema y a su rendimiento.

Por otro lado, el control predictivo basado en modelo (MPC), es un enfoque de control industrial empleado en DSS para problemas multivariables a gran escala con múltiples restricciones. Diversos autores Lozoya et al., 2014; Ooi et al., 2008 y Saleem et al., 2013 describieron un marco MPC para la programación del riego basado en un modelo de balance de humedad del suelo. En estos artículos, se identificó un modelo de caja gris del sistema agua-suelo-planta-atmósfera con una red de sensores de humedad del suelo que proporcionan retroalimentación en tiempo real al algoritmo de control. Todos ellos informaron la capacidad de la plataforma MPC para predecir las necesidades de riego de los cultivos y ahorros significativos de agua.

Luego, en (Lozoya et al., 2016b) se emplea un modelo de balance hídrico donde se consideran los flujos de entrada y salida de agua resultando en una suma algebraica de estos términos. El modelo propuesto usa un algoritmo predictivo que censa la humedad del suelo y las variables climáticas para determinar la cantidad óptima de agua requerida por el cultivo. El mismo, resulta en una reducción significativa del consumo del agua. De la misma manera, en (Delgoda et al., 2016b) se observó que una consideración adecuada de la incertidumbre en la lluvia y la evapotranspiración en el modelo de balance de agua empleado en el marco de MPC, mejora la capacidad del sistema para la toma de decisiones de riego.

Los artículos citados que emplean técnicas de control predictivo se basan en modelos de balances que no permiten visualizar el perfil húmedo generado bajo la superficie irrigada. A su vez, estas aplicaciones están

enfocadas en parcelas individuales de riego.

En resumen, el desarrollo de un DSS brinda la oportunidad de mejorar la sostenibilidad del *riego de precisión* mediante la mejora del uso del agua y de la productividad de los cultivos. Estos, también mejorarán las aplicaciones sinérgicas de los datos disponibles de los sensores del suelo, las plantas y el clima para llegar a decisiones óptimas de programación del riego (McCarthy et al., 2014).

Para ello, el sistema de aplicación de agua debe ser capaz de controlar el caudal aplicado a cada unidad de gestión de riego definida dentro de un campo (Pierce, 2010). De este modo, utilizando una metodología de riego de caudal variable (VRI, Monaghan et al., 2013), se puede aumentar la eficiencia y la sostenibilidad del agua utilizada.

El VRI, a veces denominado riego de “precisión” o “sitio específico”, que es la capacidad de un sistema de riego para aplicar diferentes cantidades de agua a distintas zonas del campo en función de las necesidades específicas del lugar, surge como una solución potencial para aumentar la productividad y reducir el impacto medioambiental de la agricultura de regadío (Serrano et al., 2020).

La mayoría de los DSS VRI se han incorporado a sistemas móviles (Evelt et al., 2020; González Perea et al., 2018; Li et al., 2022; Serrano et al., 2020). Los sistemas de riego fijos se han adaptado para la aplicación de agua a caudal variable (Coates & Delwiche, 2008; Linker, 2021). La implementación del VRI en estos sistemas se consigue mediante el control individual de los emisores de agua o de las zonas de gestión (HMZ) (Pierce, 2010). En este sentido, en Ortuani et al., 2019 se reconocieron dos HMZ principales diferentes donde se diseñó un sistema de riego por goteo de caudal variable (VRDI) compuesto por dos sectores (más un "sector de referencia"). La programación preliminar del riego se modificó dinámicamente durante el periodo vegetativo en función de las mediciones de la humedad del suelo. En este caso, la reducción del consumo de agua alcanzó un 18 % menos que si el viñedo se regaba uniformemente como el sector de referencia.

4.1.2 Generalidades

En el capítulo 3, se obtuvo la formulación del movimiento del agua en un suelo cultivado bajo riego localizado. De modo que, a continuación se plantean diferentes estrategias de control cuyas aplicaciones de riego serán ejecutadas en simulación considerando dicho modelo.

Así, en las secciones 4.2 y 4.3 se plantean dos leyes de control adaptables para el DSS cuando las características del terreno varían tanto espacial como temporalmente. En ambas, se propone que la dinámica de irrigación del suelo posea la siguiente estructura:

$$\dot{\theta}(t) = F(\theta) + Gu + \delta(t) \quad (4.1)$$

El modelo representado en (4.1) es un sistema SISO, donde por (3.22), $F(\theta) = Q_n(\theta)/Vo - S(\psi_h(\theta))$ y $G = Q_i/Vo$ es la dinámica desconocida del sistema de riego con $\underline{g} < G(t) < \bar{g}$, donde $\underline{g}$ y $\bar{g}$ son los límites inferiores y superiores de $G(t)$, respectivamente; $\delta(t)$ representa las dinámicas no modeladas en la estructura y u la acción de control parametrizada.

Por último, en la sección 4.4 se plantea un DSS-VRI basado en un esquema MPC para gestionar diversas zonas de manejo de riego (HMZ).

En todos los casos, la acción de control (u) se parametriza teniendo en cuenta el tiempo que la válvula permanecerá encendida para alcanzar los objetivos de control, por tanto:

$$T_{on} = \frac{T_s}{Q_{got}} u \quad (4.2)$$

y,

$$V = \begin{cases} 1 & t \leq T_{on} \\ 0 & T_{on} < t \leq T_s \end{cases} \quad (4.3)$$

donde, Q_{got} es el caudal del emisor de riego, T_s es el tiempo de muestreo y t es el tiempo que transcurre entre el inicio y la finalización de un periodo de muestreo.

4.2 Control PI neuro-adaptable por superficies deslizantes

La dificultad que en ocasiones existe para determinar la dinámica de un sistema o la variabilidad de los parámetros del mismo, como es el caso del modelo descrito en el Capítulo 3, precisa de un DSS adaptativo a tales condiciones. Por eso, en esta sección se propone un controlador de riego de tipo adaptable para dinámicas desconocidas. El diseño está basado en superficies deslizantes en combinación con un controlador Proporcional-Integral (PI) y neuronal. Se comprueba la estabilidad del controlador y, luego, se realizan las pruebas de simulación de la estrategia de control del riego empleada. Dichas pruebas se complementan con los resultados obtenidos con un PID tradicional, verificando un ahorro del volumen de agua otorgado de un 55 % y 62 % en comparación con esta técnica para los suelos considerados. Por último, se demuestra el rechazo a perturbaciones (lluvia), de la estrategia planteada.

4.2.1 Diseño del controlador

El controlador PI neuronal toma la decisión de riego en función de la señal de error de humedad. Esta diferencia entre la referencia deseada y el contenido de agua en el punto considerado del suelo puede definirse como:

$$e(t) = \theta_{ref}(t) - \theta(t) \quad (4.4)$$

o,

$$\dot{e}(t) = \dot{\theta}_{ref}(t) - \dot{\theta}(t) \quad (4.5)$$

Entonces, el error de humedad del estado de salida se define como en (4.4) y (4.5). Partiendo de dichas ecuaciones, el objetivo es encontrar una ley de control tal que el estado θ , del sistema de lazo cerrado, tenga el mismo valor que el estado deseado θ_{ref} ; en otras palabras, el error de humedad debe converger a cero. Así, el esquema de control propuesto se presenta en la Figura 4.1.

El objetivo de la ley de control, obtenida mediante la técnica de modo deslizante, es seguir la referencia del sistema hasta una superficie preestablecida (definida por el diseñador), en el espacio de estado y mantenerla




Figura 4.1: Arquitectura de control del sistema de riego.

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. Esto 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 & Spurgeon, 1998), (Utkin, 1992), (Rossomando et al., 2014).

Se define una superficie de deslizamiento $s(\theta)$, para el sistema SISO, en el estado de error (4.4), que depende de las características y orden del sistema. Siendo $n = 1$ en este caso.

$$s(\theta) = \left(\frac{d}{dt} + \lambda \right)^n \int_0^t e(t) dt = e(t) + \lambda \int_0^t e(t) dt \quad (4.6)$$

La derivada de la superficie deslizante propuesta es:

$$\dot{s}(\theta) = \frac{d}{dt} \left(e(t) + \lambda \int_0^t e(\tau) d\tau \right) = \dot{e}(t) + \lambda e(t) \quad (4.7)$$

La ley de control, en la estrategia deslizante, está conformada por dos partes, una continua (u_c) y otra discontinua (u_d), de esta forma:

$$u(t) = u_c(t) + u_d(t)$$

Ahora, considerando el modelo dinámico (4.1) y la denominada condición de Filippov ($\dot{s} = 0$), (4.7) se puede escribir como:

$$\begin{aligned} \dot{s} &= \lambda e(t) + (\dot{\theta}_{ref} - \dot{\theta}) = 0 \\ &= \lambda e(t) + \dot{\theta}_{ref} - [F(\theta) + Gu_c(t) + \delta(t)] = 0 \end{aligned} \quad (4.8)$$

De esta manera, la parte continua de la ley de control puede obtenerse despejando u_c :

$$\begin{aligned} Gu_c(t) &= \lambda e(t) + \dot{\theta}_{ref} - F(\theta) - \delta(t) \\ u_c(t) &= G^{-1}[\lambda e(t) + \dot{\theta}_{ref} - F(\theta) - \delta(t)] \end{aligned} \quad (4.9)$$

Sin embargo, los parámetros del sistema dinámico son desconocidos ($F(\theta)$, G , $\delta(t)$), por lo que es necesario estimar los valores. Por ello, se hace uso de la capacidad de aproximación de funciones que tienen las redes neuronales de base radial (RBF) para realizar la estimación de estos parámetros. La estructura de la red RBF utilizada se muestra en la Figura 4.2. La función gaussiana que se utiliza como función de activación de cada neurona en la capa oculta de la red propuesta es la siguiente.

$$\xi_i(\psi, c_i, \varsigma_i) = e^{(\psi - c_i)^T (\psi - c_i) / -\varsigma_i^2} \quad (4.10)$$

siendo, ψ 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; ς_i es el factor de dispersión de la función gaussiana.




Figura 4.2: Estructura de la red RBF-PI

Entonces, se definen las funciones de estimación $F(\theta, \hat{\mathbf{w}}_f)$ y $G(\theta, \hat{\mathbf{w}}_g)$ de la forma:

$$F(\theta, \hat{\mathbf{w}}_f) = \hat{\mathbf{w}}_f^T \xi(\psi_f) = \sum_{i=1}^m \hat{w}_{fi} e^{-(\psi_f - c_{fi})^T (\psi_f - c_{fi}) / \zeta_{fi}^2} \quad (4.11)$$

y,

$$G(\theta, \hat{\mathbf{w}}_g) = \hat{\mathbf{w}}_g^T \xi(\psi_g) = \sum_{i=1}^m \hat{w}_{gi} e^{-(\psi_g - c_{gi})^T (\psi_g - c_{gi}) / \zeta_{gi}^2} \quad (4.12)$$

donde, $\psi_f = [\theta, \dot{\theta}, \theta_{ref}]$ y $\psi_g = [u, \dot{u}, \theta_{ref}]$ son los vectores regresores de la red.

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

$$\delta(s, \hat{\mathbf{w}}_\delta) = \hat{\mathbf{w}}_\delta^T \xi(\chi_\delta) = \sum_{i=1}^m \hat{w}_{\delta i} e^{-(\chi - c_{\delta i})^T (\chi - c_{\delta i}) / \zeta_{\delta i}^2} \quad (4.13)$$

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.

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

$$u = G^{-1}(\theta, \hat{\mathbf{w}}_g) [\alpha s + \lambda e(t) + \dot{\theta}_{ref} - F(\theta, \hat{\mathbf{w}}_f) - \delta(s, \hat{\mathbf{w}}_\delta) + u_d] \quad (4.14)$$

donde, αs es un término 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 $\mathbf{w}_f, \mathbf{w}_g \in \mathbb{R}^{m \times 1}$, asociados a la función de base radial ξ . Las reglas de ajuste de dichos pesos se determinarán en el análisis de estabilidad, con m el número de neuronas. Por último, u_d es el término no lineal $u_d = \eta \operatorname{sgn}(s)$.

La ley de control global viene dada por la ecuación (4.14), y definiendo el error mínimo de aproximación como:

$$\varepsilon = [F(\theta, \mathbf{w}_f^*) - F(\theta)] + [G(\theta, \mathbf{w}_g^*) - G(\theta)]u + [\delta(s, \mathbf{w}_\delta^*) - \delta(t)] \quad (4.15)$$

Consideración 1: ε está acotada por una constante η positiva, siendo:

$$|\varepsilon| \leq \eta \quad (4.16)$$

Restando la acción de control propuesta (4.14) en ambos miembros de (4.8) y expandiendo en una de ellas:

$$\begin{aligned} \dot{s} - G(\theta, \hat{\mathbf{w}}_g)u &= \lambda e(t) + \dot{\theta}_{ref} - F(\theta) - Gu - \delta(t) \\ &\quad \dots - [\alpha s + \lambda e(t) + \dot{\theta}_{ref} + u_s - F(\theta, \hat{\mathbf{w}}_f) - \delta(s, \hat{\mathbf{w}}_\delta)] \\ \dot{s} &= \lambda e(t) + \dot{\theta}_{ref} - F(\theta) - Gu - \delta(t) - \alpha s - \lambda e(t) \\ &\quad \dots - \dot{\theta}_{ref} - u_s + F(\theta, \hat{\mathbf{w}}_f) + \delta(s, \hat{\mathbf{w}}_\delta) + G(\theta, \hat{\mathbf{w}}_g)u \\ \dot{s} &= [F(\theta, \hat{\mathbf{w}}_f) - F(\theta)] + [G(\theta, \hat{\mathbf{w}}_g) - G]u + \dots \\ &\quad \dots + [\delta(s, \hat{\mathbf{w}}_\delta) - \delta(t)] - \alpha s - u_s \end{aligned} \quad (4.17)$$

Ahora, sumando y restando ε en (4.17) y expandiendo una de ellas:

$$\begin{aligned} \dot{s} &= [F(\theta, \hat{\mathbf{w}}_f) - F(\theta)] + [G(\theta, \hat{\mathbf{w}}_g) - G]u + \dots \\ &\quad \dots + [\delta(s, \hat{\mathbf{w}}_\delta) - \delta(t)] - \alpha s - u_s - \{[F(\theta, \mathbf{w}_f^*) - F(\theta)] + \dots \\ &\quad \dots + [G(\theta, \mathbf{w}_g^*) - G(\theta)]u + [\delta(s, \mathbf{w}_\delta^*) - \delta(t)]\} + \varepsilon \\ &= F(\theta, \hat{\mathbf{w}}_f) - F(\theta) + G(\theta, \hat{\mathbf{w}}_g)u - Gu + \dots \\ &\quad \dots + \delta(s, \hat{\mathbf{w}}_\delta) - \delta(t) - \alpha s - u_s - F(\theta, \mathbf{w}_f^*) + F(\theta) - \dots \\ &\quad \dots - G(\theta, \mathbf{w}_g^*)u + G(\theta)u - \delta(s, \mathbf{w}_\delta^*) + \delta(t) + \varepsilon \\ &= [F(\theta, \hat{\mathbf{w}}_f) - F(\theta, \mathbf{w}_f^*)] + [G(\theta, \hat{\mathbf{w}}_g) - G(\theta, \mathbf{w}_g^*)]u \\ &\quad \dots + [\delta(s, \hat{\mathbf{w}}_\delta) - \delta(s, \mathbf{w}_\delta^*)] - \alpha s + \varepsilon - u_s \end{aligned} \quad (4.18)$$

Teniendo en cuenta que,

$$\begin{aligned} F(\theta, \hat{\mathbf{w}}_f) - F(\theta, \mathbf{w}_f^*) &= \tilde{\mathbf{w}}_f^T \boldsymbol{\xi}(\psi_f) - \mathbf{w}_f^{*T} \boldsymbol{\xi}(\psi_f) = \tilde{\mathbf{w}}_f^T \boldsymbol{\xi}(\psi_f) \\ G(\theta, \hat{\mathbf{w}}_g) - G(\theta, \mathbf{w}_g^*) &= \tilde{\mathbf{w}}_g^T \boldsymbol{\xi}(\psi_g) - \mathbf{w}_g^{*T} \boldsymbol{\xi}(\psi_g) = \tilde{\mathbf{w}}_g^T \boldsymbol{\xi}(\psi_g) \\ \delta(s, \hat{\mathbf{w}}_\delta) - \delta(s, \mathbf{w}_\delta^*) &= \tilde{\mathbf{w}}_\delta^T \boldsymbol{\chi}(s) - \mathbf{w}_\delta^{*T} \boldsymbol{\chi}(s) = \tilde{\mathbf{w}}_\delta^T \boldsymbol{\chi}(s) \end{aligned} \quad (4.19)$$

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

$$\begin{cases} \tilde{\mathbf{w}}_f = \hat{\mathbf{w}}_f - \mathbf{w}_f^* \\ \tilde{\mathbf{w}}_g = \hat{\mathbf{w}}_g - \mathbf{w}_g^* \\ \tilde{\mathbf{w}}_\delta = \hat{\mathbf{w}}_\delta - \mathbf{w}_\delta^* \end{cases} \quad (4.20)$$

Y, por tanto, su derivada, considerando que $\mathbf{w}_f^*, \mathbf{w}_g^*, \mathbf{w}_\delta^*$ son constantes:

$$\begin{cases} \dot{\tilde{\mathbf{w}}}_f = \dot{\hat{\mathbf{w}}}_f \\ \dot{\tilde{\mathbf{w}}}_g = \dot{\hat{\mathbf{w}}}_g \\ \dot{\tilde{\mathbf{w}}}_\delta = \dot{\hat{\mathbf{w}}}_\delta \end{cases} \quad (4.21)$$

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

$$\dot{s} = \tilde{\mathbf{w}}_f^T \boldsymbol{\xi}(\psi_f) + \tilde{\mathbf{w}}_g^T \boldsymbol{\xi}(\psi_g)u + \tilde{\mathbf{w}}_\delta^T \boldsymbol{\chi}(s) - \alpha s + \varepsilon - u_s \quad (4.22)$$

Análisis de estabilidad y ajuste de parámetros

Teorema: Se considera el sistema no lineal incierto (4.1) y las leyes de ajuste (4.29)-(4.31), que serán definidas en lo que sigue. Entonces, el controlador definido por (4.14) asegura la convergencia en tiempo finito del vector de error de seguimiento a la capa límite y su convergencia exponencial en la región cerrada Λ .

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

$$L = \frac{1}{2}[s^2 + \gamma_1^{-1}(\tilde{\mathbf{w}}_f^T \tilde{\mathbf{w}}_f) + \gamma_2^{-1}(\tilde{\mathbf{w}}_g^T \tilde{\mathbf{w}}_g) + \gamma_3^{-1}(\tilde{\mathbf{w}}_\delta^T \tilde{\mathbf{w}}_\delta)] \quad (4.23)$$

La presencia de un término 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 y Chung, 2007. Esta sustitución suaviza la discontinuidad del control e introduce una fina capa límite Λ en la vecindad de la superficie de conmutación, por lo tanto, la función $u_d = \eta \text{sign}(s)$ puede ser reemplazada por la función $u_d = \eta \text{sat}(s/\Lambda)$, siendo la función saturación expresada como:

$$\text{sat}\left(\frac{s}{\Lambda}\right) = \begin{cases} \text{sign}(s) & \text{if } |s| \geq \Lambda \\ (s/\Lambda) & \text{if } |s| < \Lambda \end{cases} \quad (4.24)$$

donde, Λ es una constante estrictamente positiva que representa el espesor de la capa límite.

Ahora, derivando (4.23) queda:

$$\dot{L} = s\dot{s} + \gamma_1^{-1}(\tilde{\mathbf{w}}_f^T \dot{\tilde{\mathbf{w}}}_f) + \gamma_2^{-1}(\tilde{\mathbf{w}}_g^T \dot{\tilde{\mathbf{w}}}_g) + \gamma_3^{-1}(\tilde{\mathbf{w}}_\delta^T \dot{\tilde{\mathbf{w}}}_\delta) \quad (4.25)$$

Sustituyendo (4.22) en (4.25) y considerando la situación en que $|s| \geq \Lambda$ donde la función toma el valor $\text{sat}(s/\Lambda) = \eta \text{sign}(s)$, (4.24).

$$\begin{aligned} \dot{L} = & s[\tilde{\mathbf{w}}_f^T \boldsymbol{\xi}(\psi_f) + \tilde{\mathbf{w}}_g^T \boldsymbol{\xi}(\psi_g)u + \tilde{\mathbf{w}}_\delta^T \boldsymbol{\chi}(s) - \alpha s + \varepsilon - \eta \text{sign}(s)] + \dots \\ & \dots + \gamma_1^{-1}(\tilde{\mathbf{w}}_f^T \dot{\tilde{\mathbf{w}}}_f) + \gamma_2^{-1}(\tilde{\mathbf{w}}_g^T \dot{\tilde{\mathbf{w}}}_g) + \gamma_3^{-1}(\tilde{\mathbf{w}}_\delta^T \dot{\tilde{\mathbf{w}}}_\delta) \end{aligned} \quad (4.26)$$

Reordenando (4.26) y, teniendo en cuenta que $s[\text{sign}(s)] = |s|$;

$$\begin{aligned} \dot{L} = & s\tilde{\mathbf{w}}_f^T \boldsymbol{\xi}(\psi_f) + s\tilde{\mathbf{w}}_g^T \boldsymbol{\xi}(\psi_g)u + s\tilde{\mathbf{w}}_\delta^T \boldsymbol{\chi}(s) - \alpha s^2 + s\varepsilon - \dots \\ & \dots - \eta |s| + \gamma_1^{-1}(\tilde{\mathbf{w}}_f^T \dot{\tilde{\mathbf{w}}}_f) + \gamma_2^{-1}(\tilde{\mathbf{w}}_g^T \dot{\tilde{\mathbf{w}}}_g) + \gamma_3^{-1}(\tilde{\mathbf{w}}_\delta^T \dot{\tilde{\mathbf{w}}}_\delta) \end{aligned} \quad (4.27)$$

Agrupando,

$$\begin{aligned} \dot{L} = & \tilde{\mathbf{w}}_f^T [s\boldsymbol{\xi}(\psi_f) + \gamma_1^{-1}\dot{\tilde{\mathbf{w}}}_f] + \tilde{\mathbf{w}}_g^T [s\boldsymbol{\xi}(\psi_g)u + \gamma_2^{-1}\dot{\tilde{\mathbf{w}}}_g] + \dots \\ & \dots + \tilde{\mathbf{w}}_\delta^T [s\boldsymbol{\chi}(s) + \gamma_3^{-1}\dot{\tilde{\mathbf{w}}}_\delta] - \alpha s^2 + s\varepsilon - \eta |s| \end{aligned} \quad (4.28)$$

Si se definen las reglas de ajuste de la siguiente forma:

$$\dot{\mathbf{w}}_f = -\gamma_1 s \boldsymbol{\xi}(\psi_f) \quad (4.29)$$

$$\dot{\mathbf{w}}_g = -\gamma_2 s \boldsymbol{\xi}(\psi_g) u \quad (4.30)$$

$$\dot{\mathbf{w}}_\delta = -\gamma_3 s \boldsymbol{\chi}(s) \quad (4.31)$$

Reemplazando las ecuaciones (4.29), (4.30) y (4.31) en (4.28) se obtiene que:

$$\dot{L} = -\alpha s^2 - \eta |s| + \varepsilon s \leq 0 \quad (4.32)$$

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 (4.26), (4.32) resulta en:

$$\dot{L} = -(\alpha + \frac{1}{\Lambda})s^2 + \varepsilon s \leq 0$$

Se debe cumplir que:

$$\begin{aligned} s \left(\frac{\alpha\Lambda + 1}{\Lambda} \right) &\geq \varepsilon \\ s &\geq \frac{\varepsilon\Lambda}{(\alpha\Lambda + 1)} \end{aligned} \quad (4.33)$$

En ambos casos, implica que $L(t) \leq L(0)$. A partir de la definición, se puede comprobar fácilmente que s está acotado. Considerando (4.6), se puede verificar que e también está acotado. Por lo tanto, implica que (4.7) también está acotado. Este resultado implica que la variable controlada tiende a cero aun cuando el modelo es totalmente desconocido.

La Tabla 4.1 presenta los parámetros y variables utilizadas en la configuración del controlador, junto con sus descripciones correspondientes. Es importante destacar que algunos de estos elementos comparten la misma notación que secciones anteriores, si bien ahora poseen un significado distinto.

Tabla 4.1: Nomenclatura del diseño del controlador

Símbolo	Descripción
λ	Capa límite
s	Superficie de deslizamiento
u_s	Término robusto de control
η	Constante positiva
w_f^* w_g^* w_δ^*	Pesos óptimos
$\hat{w}_f$ $\hat{w}_g$ $\hat{w}_\delta$	Pesos estimados
σ	Anchura de la campana de Gauss
c	Centros de la campana de Gauss
m	Número neuronas ocultas
ψ_f ψ_g χ	Vector regresor
ξ	Función de activación Gaussiana
K_p K_i	Pesos proporcional e integral de la RN
α	Parámetro asociado con la convergencia

4.2.2 Resultados

El controlador PI neuronal, se probó en simulación teniendo en cuenta el modelo descrito en el Capítulo 3. Los parámetros del suelo y del cultivo usados en la simulación se presentan en la Tabla 4.2, Tabla 4.3 y la Tabla 4.4. A partir de esta parametrización del modelo, se aplicó el control descrito en la sección 4.2.1 durante un periodo de riego y se obtuvieron los resultados de la Figura 4.3 y Figura 4.4. En las mismas, se grafican también los valores de contenido de agua obtenidos mediante un controlador PID tradicional.

Tabla 4.2: Propiedades texturales e hídricas

Suelo	Propiedades					
	Texturales ¹			hídricas		
	Arena	Arcilla	Limo	FC ²	WP ²	BD ³
S1	35	33	32	39.18	18.31	1.28
S2	33	34	33	0.32	0.2	1.34

Unidades:

^a %

^b $cm^3 \cdot cm^{-3}$

^c $g \cdot cm^{-3}$

Tabla 4.3: Parámetros del modelo de suelo

	θ_r	θ_s	α	n	K_s
S1	0.0845	0.4683	0.012	1.4550	1e-3
S2	0.0854	0.4572	0.0124	1.4340	1.6e-4

Tabla 4.4: Parámetros del modelo de extracción

Parameters	z_m	r_m	z^*	r^*	p_z	p_r
Value	75	50	35	10	29.9251	0.0029




Figura 4.3: Contenido volumétrico de agua porcentual controlador PI-neuronal. Valor de referencia $\theta_{ref} = 22\%$. Suelo 1.




Figura 4.4: Contenido volumétrico de agua porcentual controlador PI-neuronal. Valor de referencia $\theta_{ref} = 22\%$. Suelo 2.

Se puede observar, en todas las gráficas, la respuesta estable del lazo cerrado y el contenido de agua manteniéndose dentro de la zona de punto de marchitamiento permanente (θ_{PMP}) y capacidad de campo (θ_{FC}), alrededor de la referencia. En términos generales, se puede decir que la amplitud de la variación del contenido de agua es menor para el caso del PID neuronal. En cuanto al volumen de agua aplicado por uno y otro método, el PI neuronal muestra un menor uso de este recurso. En la Tabla 4.5, se muestra una comparativa de los volúmenes otorgados por ambas técnicas de control.

Tabla 4.5: Comparación entre el controlador PI neuronal y el PID

Suelo	NN PI	PID
S1	64l	167.83l
S3	56l	123.88l

Para evaluar el rechazo a las perturbaciones del controlador, se introdujeron perturbaciones arbitrarias en dos momentos del riego. La primera, se produce a las 70h aproximadamente y durante más de media hora. Esto, coincide con el descenso de la respuesta de humedad, cercana a un pico de humedad de un riego anterior. La segunda, se produce antes de las 140h aproximadamente y durante una hora, coincidiendo con la finalización de un riego previo. Estas situaciones pueden verse en la Figura 4.5, donde, en ambos casos se retrasa el inicio del siguiente riego. Solo se consideró el tipo de suelo 1 en este ensayo.

4.2.3 Conclusiones

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. 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




Figura 4.5: Respuesta del controlador PI neuronal ante perturbaciones aleatorias.

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.

El sistema de control PI neuronal consiguió un ahorro en la cantidad de agua aplicada de entre el 55 % y el 62 %, en comparación con el PID tradicional, para los tipos de suelo considerados.

Se introdujo una lluvia aleatoria en dos ocasiones para evaluar el rechazo a perturbaciones del controlador, y se observó una respuesta satisfactoria ante estas.

4.3 Control PI con compensación

La variabilidad espacial y temporal de un suelo cultivado, con sistemas de riego tecnificados, requiere sistemas de control adaptativos a las condicio-

nes variables del intesistema agua-suelo-clima-cultivo. Por ello, en esta sección se propone un control adaptativo basado en una Red Neuronal de Función de Base Radial (RBF-RN). Un controlador estático Proporcional-Integral (PI) fue sintonizado sin modificar sus parámetros añadiendo una compensación basada en RBF-RNs. De esta forma, la variación dinámica se aproxima en tiempo real mediante una RBF-RN. El controlador se prueba en simulación a partir de un modelo de distribución de agua en el suelo con extracción por un cultivo. Los resultados obtenidos con este método se comparan con un controlador tradicional Proporcional-Integral-Derivativo (PID). Las comparaciones se realizan teniendo en cuenta el compromiso entre la cantidad de agua aplicada y la frecuencia de riego para mantener los valores de humedad del suelo dentro de los límites permitidos. Se consigue un ahorro de agua del 20 % y una reducción de las activaciones de válvulas 2 veces menor que con el PID tradicional. Finalmente, se evalúa el comportamiento del controlador ante perturbaciones, comprobando el rechazo que produce ante estas eventualidades.

4.3.1 Diseño del controlador

Definiendo el error de control como:

$$\tilde{\theta} = \theta_{ref} - \theta \quad (4.34)$$

Derivando (4.34):

$$\dot{\tilde{\theta}} = \dot{\theta}_{ref} - \dot{\theta} \quad (4.35)$$

Reemplazando (4.1) in (4.35), el cambio en el error de control se define mediante:

$$\dot{\tilde{\theta}} = \dot{\theta}_{ref} - \left(f(\theta) + gu + \delta \right) \quad (4.36)$$

Para obtener la ley de control, el cambio en el esfuerzo de control U se define como:

$$U = \dot{\theta}_{ref} - \left(f(\theta) + gu + \delta \right) \quad (4.37)$$

Ahora, operando y despejando la acción de control efectiva (u) aplicada al sistema:

$$u = \frac{1}{g} \left(- (U - \dot{\theta}_{ref}) - f(\theta) - \delta \right) \quad (4.38)$$

Utilizando la siguiente expresión para un controlador PI como ley de control U :

$$U = -(K_P \tilde{\theta} + \omega) \quad (4.39)$$

siendo, ω una variable auxiliar para calcular la acción integral. La derivada de esta acción integral se puede expresar como:

$$\dot{\omega} = K_i \tilde{\theta} \quad (4.40)$$

Reemplazando (4.39) in (4.38):

$$u = \frac{1}{g} \left(K_P \tilde{\theta} + \omega + \dot{\theta}_{ref} - f(\theta) - \delta \right) \quad (4.41)$$

Empleando $\hat{f}(\theta)$, $\hat{g}$ y $\hat{\delta}$ como los valores de estos parámetros en el punto de funcionamiento deseado, la nueva ley de control puede expresarse como:

$$u = \frac{1}{\hat{g}} \left(K_P \tilde{\theta} + \omega + \dot{\theta}_{ref} - \hat{f}(\theta) - \hat{\delta} \right) \quad (4.42)$$

Recordando que, $\dot{\omega} = K_i \tilde{\theta}$ y el símbolo $\hat{f}$ indica los valores en el punto de diseño del controlador. En ese sentido, $f(\theta)$ y g son los parámetros no lineales del modelo, sólo conocidos en el punto de diseño del controlador PI tomado de un modelo del proceso. Estos parámetros cambian durante la operación del proceso causando un bajo rendimiento del controlador PI. En este sentido, ajustar estos valores en tiempo real ayudará al controlador PI a mantener su rendimiento lo más cercano posible al diseñado. El comportamiento de dicha compensación durante la respuesta transitoria debe ser aceptable considerando que la compensación puede realizarse en tiempo real.

Sumando y restando el término $\hat{g}u$ en (4.1), que representa la dinámica del sistema utilizada para el diseño del controlador, se obtiene la siguiente expresión:

$$\dot{\theta} = f(\theta) + gu + \delta + \hat{g}u - \hat{g}u \quad (4.43)$$

Para obtener el error de control, (4.42) se sustituye en (4.43), pero sólo en el último u para dejar visible una acción de control u en el modelo del

proceso controlado (con valores de estado real y estacionario de $f(\theta)$). Utilizando la derivada de ω para completar la representación vectorial del proceso controlado:

$$\begin{bmatrix} \dot{\theta} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} f(\theta) + gu + \delta - \hat{g}u + \left(K_P \tilde{\theta} + \omega + \dot{\theta}_{ref} - \hat{f}(\theta) - \hat{\delta} \right) \\ K_i \tilde{\theta} \end{bmatrix}$$

Reordenando, al considerar $\tilde{f}(\theta) = f(\theta) - \hat{f}(\theta)$, $\tilde{g} = g - \hat{g}$ y $\tilde{\delta} = \delta - \hat{\delta}$, aparece la siguiente expresión:

$$\begin{bmatrix} \dot{\theta} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} \tilde{f}(\theta) + \tilde{g}u + \tilde{\delta} + \dot{\theta}_{ref} + K_P \tilde{\theta} + \omega \\ K_i \tilde{\theta} \end{bmatrix} \quad (4.44)$$

Agrupando los términos de la derivada de humedad a la izquierda:

$$\begin{bmatrix} \dot{\theta} - \dot{\theta}_{ref} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} \tilde{f}(\theta) + \tilde{g}u + \tilde{\delta} + K_P \tilde{\theta} + \omega \\ K_i \tilde{\theta} \end{bmatrix} \quad (4.45)$$

Definiendo la derivada del error de salida ($\dot{\theta}_{ref} - \dot{\theta}$) como $\dot{\tilde{\theta}}$ y sustituyendo en 4.45, se obtiene:

$$\begin{bmatrix} -\dot{\tilde{\theta}} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} \tilde{f}(\theta) + \tilde{g}u + \tilde{\delta} + K_P \tilde{\theta} + \omega \\ K_i \tilde{\theta} \end{bmatrix} \quad (4.46)$$

Expresando las derivadas como magnitudes positivas, se obtiene la ecuación diferencial que representa la dinámica del error del sistema controlado:

$$\begin{bmatrix} \dot{\tilde{\theta}} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} -(\tilde{f}(\theta) + \tilde{g}u + \tilde{\delta}) - K_P \tilde{\theta} - \omega \\ K_i \tilde{\theta} \end{bmatrix} \quad (4.47)$$

En la ecuación anterior, se puede ver que el error del sistema de control se ve afectado por el error de diferencia dinámica $\tilde{f}(\theta) + \tilde{g}u + \tilde{\delta}$. Los parámetros $\tilde{f}(\theta)$ y $\tilde{\delta}$ se utilizan aquí como constantes pero en la operación

real estos parámetros cambian con θ . Esta diferencia, se denomina en lo siguiente como: $\Delta = (\tilde{f}(\theta) + \tilde{g}u + \tilde{\delta})$, recordando que además contiene el efecto de la acción de control total u . Para resolver este problema, se propone añadir un término adaptable a la acción de control total (4.42). De esta manera, reducir el efecto de las mencionadas diferencias en la dinámica.

La Figura 4.6, muestra de forma gráfica la estrategia de control propuesta. Se puede observar que la compensación adaptativa añade un valor a la acción de control, este valor mejora la respuesta de salida reduciendo el error de control.




Figura 4.6: Esquema de la estrategia de control PI neuroadaptativa propuesta, incluida la ley de aprendizaje.

Compensación adaptable

Aquí, se implementa una técnica de ajuste on-line basada en una red neuronal de Función de Base Radial (RBF-NN). El objetivo principal, es ajustar u para compensar las variaciones dinámicas del proceso respecto al estado estacionario donde se sintonizó el controlador PI, sin modificar los parámetros del controlador PI estático. Para construir esta estrategia de control, se debe realizar una identificación adaptativa, considerando que cualquier función no lineal puede ser aproximada por una red neuronal (Cybenko, 1989). En este caso, la variación dinámica $\Delta = (\tilde{f}(\theta) + \tilde{g}u + \tilde{\delta})$ se aproxima mediante una RBF-RN, con ajuste de parámetros on-line.

Definiendo el vector regresor para la RBF-RN como la humedad actual, la referencia de humedad y el cambio de humedad ($\zeta = [\theta, \theta_{ref}, \dot{\theta}]$), la

aproximación de Δ con la RBF-RN se expresa como:

$$\begin{aligned}\Delta = (\tilde{f}(\theta) + \tilde{g}u + \tilde{\delta}) &= \sum_{j=1}^m w_j^* e^{-\frac{1}{\sigma_j^{*2}} \|\zeta - c_j^*\|} + \varepsilon \\ &= \mathbf{w}^{*T} \boldsymbol{\xi}(\zeta, \sigma^*, c^*) - \varepsilon(\theta)\end{aligned}\quad (4.48)$$

donde, $\mathbf{w}^*$ es el vector de pesos óptimo $m \times 1$ (m indica el número de neuronas ocultas) y $\boldsymbol{\xi}$ es el vector RBF-RN $m \times 1$ con cada entrada que representa una única función RBF-RN. Cada función gaussiana está determinada por el vector de centros $\mathbf{c}^*$ y las anchuras de la campana gaussiana σ^* y ζ la mejor aproximación realizada por la RBF-RN. Por último, ε es el menor valor del error de aproximación de la red neuronal. Los valores óptimos definidos anteriormente son valores desconocidos y constantes; esta estructura neuronal se utiliza para diseñar la compensación neuronal.

A partir de ahora, se utiliza la función $\boldsymbol{\xi}^*$ en lugar de $\boldsymbol{\xi}(\zeta, \sigma^*, \mathbf{c}^*)$ para reducir la extensión de las ecuaciones. Por lo tanto, la representación neuronal de las variaciones dinámicas es:

$$\Delta = (\tilde{f}(\theta) + \tilde{g}u + \tilde{\delta}) = \mathbf{w}^{*T} \boldsymbol{\xi}^* - \varepsilon(\theta) \quad (4.49)$$

Observación 1: El error de aproximación neural ε es Lipschitz sobre θ :

$$\|\vartheta(x) - \vartheta(y)\| \leq k_\vartheta \|x - y\| \quad (4.50)$$

A partir de (4.49), $\Delta = (\tilde{f}(\theta) + \tilde{g}u + \tilde{\delta})$ satisface la condición de Lipschitz, tal como se presenta en (4.50). Ahora, a partir de (4.49) despejando $\varepsilon(\theta)$ y aplicando integral entre 0 y t , se obtiene lo siguiente:

$$\int_0^t \varepsilon(\theta) d\theta = \int_0^t \mathbf{w}^{*T} \boldsymbol{\xi}^* d\theta - \int_0^t (\tilde{g}u + \tilde{\delta}) d\theta - \int_0^t \tilde{f}(\theta) d\theta \quad (4.51)$$

donde, $\mathbf{w}^{*T} \int_0^t \boldsymbol{\xi}^* d\theta = \frac{1}{2} \|\mathbf{w}^*\| \sqrt{\pi}$, ya que se conoce el espacio de trabajo del suelo húmedo (todo el conjunto de puntos alcanzables por el proceso) y se puede estimar $\bar{\theta} = \max(\theta)$. Y $\int_0^t \tilde{g}u d\theta + \int_0^t \tilde{\delta} d\theta \leq k_g$, por diferencia de valores constantes. Ahora, (4.51) puede expresarse como:

$$k_\varepsilon = \frac{1}{2} \|\mathbf{w}^*\| \sqrt{\pi} - k_g - k_f \bar{\theta} \quad (4.52)$$

siendo k_ε el límite superior de $\int_0^t \varepsilon(\theta) d\theta$. Por simplicidad se representará $\varepsilon(\theta)$ como ε .

En este punto es necesario definir un término de compensación que se añadirá a la ley de control para reducir el error de control. Esta compensación puede definirse como:

$$\hat{\Delta} = \hat{\mathbf{w}}^T \hat{\boldsymbol{\xi}}(\zeta, \hat{\sigma}, \hat{c}) \quad (4.53)$$

Y se utilizará en la ley de control propuesta, simbolizada como $\hat{\boldsymbol{\xi}}(\zeta, \hat{\sigma}, \hat{c})$ para reducir la longitud de las ecuaciones. Restando el término de compensación (4.53) a la acción de control (4.42) conduce a:

$$\begin{bmatrix} u \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} \frac{1}{\hat{g}} \left(K_P \tilde{\theta} + \omega + \dot{\theta}_{ref} - \hat{f}(\theta) - \hat{\delta} - \hat{\mathbf{w}}^T \hat{\boldsymbol{\xi}} \right) \\ K_i \tilde{\theta} \end{bmatrix} \quad (4.54)$$

que se añade también en (4.43) conduciendo a:

$$\begin{bmatrix} \dot{\theta} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} f(\theta) + gu + \delta + K_P \tilde{\theta} + \omega + \dot{\theta}_{ref} - \hat{f}(\theta) - \hat{\delta} - \hat{\mathbf{w}}^T \hat{\boldsymbol{\xi}} - \hat{g}u \\ K_i \tilde{\theta} \end{bmatrix} \quad (4.55)$$

Despejando $\dot{\theta}_{ref}$ en (4.55), se obtiene:

$$\begin{aligned} \begin{bmatrix} \dot{\theta} - \dot{\theta}_{ref} \\ \dot{\omega} \end{bmatrix} &= \begin{bmatrix} \tilde{f}(\theta) + \tilde{g}u + \tilde{\delta} + (K_\theta \tilde{\theta} + \omega) - \hat{\mathbf{w}}^T \hat{\boldsymbol{\xi}} \\ K_i \tilde{\theta} \end{bmatrix} \\ \begin{bmatrix} \dot{\theta} \\ \dot{\omega} \end{bmatrix} &= \begin{bmatrix} -(\tilde{f}(\theta) + \tilde{g}u + \tilde{\delta}) - (K_\theta \tilde{\theta} - \omega) + \hat{\mathbf{w}}^T \hat{\boldsymbol{\xi}} \\ K_i \tilde{\theta} \end{bmatrix} \end{aligned} \quad (4.56)$$

Teniendo en cuenta (4.49) y sustituyendo en (4.56):

$$\begin{bmatrix} \dot{\theta} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} -(\mathbf{w}^{*T} \boldsymbol{\xi}^* - \varepsilon) - K_\theta \tilde{\theta} - \omega + \hat{\mathbf{w}}^T \hat{\boldsymbol{\xi}} \\ K_i \tilde{\theta} \end{bmatrix} \quad (4.57)$$

Ahora, definiendo el error del vector de pesos $\tilde{\mathbf{w}}$ como la diferencia entre $\mathbf{w}^*$, el óptimo, y $\mathbf{w}$, el instantáneo, ($\tilde{\mathbf{w}} = \mathbf{w}^* - \mathbf{w}$), y de la misma manera para $\tilde{\xi} = \xi^* - \hat{\xi}$, (4.57) puede escribirse como:

$$\begin{aligned} \begin{bmatrix} \dot{\tilde{\theta}} \\ \dot{\tilde{\omega}} \end{bmatrix} &= \begin{bmatrix} -(\hat{\mathbf{w}}^T \tilde{\xi} + \tilde{\mathbf{w}}^T \hat{\xi} + \tilde{\mathbf{w}}^T \tilde{\xi} + \tilde{\mathbf{w}}^T \tilde{\xi} - \varepsilon) - K_P \tilde{\theta} - \omega + (\hat{\mathbf{w}}^T \hat{\xi}) \\ K_i \tilde{\theta} \end{bmatrix} \\ &= \begin{bmatrix} -(\tilde{\mathbf{w}}^T \hat{\xi} + \tilde{\mathbf{w}}^T \tilde{\xi} + \tilde{\mathbf{w}}^T \tilde{\xi} - \varepsilon) - K_P \tilde{\theta} - \omega \\ K_i \tilde{\theta} \end{bmatrix} \end{aligned} \quad (4.58)$$

Considerando que $\tilde{\mathbf{w}}^T \tilde{\xi} + \varepsilon = \varepsilon^i$, debido a que el producto $\tilde{\mathbf{w}}^T \tilde{\xi}$ es equivalente al producto de dos errores, se puede considerar como parte del error mínimo de la red neuronal. Por lo tanto, (4.58) se expresa como:

$$\begin{bmatrix} \dot{\tilde{\theta}} \\ \dot{\tilde{\omega}} \end{bmatrix} = \begin{bmatrix} -K_P \tilde{\theta} - \omega - (\hat{\mathbf{w}}^T \tilde{\xi} + \tilde{\mathbf{w}}^T \hat{\xi} - \varepsilon^i(\theta)) \\ K_i \tilde{\theta} \end{bmatrix} \quad (4.59)$$

El equilibrio de (4.59) es $(\tilde{\theta}, \omega)^T = (0, \omega^*)^T$, ya que en el punto de equilibrio $\theta = \theta_{ref}$. Por lo tanto, este equilibrio es $(0, \varepsilon^i(\theta_{ref}))^T$. Para trasladar el equilibrio al origen, se define:

$$\tilde{\omega} = \omega - \varepsilon^i(\theta_{ref}) \quad (4.60)$$

Entonces, (4.59) puede expresarse como:

$$\begin{aligned} \begin{bmatrix} \dot{\tilde{\theta}} \\ \dot{\tilde{\omega}} \end{bmatrix} &= \begin{bmatrix} -K_P \tilde{\theta} - \tilde{\omega} - \varepsilon^i(\theta_{ref}) - (\hat{\mathbf{w}}^T \tilde{\xi} + \tilde{\mathbf{w}}^T \hat{\xi} - \varepsilon^i(\theta)) \\ K_i \tilde{\theta} \end{bmatrix} \\ &= \begin{bmatrix} -K_P \tilde{\theta} - \tilde{\omega} - (\hat{\mathbf{w}}^T \tilde{\xi} + \tilde{\mathbf{w}}^T \hat{\xi} + \tilde{\varepsilon}) \\ K_i \tilde{\theta} \end{bmatrix} \end{aligned} \quad (4.61)$$

donde, $\tilde{\varepsilon} = \varepsilon^i(\theta_{ref}) - \varepsilon^i(\theta)$, de la **Observación 1** (4.52), $\varepsilon(\theta)$ está limitada por k_ε , luego, $\tilde{\varepsilon}$ también está limitada por una constante k . Esta definición se utilizará en la siguiente sección.

Análisis de estabilidad y ajuste de parámetros

Proponiendo una función candidata de Lyapunov (LCF) de la forma:

$$\mathcal{L} = \frac{1}{2} (K_P K_i (\tilde{\theta})^2 + K_P (\tilde{\omega})^2 + \frac{\tilde{\mathbf{w}}^T \tilde{\mathbf{w}}}{\alpha} + \frac{\tilde{\mathbf{c}}^T \tilde{\mathbf{c}}}{\beta} + \frac{\tilde{\boldsymbol{\sigma}}^T \tilde{\boldsymbol{\sigma}}}{\gamma}) \quad (4.62)$$

Donde, α , β , y γ son constantes de ajuste que varían entre 0 y 1. Derivando (4.62) conduce a:

$$\dot{\mathcal{L}} = (K_P K_i \dot{\tilde{\theta}} \tilde{\theta} + K_P \tilde{\omega} \dot{\tilde{\omega}} + \frac{\tilde{\mathbf{w}}^T \dot{\tilde{\mathbf{w}}}}{\alpha} + \frac{\tilde{\mathbf{c}}^T \dot{\tilde{\mathbf{c}}}}{\beta} + \frac{\tilde{\boldsymbol{\sigma}}^T \dot{\tilde{\boldsymbol{\sigma}}}}{\gamma}) \quad (4.63)$$

Reemplazando (4.61) in (4.63) se obtiene:

$$\begin{aligned} \dot{\mathcal{L}} = & -K_P^2 K_i \tilde{\theta}^2 - K_P \tilde{\theta} K_i \tilde{\omega} - K_P K_i \tilde{\theta} (\tilde{\mathbf{w}}^T \tilde{\boldsymbol{\xi}} + \tilde{\mathbf{w}}^T \hat{\boldsymbol{\xi}} + \tilde{\varepsilon}) + \dots \\ & + K_P \tilde{\omega} (K_i \tilde{\theta}) + \frac{\tilde{\mathbf{w}}^T \dot{\tilde{\mathbf{w}}}}{\alpha} + \frac{\tilde{\mathbf{c}}^T \dot{\tilde{\mathbf{c}}}}{\beta} + \frac{\tilde{\boldsymbol{\sigma}}^T \dot{\tilde{\boldsymbol{\sigma}}}}{\gamma} \end{aligned} \quad (4.64)$$

Reordenando (4.64):

$$\dot{\mathcal{L}} = -K_P^2 K_i \tilde{\theta}^2 - K_P K_i \tilde{\theta} (\tilde{\mathbf{w}}^T \tilde{\boldsymbol{\xi}} + \tilde{\mathbf{w}}^T \hat{\boldsymbol{\xi}} + \tilde{\varepsilon}) + \frac{\tilde{\mathbf{w}}^T \dot{\tilde{\mathbf{w}}}}{\alpha} + \frac{\tilde{\mathbf{c}}^T \dot{\tilde{\mathbf{c}}}}{\beta} + \frac{\tilde{\boldsymbol{\sigma}}^T \dot{\tilde{\boldsymbol{\sigma}}}}{\gamma} \quad (4.65)$$

Ahora, utilizando una aproximación para la función $\tilde{\boldsymbol{\xi}}$ basada en la serie de Taylor, se puede expresar como la expansión de Taylor de $\boldsymbol{\xi}^*$ aplicada en los puntos $\mathbf{c}^* = \mathbf{c}$ y $\sigma^* = \sigma$, obteniendo:

$$\boldsymbol{\xi}^*(\boldsymbol{\zeta}, \sigma^*, \mathbf{c}^*) = \boldsymbol{\xi}(\boldsymbol{\zeta}, \sigma, \mathbf{c}) + \mathbf{Z}^T \tilde{\mathbf{c}} + \boldsymbol{\Gamma}^T \tilde{\sigma} + \mathbf{H}(\boldsymbol{\zeta}, \tilde{\sigma}, \tilde{\mathbf{c}}) \quad (4.66)$$

donde $\mathbf{H}(\cdot)$ denota los argumentos de orden superior en una expansión en serie de Taylor, y $\mathbf{Z}$ y $\boldsymbol{\Gamma}$ se derivan de $\boldsymbol{\xi}^*(\boldsymbol{\zeta}, \sigma^*, \mathbf{c}^*)$ con respecto a $\mathbf{c}^*$ y σ^* en el punto $(\mathbf{c}, \sigma)$. Estos términos se pueden expresar como:

$$\mathbf{Z}^T = \frac{\partial \boldsymbol{\xi}^*(\boldsymbol{\zeta}, \sigma^*, \mathbf{c}^*)}{\partial \mathbf{c}^*} \quad (4.67)$$

y,

$$\mathbf{\Gamma}^T = \frac{\partial \xi^*(\zeta, \sigma^*, \mathbf{c}^*)}{\partial \sigma^*} \quad (4.68)$$

Evaluable en los puntos $\mathbf{c}^* = \mathbf{c}$ y $\sigma^* = \sigma$, produce:

$$\tilde{\xi}(\zeta, \tilde{\sigma}, \tilde{\mathbf{c}}) = \mathbf{Z}^T \tilde{\mathbf{c}} + \mathbf{\Gamma}^T \tilde{\sigma} + \mathbf{H}(\zeta, \tilde{\sigma}, \tilde{\mathbf{c}}) \quad (4.69)$$

A partir de (4.69), el término de orden superior $\mathbf{H}(\cdot)$ queda delimitado por:

$$\begin{aligned} \|\mathbf{H}(\zeta, \tilde{\sigma}, \tilde{\mathbf{c}})\| &= \|\tilde{\xi}(\zeta, \tilde{\sigma}, \tilde{\mathbf{c}}) - \mathbf{Z}^T \tilde{\mathbf{c}} - \mathbf{\Gamma}^T \tilde{\sigma}\| \leq \dots \\ &\leq \|\tilde{\xi}(\zeta, \tilde{\sigma}, \tilde{\mathbf{c}})\| + \|\mathbf{Z}^T \tilde{\mathbf{c}}\| + \|\mathbf{\Gamma}^T \tilde{\sigma}\| \leq \dots \\ &\leq b_1 + b_2 \|\tilde{\mathbf{c}}\| + b_3 \|\tilde{\sigma}\| \leq H_{max} \end{aligned} \quad (4.70)$$

donde b_1 , b_2 y b_3 son constantes debido a que las funciones gaussianas (RBF) y sus derivadas están limitadas por constantes (b_1 , b_2 y b_3). Sustituyendo (4.69) en (4.64), se obtiene:

$$\begin{aligned} \dot{\mathcal{L}} &= -K_P K_i \tilde{\theta}^2 - K_P K_i \tilde{\theta} \left[\hat{\mathbf{w}}^T \left(\mathbf{Z}^T \tilde{\mathbf{c}} + \mathbf{\Gamma}^T \tilde{\sigma} + \mathbf{H}(\cdot) \right) + \tilde{\mathbf{w}}^T \hat{\xi} + \dots \right. \\ &\quad \left. + \tilde{\varepsilon} \right] + \frac{\tilde{\mathbf{w}}^T \dot{\tilde{\mathbf{w}}}}{\alpha} + \frac{\tilde{\mathbf{c}}^T \dot{\tilde{\mathbf{c}}}}{\beta} + \frac{\tilde{\sigma}^T \dot{\tilde{\sigma}}}{\gamma} \\ &= -K_P K_i \tilde{\theta}^2 - \dots \\ &\quad K_P K_i \tilde{\theta} \left(\hat{\mathbf{w}}^T \mathbf{Z}^T \tilde{\mathbf{c}} + \hat{\mathbf{w}}^T \mathbf{\Gamma}^T \tilde{\sigma} + \hat{\mathbf{w}}^T \mathbf{H}(\cdot) + \tilde{\mathbf{w}}^T \xi + \tilde{\varepsilon} \right) + \dots \\ &\quad + \frac{\tilde{\mathbf{w}}^T \dot{\tilde{\mathbf{w}}}}{\alpha} + \frac{\tilde{\mathbf{c}}^T \dot{\tilde{\mathbf{c}}}}{\beta} + \frac{\tilde{\sigma}^T \dot{\tilde{\sigma}}}{\gamma} \end{aligned} \quad (4.71)$$

Definiendo la suma $\hat{\mathbf{w}}^T \mathbf{H}(\cdot) + \tilde{\varepsilon} = \bar{\varepsilon}$ y suponiendo que esta suma está delimitada por:

$$|\bar{\varepsilon}| \leq k \quad (4.72)$$

donde, $\bar{\varepsilon}$ representa el error de aproximación de la compensación neuronal.

Utilizando la teoría de aproximación basada en redes neuronales, el error de aproximación inherente $\bar{\varepsilon}$, puede reducirse arbitrariamente aumentando m (Haykin, 1999), de (4.52) y (4.70) por lo que es razonable suponer que

$\bar{\varepsilon}$ está limitado por una constante k . De este modo (4.71) puede reescribirse como:

$$\begin{aligned}\dot{\mathcal{L}} = & -K_P^2 K_i \tilde{\theta}^2 + \dots \\ & K_P K_i \tilde{\theta} \left(-\hat{\mathbf{w}}^T \mathbf{Z}^T \tilde{\mathbf{c}} - \hat{\mathbf{w}}^T \mathbf{\Gamma}^T \tilde{\boldsymbol{\sigma}} - \tilde{\mathbf{w}}^T \boldsymbol{\xi} - \bar{\varepsilon} \right) + \dots \\ & + \frac{\tilde{\mathbf{w}}^T \dot{\tilde{\mathbf{w}}}}{\alpha} + \frac{\tilde{\mathbf{c}}^T \dot{\tilde{\mathbf{c}}}}{\beta} + \frac{\tilde{\boldsymbol{\sigma}}^T \dot{\tilde{\boldsymbol{\sigma}}}}{\gamma}\end{aligned}\quad (4.73)$$

Agrupando y reordenando (4.73) se llega a:

$$\begin{aligned}\dot{\mathcal{L}} = & -K_P^2 K_i \tilde{\theta}^2 - \left[\frac{K_P}{K_i} \left(\tilde{\theta} \hat{\mathbf{w}}^T \mathbf{Z}^T \tilde{\mathbf{c}} - \frac{\tilde{\mathbf{c}}^T \dot{\tilde{\mathbf{c}}}}{\beta} \right) + \dots \right. \\ & + K_P K_i \left(\tilde{\theta} \hat{\mathbf{w}}^T \mathbf{\Gamma}^T \tilde{\boldsymbol{\sigma}} - \frac{\tilde{\boldsymbol{\sigma}}^T \dot{\tilde{\boldsymbol{\sigma}}}}{\gamma} \right) + \dots \\ & \left. + K_P K_i \left(\tilde{\theta} \tilde{\mathbf{w}}^T \boldsymbol{\xi} - \frac{\tilde{\mathbf{w}}^T \dot{\tilde{\mathbf{w}}}}{\alpha} \right) \right] - K_P K_i \tilde{\theta} \bar{\varepsilon}\end{aligned}\quad (4.74)$$

A partir de (4.74), es fácil demostrar que:

$$\begin{aligned}\tilde{\theta} \hat{\mathbf{w}}^T \mathbf{Z}^T \tilde{\mathbf{c}} &= \left(\tilde{\theta} \hat{\mathbf{w}}^T \mathbf{Z}^T \tilde{\mathbf{c}} \right)^T = \tilde{\mathbf{c}}^T \mathbf{Z} \hat{\mathbf{w}} \tilde{\theta} \\ \tilde{\theta} \hat{\mathbf{w}}^T \mathbf{\Gamma}^T \tilde{\boldsymbol{\sigma}} &= \left(\tilde{\theta} \hat{\mathbf{w}}^T \mathbf{\Gamma}^T \tilde{\boldsymbol{\sigma}} \right)^T = \tilde{\boldsymbol{\sigma}}^T \mathbf{\Gamma} \hat{\mathbf{w}} \tilde{\theta}\end{aligned}\quad (4.75)$$

Sustituyendo (4.75) en (4.74), se obtiene la siguiente expresión:

$$\begin{aligned}\dot{\mathcal{L}} = & -K_P^2 K_i \tilde{\theta}^2 - \left[K_P K_i \left(\tilde{\mathbf{c}}^T \mathbf{Z} \hat{\mathbf{w}} \tilde{\theta} - \frac{\tilde{\mathbf{c}}^T \dot{\tilde{\mathbf{c}}}}{\beta} \right) + \dots \right. \\ & + K_P K_i \left(\tilde{\boldsymbol{\sigma}}^T \mathbf{\Gamma} \hat{\mathbf{w}} \tilde{\theta} - \frac{\tilde{\boldsymbol{\sigma}}^T \dot{\tilde{\boldsymbol{\sigma}}}}{\gamma} \right) + \dots \\ & \left. + K_P K_i \left(\tilde{\mathbf{w}}^T \boldsymbol{\xi} \tilde{\theta} - \frac{\tilde{\mathbf{w}}^T \dot{\tilde{\mathbf{w}}}}{\alpha} \right) \right] - K_P K_i \tilde{\theta} \bar{\varepsilon}\end{aligned}\quad (4.76)$$

Tomado como término común $\tilde{\mathbf{c}}^T$, $\tilde{\boldsymbol{\sigma}}^T$ y $\tilde{\mathbf{w}}^T$ en (4.76), conduce a:

$$\begin{aligned} \dot{\mathcal{L}} = & -K_P^2 K_i \tilde{\theta}^2 - \left[K_P K_i \tilde{\mathbf{c}}^T \left(\mathbf{Z} \tilde{\mathbf{w}} \tilde{\theta} - \frac{\dot{\tilde{\mathbf{c}}}}{\beta} \right) + \dots \right. \\ & + K_P K_i \tilde{\boldsymbol{\sigma}}^T \left(\boldsymbol{\Gamma} \tilde{\mathbf{w}} \tilde{\theta} - \frac{\dot{\tilde{\boldsymbol{\sigma}}}}{\gamma} \right) + \dots \\ & \left. + K_P K_i \tilde{\mathbf{w}}^T \left(\boldsymbol{\xi} \tilde{\theta} - \frac{\dot{\tilde{\mathbf{w}}}}{\alpha} \right) \right] - K_P K_i \tilde{\theta} \bar{\varepsilon} \end{aligned} \quad (4.77)$$

Igualando a cero los términos entre paréntesis y despejando las derivadas, se obtiene:

$$\dot{\tilde{\mathbf{c}}} = \beta \mathbf{Z} \tilde{\mathbf{w}} \tilde{\theta} \quad (4.78)$$

$$\dot{\tilde{\boldsymbol{\sigma}}} = \gamma \boldsymbol{\Gamma} \tilde{\mathbf{w}} \tilde{\theta} \quad (4.79)$$

$$\dot{\tilde{\mathbf{w}}} = \alpha \boldsymbol{\xi} \tilde{\theta} \quad (4.80)$$

Se tiene que, 4.78, 4.79 y 4.80 se definen como reglas de sintonización, estas ecuaciones ajustan los parámetros neuronales para reducir el error de control. La sustitución de estas ecuaciones en (4.77) conduce a:

$$\dot{\mathcal{L}} = -K_P^2 K_i \tilde{\theta}^2 - K_P K_i \tilde{\theta} \bar{\varepsilon} \quad (4.81)$$

Para demostrar la convergencia del control propuesto, en primer lugar, es necesario demostrar que (4.81) es negativa. Por lo tanto, se debe encontrar las condiciones para que esta ecuación sea negativa. A partir de (4.72) y aplicando la norma en (4.81). Se puede obtener la siguiente expresión:

$$\dot{\mathcal{L}} \leq -K_P^2 K_i |\tilde{\theta}|^2 + K_P K_i |\tilde{\theta}| k_\varepsilon = -K_P K_i |\tilde{\theta}| \left(|\tilde{\theta}| - k_\varepsilon \right) \quad (4.82)$$

De esta forma, $\dot{\mathcal{L}} \leq 0$ siempre que:

$$|\tilde{\theta}| \geq k_\varepsilon = \psi \quad (4.83)$$

La ecuación (4.83), implica que el error de control está acotado en última instancia por el valor $\psi = k$, se puede afirmar que la técnica de control propuesta presenta una estabilidad uniformemente acotada.

Finalmente, considerando que $\tilde{\mathbf{c}} = \mathbf{c}^* - \mathbf{c}$, $\tilde{\boldsymbol{\sigma}} = \boldsymbol{\sigma}^* - \boldsymbol{\sigma}$ y $\tilde{\mathbf{w}} = \mathbf{w}^* - \mathbf{w}$, con $\dot{\mathbf{w}}^* = 0$, $\dot{\mathbf{c}}^* = 0$ y $\dot{\boldsymbol{\sigma}}^* = 0$, las leyes de sintonía se expresan como:

$$\dot{\mathbf{c}} = -\beta \mathbf{Z} \mathbf{w} \tilde{\theta} \quad (4.84)$$

$$\dot{\boldsymbol{\sigma}} = -\gamma \Gamma \mathbf{w} \tilde{\theta} \quad (4.85)$$

$$\dot{\mathbf{w}} = -\alpha \xi \tilde{\theta} \quad (4.86)$$

Estas ecuaciones se utilizan para desarrollar la compensación neuronal en línea y se utilizan para ajustar los parámetros neuronales. Se puede observar que cualquier variación del error de control produce variaciones de los parámetros neuronales para reducir este error.

La Tabla 4.10, muestra los parámetros y variables empleadas en el diseño del controlador con sus respectivas descripciones. Nótese que a algunos de ellos se les asignó la misma nomenclatura que en secciones anteriores, pero con un significado diferente.

4.3.2 Resultados

Los experimentos se realizaron en simulación y consistieron en la aplicación de riego basado en el controlador PI neuronal y PID tradicional. Se consideraron tres tipos de suelo diferentes (S1, S2, S3), existentes en la provincia de San Juan, en presencia de un cultivar. Los parámetros del suelo y del cultivo usados en la simulación se presentan en la Tabla 4.7, Tabla 4.8 y la Tabla 4.4. Los parámetros del controlador se inicializaron con el mismo valor para todos los casos y estos se ajustaron para lograr las referencias deseadas.

Las figuras 4.7, 4.8, 4.9 muestran el contenido volumétrico de agua tras aplicar el riego basado en acciones de control PI-neuronal y PID para un valor de humedad de referencia de 22 %. Donde se consideró la extracción de agua por un olivo de 5 años cuyas raíces se extienden según los parámetros detallados en la Tabla 4.13 y un valor de $K_c = 0,6$ constante durante todo el ensayo.

Se puede observar la respuesta estable del sistema en lazo cerrado para el modelo de simulación y la variación del contenido de agua en el punto de medida alrededor de la referencia dentro de los valores admisibles.

Tabla 4.6: Nomenclatura del diseño del controlador

Símbolo	Descripción
U	Esfuerzo de control
ω	Variable de integración auxiliar
K_p	Constante de proporcionalidad
K_i	Constante Integral
m	Número neuronas ocultas
w^*	Vector de pesos óptimos
ζ	Vector regresor
σ^*	Anchura de la campana de Gauss
c^*	Centros de la campana de Gauss
ε	Valor mínimo del error de aproximación de la RN
ξ	Función de activación de la RN
α	Constantes de ajuste
β	
γ	

Tabla 4.7: Propiedades texturales e hídricas

Suelo	Propiedades					
	Texturales ¹			hídricas		
	Arena	Arcilla	Limo	FC ²	WP ²	BD ³
S1	35	33	32	39.18	18.31	1.28
S2	11.4	50.2	38.4	32.4	17.2	-
S3	17	70	13	0.33	0.13	1.31

Unidades:

^a %

^b $cm^3 \cdot cm^{-3}$

^c $g \cdot cm^{-3}$

Tabla 4.8: Parámetros del modelo de suelo

	θ_r	θ_s	α	n	K_s
S1	0.0845	0.4683	0.012	1.4550	1e-3
S2	0.0949	0.4841	0.0104	1.4398	2.19e-4
S3	0.0617	0.4261	0.0046	1.7126	42.1




Figura 4.7: Respuestas de humedad ante un controlador PID tradicional y un PI neuronal. $\theta_{ref} = 22\%$. Tipo de suelo 1.




Figura 4.8: Respuestas de humedad ante un controlador PID tradicional y un PI neuronal. $\theta_{ref} = 22\%$. Tipo de suelo 2.




Figura 4.9: Respuestas de humedad ante un controlador PID tradicional y un PI neuronal. $\theta_{ref} = 22\%$. Tipo de suelo 3.

Asimismo, se puede observar que la humedad se mantiene por encima del punto de marchitez permanente, siendo los picos de mayor amplitud para el caso del PI neuronal. Por otro lado, este controlador proporciona entre un 15 % y un 20 % menos de volumen de agua que el proporcionado por el PID fijo. Además, de una menor frecuencia de activación del actuador, que en este caso es una válvula on/off.

La Tabla 4.9, proporciona una comparación entre el PI neuronal y el PID fijo, en función del número de litros de agua suministrados y del número de activaciones del elemento de control durante el periodo considerado.

Un último experimento, consistió en añadir una perturbación, correspondiente a una precipitación aleatoria en dos momentos del periodo considerado. Para esta prueba, sólo se consideró el tipo de suelo 1 para ejemplificar esta situación particular. La primera, se produce a las 40h aproximadamente, en el momento en que se produce un pico en la respuesta de humedad de un riego anterior y durante más de media hora, por lo que la amplitud de la respuesta se hace aún mayor. La segunda, se produce a las 185h aproximadamente y durante dos horas, en ausencia de riego artificial, por lo que ocurre como si se estuviera produciendo uno. Esta situación se puede observar en la Figura 4.10, donde en el primer caso se retrasa el inicio del siguiente riego y, en el segundo, no es necesario activar la válvula frente a lo que ocurre en la Figura 4.7.

Tabla 4.9: Comparación entre el controlador PI neuronal y el PID

Soil	NN PI	PID	Irrigation
S1	143.86	167.83	litros
	6	15	Activaciones
S2	170	199.8	litros
	7	17	Activaciones
S3	319.68	403.6	litros
	9	17	Activaciones




Figura 4.10: Respuesta del controlador PI neuronal ante perturbaciones aleatorias.

4.3.3 Conclusiones

Se propuso un controlador neuronal de riego basado en la compensación de un PI neuronal, que permitió dar características de adaptabilidad a este control. De esta manera, se realiza un autoajuste en tiempo real para diferentes tipos de suelo, en este caso, de la Provincia de San Juan, así como para la variabilidad temporal de los parámetros que describen el sistema agua-suelo-clima-cultivo. Se incluyó el diseño, estructura y demostración de estabilidad del controlador PI neuronal.

Las simulaciones muestran que el contenido volumétrico de agua en el punto de medida se mantuvo en todo momento alrededor de la referencia y dentro del rango de humedad útil para los tres tipos de suelo. Se añadió una lluvia aleatoria en dos momentos para probar las perturbaciones de rechazo del controlador y se puede observar una buena respuesta frente a ello.

El sistema de control PI neuronal consiguió un ahorro en la cantidad de agua aplicada de entre el 15 % y el 20 %, en comparación con el PID tradicio-

nal, para los tipos de suelo considerados. Además, la evapotranspiración diaria, teniendo en cuenta la dinámica de retención de humedad del suelo se cubrió satisfactoriamente con una baja frecuencia de accionamiento de la válvula, lo que se traduce en una mayor vida útil de la misma.

4.4 Control MPC

En un campo cultivado extenso, el suelo presenta variaciones en sus propiedades a lo largo del mismo. Asimismo, dichas variaciones pueden darse también a lo largo del tiempo debido a cambios en la composición del suelo y al crecimiento de las plantas. Por lo tanto, es necesario establecer una estructura de riego de tasa variable (VRI), identificando previamente zonas homogéneas de manejo de riego (HMZ). En este sentido, en este trabajo se propone un controlador predictivo basado en modelo (MPC) como sistema de soporte a las decisiones de riego (DSS). La gestión del riego sitio-específica mediante el empleo de técnicas de control predictivo ha dado buenos resultados en el caso de parcelas individuales (Delgoda et al., 2016a; Lozoya et al., 2016a; Lozoya et al., 2014; Shang et al., 2019). Por lo que, aquí se implementan dichas técnicas de control pero considerando la gestión simultánea de más de una zona de manejo de riego. El modelo interno del MPC se basa en la dinámica del bulbo húmedo generado debajo de un suelo sometido a riego por goteo en presencia de un cultivo. Se llevaron a cabo dos ensayos para testear el DSS. En uno de ellos, se consideraron dos HMZ y en el restante cuatro HMZ, logrando en ambos resultados satisfactorios. El DSS otorgó la suficiente cantidad de riego para mantener el contenido volumétrico de agua entre el punto de marchitamiento y de capacidad de campo, teniendo en cuenta las restricciones del sistema de irrigación.

4.4.1 Diseño del controlador

A partir de la dinámica del modelo agua-suelo-cultivo-clima, descrita en secciones anteriores, se puede predecir su comportamiento futuro y de esta manera optimizar las acciones de riego. Los MPC permiten realizar esta tarea, donde las restricciones del sistema de riego pueden incluirse como restricciones de la función de costo a minimizar. Luego, se aplica la

primera de las acciones de control optimizadas, calculada hacia delante.

El problema de gestión del riego puede formularse como un problema de optimización no lineal, cuyo objetivo es minimizar una función de costo sujeta a la dinámica del sistema, a restricciones y a límites de control. La forma genérica del problema de optimización para un sistema MIMO es:

$$\begin{aligned} \min_{\mathbf{u}(k), \dots, \mathbf{u}(k+N)} J &= \sum_{i=k}^{k+N} \mathbf{e}(i+1)^T \mathbf{R} \mathbf{e}(i+1) + \mathbf{u}(i)^T \mathbf{S} \mathbf{u}(i) \\ \text{s.to } &\begin{cases} u_b \leq u(i) \leq l_b \\ y_l \leq y(i) \leq y_u \end{cases} \end{aligned} \quad (4.87)$$

donde, $\mathbf{y} \in \mathbb{R}^p$ es el vector de salida; p es el número de salidas; $\mathbf{u} \in \mathbb{R}^m$ es el vector de variables de control; m es el número de acciones de control; N es el horizonte de predicción; $\mathbf{R} \in \mathbb{R}^{p \times p}$ es una matriz diagonal que pondera la importancia de las salidas; $\mathbf{S} \in \mathbb{R}^{m \times m}$ es una matriz diagonal que pondera la penalización sobre las entradas de control; u_b y l_b corresponden a los límites superior e inferior de la variable de control; y_l y y_u corresponden a los límites superior e inferior de la variable de salida.

El problema de optimización no lineal propuesto en (4.87), se resuelve en cada periodo de muestreo. La función de costo J , se calcula integrando el modelo interno sobre el horizonte de predicción N , tomando como condiciones iniciales el estado actual del proceso y evaluando la función de costo al final de la integración.

Implementación del MPC para la gestión de zonas de riego

Para la implementación del MPC en un campo compuesto por múltiples zonas de manejo de riego, se siguen los siguientes pasos:

1. *Zonificación*: El campo se divide en varias zonas de gestión, cada una con características distintas de suelo y cultivo. Esto permite una gestión del riego sitio-específica.
2. *Formulación*: El modelo agua-suelo-cultivo-clima descrito en los apartados anteriores se adapta a cada zona de gestión. Este modelo

incorpora la dinámica de la humedad del suelo, la absorción de agua por las raíces y factores externos como la evapotranspiración.

3. *Integración de datos*: En el marco del MPC se integran datos en tiempo real procedentes de sensores de campo (por ejemplo, sensores de humedad del suelo) y previsiones meteorológicas. Estos datos se utilizan para actualizar el modelo y mejorar la precisión de las predicciones. En este caso, la humedad del suelo se obtiene a partir del mismo modelo de simulación utilizado para el MPC.
4. *Problema de optimización*: En cada paso de control, se formula un problema de optimización para minimizar el uso de agua y, al mismo tiempo, garantizar que los niveles de humedad del suelo permanezcan dentro de los umbrales deseados para un crecimiento óptimo de los cultivos.
5. *Restricciones*: El problema de optimización incluye restricciones como:
 - *Restricciones de entrada*: Limitaciones en la cantidad de agua que se puede aplicar.
 - *Restricciones operacionales*: Disponibilidad de equipos de riego y franjas horarias para el riego.
6. *Acciones de control*: La solución del problema de optimización proporciona el plan de riego óptimo para cada zona de gestión. Este plan especifica la cantidad y el momento de aplicación del agua para alcanzar los niveles deseados de humedad del suelo.
7. *Horizonte deslizante*: Se ejecuta la primera acción de control del programa de riego óptimo y el proceso se repite en el siguiente paso temporal con mediciones y predicciones actualizadas.

Formulación del problema de control predictivo

El problema de control predictivo para el sistema de gestión del riego puede formularse como un problema de minimización de una función de costo, que incluye términos tanto para el error de control como para el esfuerzo de control. El objetivo es encontrar la secuencia de acciones de control que minimice la función de costo a lo largo del horizonte de predicción, satisfaciendo al mismo tiempo las restricciones sobre las acciones de control.

La función de costo a minimizar es:

$$\min_{\mathbf{u}(0), \dots, \mathbf{u}(N-1)} J = \sum_{i=0}^{N-1} [\delta \mathbf{e}(i+1)^T \mathbf{e}(i+1) + \lambda \mathbf{u}(i)^T \mathbf{u}(i)] \quad (4.88)$$

$$(4.89)$$

siendo,

$$\mathbf{e} = \mathbf{w} - \mathbf{y} = \begin{bmatrix} \theta_{ref}^1 \\ \theta_{ref}^2 \\ \vdots \\ \theta_{ref}^{N_p} \end{bmatrix} - \begin{bmatrix} \theta_{ij}^1 \\ \theta_{ij}^2 \\ \vdots \\ \theta_{ij}^{N_p} \end{bmatrix} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_{N_p} \end{bmatrix} \quad (4.90)$$

$$\mathbf{u} = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_{N_p} \end{bmatrix} \quad (4.91)$$

donde, $\mathbf{u} \in \mathbb{R}^{1 \times N_p}$ es el vector de acciones de control a lo largo del horizonte de predicción; es el vector de error, que representa la diferencia entre los niveles de humedad de referencia $\mathbf{w} \in \mathbb{R}^{1 \times N_p}$ y los niveles de humedad previstos $\mathbf{y} \in \mathbb{R}^{1 \times N_p}$; δ y λ son ponderaciones que equilibran la importancia del error de control y el esfuerzo de control, respectivamente; N es el horizonte de predicción.

Las restricciones sobre las acciones de control son:

$$\text{s.to.} \begin{cases} 0 \leq \mathbf{u} \leq Q_{drip} \\ u_1 + u_2 + \dots + u_{N_p} \leq Q_{drip} \end{cases} \quad (4.92)$$

donde, Q_{drip} es el caudal del gotero de riego; u_n es la n -ésima acción de control calculada por el MPC; N_p es el número de parcelas que se

gestionan. La segunda restricción está asociada al hecho de que la suma de los tiempos de encendido de las válvulas no debe superar el tiempo de muestreo, es decir:

$$T_{ON_1} + T_{ON_2} + \dots + T_{ON_{N_p}} \leq T_s \quad (4.93)$$

Mediante la aplicación de este enfoque MPC, el sistema tiene como objetivo mantener los niveles deseados de humedad del suelo al tiempo que minimiza el uso del agua y evita el exceso de riego.

A partir de la dinámica del modelo agua-suelo-cultivo-clima, descrito en secciones anteriores, se puede predecir su comportamiento futuro y optimizar las acciones de riego. Los MPC permiten realizar esta tarea, donde las restricciones del sistema de riego pueden incluirse como restricciones de la función de costo a minimizar. A continuación, se aplica la primera de las acciones de control optimizadas, calculada hacia adelante.

El esquema de control de riego se muestra en la Fig. 4.11. El bloque MPC se ejecuta cada T_s y es donde se ejecuta el algoritmo de optimización, basado en el modelo del proceso, generando las acciones de control u_n . Este mismo bloque puede actualizar los valores del modelo interno teniendo en cuenta el crecimiento de las raíces y las variables climáticas.




Figura 4.11: Estructura del control predictivo del proceso.

El segundo bloque se encarga de convertir esa acción de control real en

discreta ($V_n = \{0, 1\}$). Las acciones de control V_n no se aplican simultáneamente a cada parcela, sino una vez finalizada la anterior.

Tabla 4.10: Nomenclatura del controlador

Símbolo	Descripción	Unit
T_{on}	Ciclo útil válvula	s
T_s	Tiempo de muestreo	
Q_{drip}	Caudal del gotero	$cm^3 \cdot s^{-1}$
u	Acción de control	
V	Estado válvula	-
w	Referencia	$cm^3 \cdot cm^{-3}$
δ	Pesos del funcional	-
λ		

4.4.2 Resultados

Se llevaron a cabo dos ensayos para probar el funcionamiento del DSS-VRI mediante la metodología MPC. En uno de ellos, se tuvo en cuenta dos parcelas y en el restante cuatro parcelas de riego cultivadas. Los datos climáticos, que determinan el índice de evapotranspiración, se tomaron de condiciones reales ocurridas en campo. Recordando, que este índice es función de la demanda hídrica del cultivo, Figura 3.1. El lugar donde se llevaron a cabo dichas mediciones fue el Instituto Nacional de Tecnología Agropecuaria (INTA), situado en la provincia de San Juan.

El sistema de riego presenta algunas limitaciones. La bomba de riego, solo puede permanecer encendida durante 8-12 horas al día, para abastecer a todas las parcelas del campo. Por lo tanto, el sistema deberá tener en cuenta proporcionar la suficiente cantidad de agua hasta el inicio del siguiente periodo de riego. Además, teniendo en cuenta que las parcelas tienen válvulas independientes cada una, otra restricción es que las mismas no pueden permanecer encendidas simultáneamente. Esto para conservar la presión del sistema de regadío.

Ensayo 1

El primer ensayo, consistió de dos HMZ nombradas Zona 1 (Z_1) y Zona 2 (Z_2). En ambas parcelas, se tuvo en cuenta el mismo tipo de suelo e idénticos cultivos pero en diferentes etapas de crecimiento. De esta manera, Z_1 contiene un olivar en una primera etapa de crecimiento y Z_2 un olivar de 5 años de edad. La Tabla 4.11, resume las propiedades hídricas y texturales del suelo. A partir de dichas propiedades, se obtienen los parámetros del modelo que se presentan en la Tabla 4.12. Por último, los parámetros que definen el área radicular se exhiben en la Tabla 4.13.

Tabla 4.11: Propiedades texturales e hídricas

Suelo	Propiedades					
	Texturales ¹			Hídricas		
	Arena	Arcilla	Limo	FC ²	WP ²	BD ³
$Z_{1,2,3}$	35	33	32	0.3918	0.1831	1.28
Z_4	17	70	13	0.33	0.13	1.31

Unidades:
^a %
^b $cm^3 \cdot cm^{-3}$
^c $g \cdot cm^{-3}$

Tabla 4.12: Parametros del modelo de suelo

	θ_r	θ_s	α	n	K_s
$Z_{1,2,3}$	0.0845	0.4683	0.012	1.4550	86.4
Z_4	0.0617	0.4261	0.0046	1.7126	42.1

Los resultados de este experimento se muestran en la Figura 4.12, donde se pueden observar las acciones de control de riego propuestas por el MPC y la respuestas de humedad en el punto considerado.

Se puede observar que el controlador fue capaz de mantener el contenido volumétrico de agua dentro de la zona de capacidad de campo (θ_{FC})

Tabla 4.13: Parámetros modelo extracción

Parameters	z_m	r_m	z^*	r^*	p_z	p_r
Z_1	75	50	35	10	29.9251	0.0029
Z_2	25	15	35	10	29.9251	0.0029

y el punto de marchitamiento permanente (θ_{PMF}) para ambas HMZs. Además, se realizaron dos aplicaciones diarias de riego para atender a la premisa de restricción de uso de la bomba.

Ensayo 2

Ahora, en el siguiente ensayo se sumaron otras dos HMZ a las ya existentes, nombradas Zona 3 (Z_3) y Zona 4 (Z_4). Z_1 se tomó como parcela de referencia y, en relación a esta, se les modificó alguna característica a las restantes para lograr heterogeneidad entre las cuatro zonas. En este sentido, Z_3 se configuró con diferentes condiciones iniciales y Z_4 con otro tipo de suelo y consigna de entrada ($\theta_{ref} = 0,2$). En la Fig. 4.13, se grafican superpuestas las señales de salida de humedad volumétrica de las distintas HMZs en respuesta a las acciones de control calculadas por el MPC. Cabe destacar que, en el caso de la respuesta de humedad del suelo de Z_4 , se ve un incremento de humedad, en ausencia de riego, debida al reacomodamiento de los flujos de agua de las celdas en el vecindario de la celda considerada.

En este ensayo, al igual que en el anterior, el MPC logra mantener la humedad volumétrica dentro de la zona de capacidad de campo y punto de marchitamiento permanente en todas las parcelas. Esto, a pesar del margen de tiempo en que el sistema de control esta inactivo.

4.4.3 Conclusiones

Se implementó un MPC para determinar el volumen y momentos de riego en un campo formado por diferentes HMZ. Se consideraron dos ensayos, donde uno consistió de dos parcelas y el restante de cuatro parcelas cultivadas para riego. Ambos ensayos resultaron satisfactorios ya que




Figura 4.12: Ensayo 1. a) Respuestas de contenido de humedad a 30cm de profundidad. b) Salidas MPC. c) Accionamiento de las válvulas




Figura 4.13: Ensayo 2. a) Respuestas de contenido de humedad a 30cm de profundidad. b) Salidas MPC. c) Accionamiento de las válvulas

se logro mantener el contenido volumétrico de agua entre el punto de marchitamiento (PMP) y la capacidad de campo (FC). En este sentido, el aporte de agua fue el necesario para lograr los objetivos, a pesar de que la bomba no estaba disponible durante todas las horas del día.

El modelo interno empleado en el MPC se implemento para dos tipos de suelos y para un cultivo de olivos en diferentes etapas fenológicas. Además, el modelo permitió el ingreso de estimaciones reales del índice de ET_0 para establecer el consumo de agua de los olivares.

CONCLUSIONES Y TRABAJOS FUTUROS

En esta tesis, se describió la integración de un modelo del flujo de agua en un suelo y un modelo de absorción de agua por parte de las raíces de un cultivar. Las respuestas de simulación ante iguales eventos de riego fueron satisfactorias en relación a mediciones tomadas en campo.

Por otra parte, se diseñaron dos algoritmos de control PI para el DSS basados en redes neuronales; uno de ellos considerando una estrategia de superficies deslizantes y el otro añadiendo un término de compensación a la acción de control. Ambos controladores, se diseñan a fin de tener en cuenta la naturaleza variante tanto espacial como temporal del sistema agua-suelo-clima-cultivo. Además, se consiguen ahorros significativos del uso del agua según se desprende del análisis de los resultados de las simulaciones. En el caso del controlador PI con compensación, también se logra una baja frecuencia de activación de la válvula lo que implica una alargamiento de la vida útil del actuador.

Asimismo, se implementó un MPC como DSS-VRI para establecer un riego simultáneo de diversas HMZ's. Una vez determinadas dichas zonas, se toman las decisiones de riego, en función de los requerimientos de agua del cultivo. Las variaciones temporales del clima y del cultivo, pueden ser actualizadas a lo largo de la temporada de riego.

En trabajos futuros, se pretende examinar y aplicar métodos numéricos más eficaces para la resolución de las ecuaciones de la estructura básica del modelo de agua en un suelo cultivado, con la finalidad de reducir los tiempos de simulación del modelo. La reducción de tiempos del modelo permitirá avanzar en incluir mayor cantidad de zonas en algoritmos de control predictivo, que incluyen un modelo explícito del sistema. Es decir, avanzar hacia un esquema de n-zonas de manejo de riego.

BIBLIOGRAFÍA

- Adeyemi, O., Grove, I., Peets, S., & Norton, T. (2017). Advanced Monitoring and Management Systems for Improving Sustainability in Precision Irrigation. *Sustainability*, 9(3). <https://www.mdpi.com/2071-1050/9/3/353>
- Adeyemi, O., Grove, I., Peets, S., & Norton, T. (2018). Neural Network Modelling of Soil Moisture Content for Predictive Irrigation Scheduling. *Sensors (Basel)*, 18. <https://doi.org/10.3390/s18103408>
- Ajzernnan, M., Browerman, E., & Rozonoer, L. (1976). Image recognition: the method of potential functions. *WNT, Warszawa (in Polish)*.
- Al-Karadsheh, E, Sourell, H, & Krause, R. (2002). Precision Irrigation: new strategy irrigation water management. Witzenhausen, Germany: conference on International Agric. Res. Develop.
- Albertos, P., & Mareels, I. (2010, enero). *Feedback and Control for Everyone*. <https://doi.org/10.1007/978-3-642-03446-6>
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (2006). Crop evapotranspiration: guidelines for determining crop water requirements. *FAO Roma, Italia*, 298.
- Alocén, J. C. (2007). Manual práctico para el diseño de sistemas de minirriego. *Programa especial para la seguridad alimentaria (PESA). Edición OCTUBRE DE*.
- Annandale, J., Jovanovic, N., Campbell, G., Du Sautoy, N, & Benade, N. (2003). A two-dimensional water balance model for micro-irrigated hedgerow tree crops. *Irrigation Science*, 22, 157-170.
- 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. (2013). Drip-Irriwater: Computer software to simulate soil wetting

- patterns under surface drip irrigation. *Computers and Electronics in Agriculture*, 98, 183. <https://doi.org/10.1016/j.compag.2013.08.009>
- Armstrong, C. F., & Wilson, T. (1983). Computer model for moisture distribution in stratified soils under a trickle source. *Transactions of the ASAE*, 26(6), 1704-1709.
- Barnard, D., & Bauerle, W. (2015). Species-specific irrigation scheduling with a spatially explicit biophysical model: A comparison to substrate moisture sensing with insight into simplified physiological parameterization. *Agricultural and Forest Meteorology*, 214, 48-59.
- Basso, B., Liu, L., & Ritchie, J. T. (2016). A Comprehensive Review of the CERES-Wheat, -Maize and -Rice Models' Performances [Cited by: 89]. *Advances in Agronomy*, 136, 27 – 132. <https://doi.org/10.1016/bs.agron.2015.11.004>
- Belayneh, B. E., Lea-Cox, J. D., & Lichtenberg, E. (2013). Costs and benefits of implementing sensor-controlled irrigation in a commercial pot-in-pot container nursery. *HortTechnology*, 23(6), 760-769.
- Ben Asher, J., Bar Yosef, B., & Volinsky, R. (2013). Ground-based remote sensing system for irrigation scheduling [Special Issue: Sensing Technologies for Sustainable Agriculture]. *Biosystems Engineering*, 114(4), 444-453. <https://doi.org/https://doi.org/10.1016/j.biosystemseng.2012.09.002>
- Bennis, N., Duplaix, J., Enéa, G., Haloua, M., & Youlal, H. (2008). Greenhouse climate modelling and robust control. *Computers and electronics in agriculture*, 61(2), 96-107.
- BM. (2006). *El agua en la agricultura*. Banco Mundial. <https://www.bancomundial.org/es/topic/water-in-agriculture#1>
- Boisier, J. P., Alvarez-Garreton, C., Cordero, R. R., Damiani, A., Gallardo, L., Garreaud, R. D., Lambert, F., Ramallo, C., Rojas, M., & Rondanelli, R. (2018). Anthropogenic drying in central-southern Chile evidenced by long-term observations and climate model simulations. *Elementa: Science of the Anthropocene*, 6, 74. <https://doi.org/10.1525/elementa.328>

- Bramley, R. G. (2009). Lessons from nearly 20 years of Precision Agriculture research, development, and adoption as a guide to its appropriate application. *Crop and Pasture Science*, 60(3), 197-217.
- Brandt, A., Bresler, E., Diner, N., Ben-Asher, I., Heller, J., & Goldberg, D. (1971). INFILTRATION FROM A TRICKLE SOURCE - 1. [Cited by: 126]. *Proc Soil Sci Soc Am*, 35(5), 675 – 682. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-0015115453&partnerID=40&md5=9f261c57863502422ecb3dabfb583e96>
- Brisson, N., Mary, B., Ripoche, D., Jeuffroy, M. H., Ruget, F., Nicoullaud, B., Gate, P., Devienne-Barret, F., Antonioletti, R., Durr, C., et al. (1998). STICS: a generic model for the simulation of crops and their water and nitrogen balances. I. Theory and parameterization applied to wheat and corn. *Agronomie*, 18(5-6), 311-346.
- Broomhead, D. S., & Lowe, D. (1988). Multivariable Functional Interpolation and Adaptive Networks. *Complex Syst.*, 2. <https://api.semanticscholar.org/CorpusID:3686496>
- Camacho, E. F., & Bordons Alba, C. (2004). Control predictivo: Pasado, presente y futuro. *Revista Iberoamericana de Automática e Informática Industrial*, 1 (3), 5-28.
- Capraro, F., Patiño, D., Tosetti, S., & Schugurensky, C. Neural Network-Based Irrigation Control for Precision Agriculture. En: *En 2008 IEEE International Conference on Networking, Sensing and Control*. 2008, 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.
- Chappell, M., Dove, S. K., van Iersel, M. W., Thomas, P. A., & Ruter, J. (2013). Implementation of wireless sensor networks for irrigation control in three container nurseries. *HortTechnology*, 23(6), 747-753.
- Chen, S., Mulgrew, B., & Grant, P. M. (1993). A clustering technique for digital communications channel equalization using radial basis function networks. *IEEE Transactions on neural networks*, 4(4), 570-590.

- Chng, E., Chen, S., & Mulgrew, B. (1996). Gradient radial basis function networks for nonlinear and nonstationary time series prediction. *IEEE transactions on neural networks*, 7(1), 190-194.
- 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. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85069512311&partnerID=40&md5=80dc2d039a797e791c3114355bcde329>
- Clausnitzer, V., & Hopmans, J. (1994). Simultaneous modeling of transient three-dimensional root growth and soil water flow. *Plant and soil*, 164, 299-314.
- Coates, R. W., & Delwiche, M. J. Site-specific water and chemical application by wireless valve controller network. En: *En 2008 Providence, Rhode Island, June 29–July 2, 2008*. American Society of Agricultural y Biological Engineers. 2008, 1.
- Cook, F. J., Fitch, P., Thorburn, P. J., Charlesworth, P. B., & Bristow, K. L. (2006). Modelling trickle irrigation: comparison of analytical and numerical models for estimation of wetting front position with time. *Environmental Modelling & Software*, 21(9), 1353-1359.
- Cook, F. J., Thorburn, P. J., Fitch, P., & Bristow, K. L. (2003). WetUp: a software tool to display approximate wetting patterns from drippers. *Irrigation Science*, 22(3-4), 129-134.
- Cybenko, G. V. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, 2, 303-314.
- Dabach, S., Lazarovitch, N., Šimůnek, J., & Shani, U. (2013). Numerical investigation of irrigation scheduling based on soil water status. *Irrigation Science*, 31, 27-36.
- Delgoda, D., Malano, H., Saleem, S. K., & Halgamuge, M. N. (2016a). Irrigation control based on model predictive control (MPC): Formulation of theory and validation using weather forecast data and AQUACROP model. *Environmental Modelling and Software*, 78, 40 -53. <http://www.sciencedirect.com/science/article/pii/S1364815215301262>

- Delgoda, D., Saleem, S. K., Malano, H., & Halgamuge, M. N. (2016b). Root zone soil moisture prediction models based on system identification: Formulation of the theory and validation using field and AQUACROP data. *Agricultural Water Management*, 163, 344 -353.
- Doussan, C., Pagès, L., & Vercambre, G. (1998). Modelling of the hydraulic architecture of root systems: an integrated approach to water absorption—model description. *Annals of botany*, 81(2), 213-223.
- Duch, W., & Jankowski, N. Survey of Neural Transfer Functions. En: 1999. <https://api.semanticscholar.org/CorpusID:2585025>
- Edwards, C., & Spurgeon, S. (1998). *Sliding Mode Control: Theory And Applications*. Taylor & Francis. <https://books.google.com.ar/books?id=uH2RJhIPsiYC>
- Elnesr, M., & Alazba, P. (2017). Simulation of water distribution under surface dripper using artificial neural networks. *Computers and Electronics in Agriculture*, 143, 90-99.
- Erdem, Y., Arin, L., Erdem, T., Polat, S., Deveci, M., Okursoy, H., & Gültaş, H. T. (2010). Crop water stress index for assessing irrigation scheduling of drip irrigated broccoli (Brassica oleracea L. var. italica). *Agricultural Water Management*, 98(1), 148-156.
- Erdem, Y., Erdem, T., Orta, A. H., & Okursoy, H. (2005). Irrigation scheduling for watermelon with crop water stress index (CWSI). *Journal of Central European Agriculture*, 6(4), 449-460.
- Evett, S. R., O'Shaughnessy, S. A., Andrade, M. A., Colaizzi, P. D., Schwartz, R. C., Schomberg, H. S., Stone, K. C., Vories, E. D., & Sui, R. (2020). Theory and development of a VRI decision support system: The USDA-ARS ISSCADA Approach. *Transactions of the ASABE*, 63(5), 1507-1519.
- Fabri, S., & Kadirkamanathan, V. (1996). Dynamic structure neural networks for stable adaptive control of nonlinear systems. *IEEE transactions on neural networks*, 7(5), 1151-1167.
- Falloon, P., & Betts, R. (2010). Climate impacts on European agriculture and water management in the context of adaptation and mitigation-The importance of an integrated approach [cited By 250]. *Science of*

- the Total Environment*, 408(23), 5667-5687. <https://doi.org/10.1016/j.scitotenv.2009.05.002>
- FAO. (2015). AQUASTAT Perfil de País - Argentina. Organización de las Naciones Unidas para la Alimentación y la Agricultura. <http://www.fao.org/aquastat/es/countries-and-basins/country-profiles/country/ARG>
- FAO. (2016). AQUASTAT Base de datos. Organización de las Naciones Unidas para la Alimentación y la Agricultura. <http://www.fao.org/nr/aquastat>
- Feddes, R., & Raats, P. (2004). Parameterizing the soil - water - plant root system. En R. Feddes, G. de Rooij & J. van Dam (Eds.), *Unsaturated-zone modeling; Progress, challenges and applications* (pp. 95-141). Kluwer Academic Publishers.
- Feddes, R., Hoff, H., Bruen, M., Dawson, T., De Rosnay, P., Dirmeyer, P., Jackson, R., Kabat, P., Kleidon, A., Lilly, A., & Pitman, A. (2001). Modeling root water uptake in hydrological and climate models. *Bulletin - American Meteorological Society*, 82(12), 2797-2809.
- Ghali, G. S. (1986). *Mathematical modelling of soil moisture dynamics in trickle irrigated fields* (Tesis doctoral). University of Southampton.
- Glória, A., Cardoso, J., & Sebastião, P. (2021). Sustainable Irrigation System for Farming Supported by Machine Learning and Real-Time Sensor Data. *Sensors*, 21(9). <https://doi.org/10.3390/s21093079>
- González Perea, R, Daccache, A., Rodríguez Díaz, J., Camacho Poyato, E, & Knox, J. W. (2018). Modelling impacts of precision irrigation on crop yield and in-field water management. *Precision Agriculture*, 19, 497-512.
- Goumopoulos, C., O'Flynn, B., & Kameas, A. (2014). Automated zone-specific irrigation with wireless sensor/actuator network and adaptable decision support [Cited by: 78]. *Computers and Electronics in Agriculture*, 105, 20 – 33.
- Hayhoe, H., & De Jong, R. (1988). Comparison of two soil water models for soybeans. *Can. Agric. Eng.*, 30, 5-11.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*.

- Hedley, C. B., & Yule, I. J. (2009). Soil water status mapping and two variable-rate irrigation scenarios. *Precision Agriculture*, 10(4), 342-355.
- Hoogenboom, G, Porter, C., Boote, K., Shelia, V, Wilkens, P., Singh, U, White, J., Asseng, S, Lizaso, J., Moreno, L., et al. (2019). Advances in crop modeling for a sustainable agriculture. *The DSSAT Crop Modeling Ecosystem*, 173-216.
- Hoogland, J., Feddes, R. A., & Belmans, C. Root water uptake model depending on soil water pressure head and maximum extraction rate. En: *En III International Symposium on Water supply and Irrigation in the open and under Protected Cultivation* 119. 1981, 123-136.
- Hu, G., & You, F. (2022). Renewable energy-powered semi-closed greenhouse for sustainable crop production using model predictive control and machine learning for energy management. *Renewable and Sustainable Energy Reviews*, 168, 112790. <https://doi.org/https://doi.org/10.1016/j.rser.2022.112790>
- 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.
- Hunt, K. J., Haas, R., & Murray-Smith, R. (1996). Extending the functional equivalence of radial basis function networks and fuzzy inference systems. *IEEE Transactions on Neural Networks*, 7(3), 776-781.
- INDEC. (2023). Censo Nacional Agropecuario 2018: resultados preliminares. Buenos Aires: INDEC.
- Jaramillo J., D. F. (2012). Spatial variability of soil: basis for its study. *Revista de la Facultad de Ciencias*, 1(1), 73-87.
- Jarvis, N. (1989). A simple empirical model of root water uptake. *Journal of Hydrology*, 107(1-4), 57-72.
- Jones, C. A., Kiniry, J. R., & Dyke, P. (1986). CERES-Maize: A simulation model of maize growth and development.
- Jones, J., Hoogenboom, G, Porter, C., Boote, K., Batchelor, W., Hunt, L., Wilkens, P., Singh, U, Gijsman, A., & Ritchie, J. (2003). The DSSAT cropping system model [Modelling Cropping Systems: Science, Software

- and Applications]. *European Journal of Agronomy*, 18(3), 235-265.
[https://doi.org/https://doi.org/10.1016/S1161-0301\(02\)00107-7](https://doi.org/https://doi.org/10.1016/S1161-0301(02)00107-7)
- Karasekreter, N., Başçiftçi, F., & Fidan, U. (2013). A new suggestion for an irrigation schedule with an artificial neural network. *Journal of Experimental and Theoretical Artificial Intelligence*, 25(1), 93-104.
<https://doi.org/10.1080/0952813X.2012.680071>
- Karimi, B., Mohammadi, P., Sanikhani, H., Salih, S. Q., & Yaseen, Z. M. (2020). Modeling wetted areas of moisture bulb for drip irrigation systems: An enhanced empirical model and artificial neural network. *Computers and Electronics in Agriculture*, 178, 105767. <https://doi.org/https://doi.org/10.1016/j.compag.2020.105767>
- Khosla, R., Westfall, D. G., Reich, R. M., Mahal, J. S., & Gangloff, W. J. (2010). Spatial Variation and Site-Specific Management Zones. En M. Oliver (Ed.), *Geostatistical Applications for Precision Agriculture* (pp. 195-219). Springer Netherlands.
- Kohanbash, D., Kantor, G., Martin, T., & Crawford, L. (2013). Wireless Sensor Network Design for Monitoring and Irrigation Control: User-centric Hardware and Software Development. *HortTechnology*, 23(6), 725-734.
- Krzyzak, A., Linder, T., & Lugosi, C. (1996). Nonparametric estimation and classification using radial basis function nets and empirical risk minimization. *IEEE Transactions on Neural Networks*, 7(2), 475-487.
- Lafolie, F., Guennelon, R., & Van Genuchten, M. T. (1989). Analysis of water flow under trickle irrigation: I. Theory and numerical solution. *Soil Science Society of America Journal*, 53(5), 1310-1318.
- Lee, W., Alchanatis, V., Yang, C., Hirafuji, M., Moshou, D., & Li, C. (2010). Sensing technologies for precision specialty crop production. *Computers and Electronics in Agriculture*, 74(1), 2 -33.
- Li, K. Y., Boisvert, J. B., & Jong, R. D. (1999). An exponential root-water-uptake model. *Canadian Journal of Soil Science*, 79(2), 333-343. <https://doi.org/10.4141/S98-032>
- Li, K., De Jong, R., & Boisvert, J. (2001). An exponential root-water-uptake model with water stress compensation. *Journal of hydrology*, 252(1-4), 189-204.

- Li, K., De Jong, R., Coe, M., & Ramankutty, N. (2006). Root-water-uptake based upon a new water stress reduction and an asymptotic root distribution function. *Earth Interactions*, 10(14), 1-22.
- Li, X., Zhao, W., Li, J., & Li, Y. (2022). Field study on the benefits of the variable rate irrigation strategies for a center pivot system; [Cited by: 2]. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 38(21), 60 – 66. <https://doi.org/10.11975/j.issn.1002-6819.2022.21.008>
- Linker, R. (2021). Model-based optimal delineation of drip irrigation management zones. *Precision Agriculture*, 22(1), 287-305.
- Liu, H., Yang, H., Zheng, J., Jia, D., Wang, J., Li, Y., & Huang, G. (2012). Irrigation scheduling strategies based on soil matric potential on yield and fruit quality of mulched-drip irrigated chili pepper in Northwest China. *Agricultural water management*, 115, 232-241.
- Lozoya, C., Mendoza, C., Aguilar, A., Román, A., Castelló, R., et al. (2016a). Sensor-based model driven control strategy for precision irrigation. *Journal of Sensors*, 2016.
- Lozoya, C., Mendoza, C., Aguilar, A., Roman-Flores, A., & Castello, R. (2016b). Sensor-Based Model Driven Control Strategy for Precision Irrigation. *Journal of Sensors*, 2016, 1-12. <https://doi.org/10.1155/2016/9784071>
- Lozoya, C., Mendoza, C., Mejía, L., Quintana, J., Mendoza, G., Bustillos, M., Arras, O., & Solis, L. (2014). Model Predictive Control for Closed-Loop Irrigation [19th IFAC World Congress]. *IFAC Proceedings Volumes*, 47(3), 4429 -4434.
- Luo, W., Karim, M., Morris, A., & Martin, E. (1996). Control relevant identification of a pH waste water neutralisation process using adaptive radial basis function networks. *Computers & chemical engineering*, 20, S1017-S1022.
- Lyu, L., Caballero, J. M., & Juanatas, R. A. Design of Irrigation Control System for Vineyard Based on LoRa Wireless Communication and Dynamic Neural Network. En: *En 2022 7th International Conference on Business and Industrial Research (ICBIR)*. 2022, 373-378. <https://doi.org/10.1109/ICBIR54589.2022.9786439>.

- Mareels, I., Weyer, E., Ooi, S. K., Cantoni, M., Li, Y., & Nair, G. (2005). Systems engineering for irrigation systems: Successes and challenges. *IFAC Proceedings Volumes*, 38(1), 1-16.
- McCarthy, A. C., Hancock, N. H., & Raine, S. R. (2010). VARIwise: A general-purpose adaptive control simulation framework for spatially and temporally varied irrigation at sub-field scale. *Computers and Electronics in Agriculture*, 70(1), 117 -128. <http://www.sciencedirect.com/science/article/pii/S0168169909002026>
- McCarthy, A. C., Hancock, N. H., & Raine, S. R. (2013). Advanced process control of irrigation: the current state and an analysis to aid future development. *Irrigation Science*, 31(3), 183-192. <https://doi.org/10.1007/s00271-011-0313-1>
- McCarthy, A. C., Hancock, N. H., & Raine, S. R. (2014). Development and simulation of sensor-based irrigation control strategies for cotton using the VARIwise simulation framework. *Computers and electronics in agriculture*, 101, 148-162.
- Medlyn, B., et al. (2004). A maestro retrospective. *Forests at the land-atmosphere interface*, 105-122.
- Mendez, A. A., Velez, J. P., Villarroel, D. D., & Scaramuzza, F. M. (2014). Evolución de la Agricultura de Precisión en Argentina en los últimos 15 años. *Red Agricultura de Precisión*.
- Micchelli, C. A. (1986). Interpolation of scattered data: Distance matrices and conditionally positive definite functions. *Constructive Approximation*, 2, 11-22. <https://api.semanticscholar.org/CorpusID:14461054>
- M.K, H., S.S., C., & S.K, A. (2012). Application of Artificial Neural Network in Predicting Farmers' Response to Water Management Decisions on Wheat Yield. *Journal of Agricultural Engineering*, 49, 32-40.
- Modina, D., Bianchi, D., Ortuani, B., Mayer, A., Spadaccini, R., & Brancadoro, L. (2021). *Variable rate irrigation in a vineyard and an orchard* (Vol. 1314).
- Molz, F. J. (1981). Models of water transport in the soil-plant system: A review. *Water resources research*, 17(5), 1245-1260.
- Monaghan, J. M., Daccache, A., Vickers, L. H., Hess, T. M., Weatherhead, E. K., Grove, I. G., & Knox, J. W. (2013). More 'crop per drop': cons-

- straints and opportunities for precision irrigation in European agriculture. *Journal of the Science of Food and Agriculture*, 93(5), 977-980.
- Moody, J., & Darken, C. J. (1989). Fast learning in networks of locally-tuned processing units. *Neural computation*, 1(2), 281-294.
- Musters, P., & Bouten, W. (1999). Assessing rooting depths of an Austrian pine stand by inverse modeling soil water content maps. *Water Resources Research*, 35(10), 3041-3048.
- Musters, P. A. D., et al. (1998). Temporal and Spatial Patterns of Root Water Uptake in an Austrian Pine Stand on Sandy Soil.
- Nobel, P. S., & Alm, D. M. (1993). Root orientation vs water uptake simulated for monocotyledonous and dicotyledonous desert succulents by a root-segment model. *Functional Ecology*, 7, 600-609. <https://api.semanticscholar.org/CorpusID:88441527>
- Ooi, S. K., Mareels, I., Cooley, N., Dunn, G., & Thoms, G. (2008). A Systems Engineering Approach to Viticulture On-Farm Irrigation [17th IFAC World Congress]. *IFAC Proceedings Volumes*, 41(2), 9569 -9574.
- Ortuani, B., Facchi, A., Mayer, A., Bianchi, D., Bianchi, A., & Brancadoro, L. (2019). Assessing the effectiveness of variable-rate drip irrigation on water use efficiency in a Vineyard in Northern Italy. *Water*, 11(10), 1964.
- O'Shaughnessy, S. A., Evett, S. R., Colaizzi, P. D., & Howell, T. A. (2012). A crop water stress index and time threshold for automatic irrigation scheduling of grain sorghum. *Agricultural water management*, 107, 122-132.
- Pagès, L., Jordan, M.-O., & Picard, D. (1989). A simulation model of the three-dimensional architecture of the maize root system. *Plant and Soil*, 119, 147-154. <https://api.semanticscholar.org/CorpusID:44925154>
- Pandey, V., Pandey, P. K., et al. (2010). Spatial and temporal variability of soil moisture. *International Journal of Geosciences*, 1(02), 87.
- Park, J., & Sandberg, I. W. (1993). Approximation and radial-basis-function networks. *Neural computation*, 5(2), 305-316.
- Pazouki, E. (2023). Optimizing an irrigation treatment using an evolutionary algorithm and a knowledge discovery framework based on Deep

- models. *Applied Soft Computing*, 133, 109940. <https://doi.org/https://doi.org/10.1016/j.asoc.2022.109940>
- Personne, E., Perrier, A., & Tuzet, A. (2003). Simulating water uptake in the root zone with a microscopic-scale model of root extraction. *Agronomie*, 23(2), 153-168.
- Philip, J. (1984). Travel times from buried and surface infiltration point sources. *Water resources research*, 20(7), 990-994.
- Pierce, F. (2010). Precision irrigation. *Landbauforsch SH*, 340, 45-56.
- Powell, M. J. D. Radial basis functions for multivariable interpolation: a review. En: 1987. <https://api.semanticscholar.org/CorpusID:118224933>
- Prado Hernández, J., Rivas, M., Lezama, A., Carrillo, M., Peña, V. M., Valenzuela, H., & Paz, O. Modelo empírico del patrón de humedad en un suelo orgánico de México con riego por goteo superficial. En: 2017, octubre.
- Prasad, R. (1988). A linear root water uptake model. *Journal of Hydrology*, 99(3-4), 297-306.
- Raats, P. (1974). Steady flows of water and salt in uniform soil profiles with plant roots. *Soil Science Society of America Journal*, 38(5), 717-722.
- Raats, P. A. (1971). Steady infiltration from point sources, cavities, and basins. *Soil Science Society of America Journal*, 35(5), 689-694.
- Raes, D., Steduto, P., Hsiao, T., & Fereres, E. (2012). AquaCrop, Version 4. *Reference Manual*, 130.
- Raine, S. R., Meyer, W. S., Rassam, D. W., Hutson, J. L., & Cook, F. J. (2007). Soil water and solute movement under precision irrigation: knowledge gaps for managing sustainable root zones. *Irrigation Science*, 26, 91-100.
- 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).
- Revol, P., Clothier, B., Mailhol, J.-C., Vachaud, G., & Vauclin, M. (1997). Infiltration from a surface point source and drip irrigation: 2. An approximate time-dependent solution for wet-front position. *Water Resources Research*, 33(8), 1869-1874.

- Richards, L. A. (1931). Capillary conduction of liquids through porous mediums. *physics*, 1(5), 318-333.
- Rodríguez Díaz, J., Weatherhead, E., Knox, J., & Camacho, E. (2007). Climate change impacts on irrigation water requirements in the Guadalquivir river basin in Spain [cited By 203]. *Regional Environmental Change*, 7(3), 149-159. <https://doi.org/10.1007/s10113-007-0035-3>
- Rojas, F. (2021). Dimensiones sociales y territoriales de las sequías en San Juan (siglos XVIII-XXI): una propuesta de periodización. *Punto sur*, (5). <https://doi.org/10.34096/ps.n5.11000>
- Rossomando, F., Soria, C., & Carelli, R. (2014). Sliding Mode Neuro Adaptive Control in Trajectory Tracking for Mobile Robots. *Journal of Intelligent & Robotic Systems*, 74. <https://doi.org/10.1007/s10846-013-9843-5>
- Saavoss, M., Majsztrik, J., Belayneh, B., Lea-Cox, J., & Lichtenberg, E. (2016). Yield, quality and profitability of sensor-controlled irrigation: A case study of snapdragon (*Antirrhinum majus* L.) production. *Irrigation science*, 34, 409-420.
- Sahbani, F., & Ferjani, E. (2018). Identification and Modelling of drop by drop Irrigation System for Tomato Plants Under Greenhouse Conditions. *Irrigation and Drainage*, 67.
- Saleem, S. K., Delgoda, D. K., Ooi, S. K., Dassanayake, K. B., Liu, L., Halgamuge, M. N., & Malano, H. (2013). Model Predictive Control for Real-Time Irrigation Scheduling [4th IFAC Conference on Modelling and Control in Agriculture, Horticulture and Post Harvest Industry]. *IFAC Proceedings Volumes*, 46(18), 299 -304. <http://www.sciencedirect.com/science/article/pii/S1474667015350011>
- Schaap, M., Leij, F., & Van Genuchten, M. (2001). ROSETTA: A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *Journal of Hydrology*, 251, 163-176. [https://doi.org/10.1016/S0022-1694\(01\)00466-8](https://doi.org/10.1016/S0022-1694(01)00466-8)
- Serrano, J., Shahidian, S., Marques da Silva, J., Paixão, L., Moral, F., Carmona-Cabezas, R., Garcia, S., Palha, J., & Noéme, J. (2020). Mapping Management Zones Based on Soil Apparent Electrical Conductivity and Remote Sensing for Implementation of Variable Rate

- Irrigation—Case Study of Corn under a Center Pivot. *Water*, 12(12). <https://doi.org/10.3390/w12123427>
- Shang, C., Chen, W.-H., Stroock, A. D., & You, F. (2019). Robust model predictive control of irrigation systems with active uncertainty learning and data analytics. *IEEE transactions on control systems technology*, 28(4), 1493-1504.
- Simunek, J., Sejna, M., & Van Genuchten, M. (2006). The HYDRUS Software Package for Simulating Two-and Three-Dimensional Movement of Water, Heat, and Multiple Solutes in Variably-Saturated Media, User Manual, Version 1.0. *University of California-Riverside Research Reports*.
- Slotine, J., Slotine, J., & Li, W. (1991). *Applied Nonlinear Control*. Prentice Hall. <https://books.google.com.ar/books?id=cwpRAAAAMAAJ>
- Smith, R. J., Baillie, J. N., McCarthy, A. C., Raine, S. R., & Baillie, C. P. (2010). *Review of precision irrigation technologies and their application* (inf. téc.). University of Southern Queensland, National Centre for Engineering in Agriculture. <http://eprints.usq.edu.au/id/eprint/23261>
- Smith, R., & Baillie, J. Defining precision irrigation: A new approach to irrigation management. En: *En Irrigation Australia 2009: Irrigation Australia Irrigation and Drainage Conference: Proceedings*. University of Southern Queensland. 2009.
- Spitters, C., Van Keulen, H., & Van Kraalingen, D. A simple and universal crop growth simulator: SUCROS87. En: *En Simulation and systems management in crop protection*. Pudoc, 1989, pp. 147-181.
- Steudle, E. (1994). Water transport across roots. *Plant and soil*, 167, 79-90.
- Strumillo, P. (2001). Matching pursuit of basis in two-layer neural networks for signal approximation. *Int. J. Comput. Syst. Signals*, 2(1), 43-53.
- Strumillo, P., & Kaminski, W. Neural Networks with Orthogonalised Transfer Functions. En: 2001, enero, 95-100.
- Strumillo, P., & Kamiński, W. Radial basis function neural networks: theory and applications. En: *En Neural Networks and Soft Computing: Proceedings of the Sixth International Conference on Neural Networks and*

- Soft Computing, Zakopane, Poland, June 11–15, 2002*. Springer. 2003, 107-119.
- Strumillo, P., & Kamiński, W. Radial basis function neural networks: theory and applications. En: *En Neural Networks and Soft Computing: Proceedings of the Sixth International Conference on Neural Networks and Soft Computing, Zakopane, Poland, June 11–15, 2002*. Springer. 2003, 107-119.
- Taghavi, S. A., Mariño, M. A., & Rolston, D. E. (1984). Infiltration from trickle irrigation source. *Journal of Irrigation and Drainage Engineering*, 110(4), 331-341.
- Thakur, A., Aggarwal, P., Dubey, A. K., Abdelgawad, A., & Rocha, A. (2023). Design of decision model for sensitive crop irrigation system. *Expert Systems*, 40(1), e13119. <https://doi.org/https://doi.org/10.1111/exsy.13119>
- Tiktak, A., & Bouten, W. (1992). Modelling soil water dynamics in a forested ecosystem. III: Model description and evaluation of discretization. *Hydrological Processes*, 6(4), 455-465.
- Utkin, V. I. (1992). Sliding modes in optimization and control problems.
- van Dam, J., Huygen, J., Wesseling, J., Feddes, R., Kabat, P., van Walsum, P., Groenendijk, P., & van Diepen, C. (1997). *Theory of SWAP version 2.0; simulation of water flow, solute transport and plant growth in the soil-water-atmosphere-plant environment* [Technical document / DLO Winand Staring Centre (ISSN 0928-0944 ; 45)]. Winand Staring Centre.
- Van der Ploeg, R., & Benecke, P. (1974). Unsteady, Unsaturated, n-Dimensional Moisture Flow in Soil: A Computer Simulation Program. *Soil Science Society of America Journal*, 38(6), 881-885.
- Van Genuchten, M. T. (1980). A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. *Soil science society of America journal*, 44(5), 892-898.
- Vellidis, G., Tucker, M., Perry, C., Kvien, C., & Bednarz, C. (2008). A real-time wireless smart sensor array for scheduling irrigation. *Computers and electronics in agriculture*, 61(1), 44-50.

- Vigo García, Á. d. (2020). *Simulación del flujo del agua en el suelo en riego por goteo superficial, soluciones analíticas aproximadas, caracterización del suelo y diseño de los riegos* [No Publicado], Agronomica. <https://doi.org/10.20868/UPM.thesis.63840>
- Vita Serman, F., Capraro, F., Tosetti, S., Cornejo, V., Carelli, A., & Ceci, L. INTELLIGENT IRRIGATION CONTROL IN OLIVE GROVES (OLEA EUROPEA L.): A NOVEL APPROACH FOR WATER RESOURCE OPTIMIZATION. En: *Acta Hort.* 2012, 343 -350. <https://doi.org/https://doi.org/10.17660/ActaHortic.2012.949.50>.
- Vrugt, J., Hopmans, J., & Simunek, J., Jiri. (2001). Calibration of a Two-Dimensional Root Water Uptake Model. *Fluid Phase Equilibria*, 65, 1027-1037. <https://doi.org/10.2136/sssaj2001.6541027x>
- Wang, Y., & Jarvis, P. (1990). Description and validation of an array model - MAESTRO [Cited by: 346]. *Agricultural and Forest Meteorology*, 51(3-4), 257 – 280. [https://doi.org/10.1016/0168-1923\(90\)90112-J](https://doi.org/10.1016/0168-1923(90)90112-J)
- Warrick, A. W. (1974). Time-dependent linearized infiltration. I. Point sources. *Soil Science Society of America Journal*, 38(3), 383-386.
- Warrick, A. W. (2003). *Soil water dynamics*. Oxford University Press.
- Whisler, F., Klute, A., & Millington, R. (1968). Analysis of steady-state evapotranspiration from a soil column. *Soil science society of America journal*, 32(2), 167-174.
- Whitehead, B. A., & Choate, T. D. (1996). Cooperative-competitive genetic evolution of radial basis function centers and widths for time series prediction. *IEEE transactions on neural networks*, 7(4), 869-880.
- Woo, D. K., Riley, W. J., Grant, R. F., & Wu, Y. (2022). Site-specific field management adaptation is key to feeding the world in the 21st century. *Agricultural and Forest Meteorology*, 327. <https://doi.org/10.1016/j.agrformet.2022.109230>
- Yahyaoui, I., Tadeo, F., & Segatto, M. V. (2017). Energy and water management for drip-irrigation of tomatoes in a semi- arid district [Special Issue: Advances on ICTs for Water Management in Agriculture]. *Agricultural Water Management*, 183, 4 -15. <http://www.sciencedirect.com/science/article/pii/S0378377416302876>

- Yingwei, L., Sundararajan, N., & Saratchandran, P. (1998). Performance evaluation of a sequential minimal radial basis function (RBF) neural network learning algorithm. *IEEE Transactions on neural networks*, 9(2), 308-318.

