

AQUIFER PROJECT: “Innovative instruments for an integrated management of groundwater in a context of an increasing scarcity of hydrological resources”

INFORME DE APLICACIÓN DE OOBN PARA EL ANÁLISIS COSTE/BENEFICIO DE LAS SOLUCIONES INNOVADORAS IMPLEMENTADAS

(OOBN application report for the cost/benefit analysis of the innovative solutions implemented)

Date: 14-11-2022



CSIC
CONSEJO SUPERIOR DE INVESTIGACIONES CIENTÍFICAS

IGME
INSTITUTO GEOLOGICO Y MINERO ESPAÑOL

El presente estudio has sido realizado en el marco del proyecto Interreg-Sudoe AQUIFER, liderado por el CN IGME-CSIC (Instituto Geológico y Minero de España), con la participación de los socios CUADLL (Comunitat d'usuaris d'aigua de la vall baixa i delta del Llobregat), CWP (Catalan Water Partnership), CRCC (Comunidad de Regantes del Campo de Cartagena), BRGM (Bureau de Recherches Géologiques et Minières), Aqua-Valley, ISA-LEAF (Instituto Superior de Agronomía de la Universidad de Lisboa), AR (Águas do Ribatejo), y PPA (Associação Parceria Portuguesa para a Água).

Este documento ha sido desarrollado bajo la dirección de Dr. José Luis García Aróstegui, científico titular del CN IGME-CSIC y responsable del proyecto, con el apoyo de Dra. Virginia María Robles Arenas, a fecha 14/11/2022.

El informe ha sido elaborado por Dr. José Luis Molina González, profesor titular de Universidad (Área de Ingeniería Hidráulica), y Director Grupo de Investigación "Ingeniería y Gestión del Agua (IGA)" del Dpto. Ingeniería Cartográfica y del Terreno (EPS-Ávila, Universidad de Salamanca), en el marco de un contrato establecido entre el IGME y la Universidad de Salamanca.

Síntesis

El proyecto Interreg Sudoe AQUIFER titulado "Herramientas innovadoras para la integración de las aguas subterráneas en un contexto de creciente escasez de recursos hídricos", es un proyecto financiado por el Fondo Europeo de Desarrollo Regional (FEDER) en el marco del programa Interreg SUDOE V (2014-2020). Su principal objetivo es capitalizar, probar, difundir y transferir prácticas innovadoras para la preservación, el seguimiento y la gestión integrada de los acuíferos que sean útiles a la hora de tomar decisiones sobre la gestión de los recursos hídricos subterráneos. Para lograr este objetivo, el proyecto se divide en 4 grupos de tareas específicas, en concreto, el presente documento responde al entregable de la actividad denominada "Análisis coste/beneficio en términos socioeconómicos y ambientales de las soluciones implementadas".

En este trabajo se ha realizado una modelización con un enfoque dual, aunque compartido con respecto a la misma técnica y algoritmo probabilístico basado en el Teorema de Bayes. El primer tipo de modelización se trata de modelización predictiva causal. En este primer paquete de trabajos se ha puesto el foco en el detalle sobre la relación de dependencia existente entre el comportamiento temporal de la lluvia y la evolución del nivel piezométrico en puntos previamente seleccionados. El resultado de este trabajo es el desarrollo de una herramienta llamada "AquiferLevel_PredicT". Posteriormente, en el segundo enfoque, se ha hecho un desarrollo de Sistemas de Apoyo a la Decisión (SAD) basados en Redes Bayesianas Orientadas a Objetos (OOBNs) en los cuatro casos de estudio. Después, una vez simulados los escenarios de gestión planteados, se ha realizado el análisis del coste y la efectividad de las soluciones previstas mediante la modelización probabilística gráfica previamente desarrollada. Se ha realizado un SAD en detalle para el caso de estudio del Campo de Cartagena con el que se han obtenido resultados tangibles muy útiles para la gestión del acuífero. Por otro lado, se han diseñado las estructuras de los SAD y se han hecho simulaciones cualitativas para los otros tres casos de estudio.

En dichas soluciones han intervenido los aspectos hidrológicos, socioeconómicos y ambientales. Dos de las soluciones previstas (modelización hidrogeológica distribuida y herramientas de predicción de niveles piezométricos) se centran en aspectos de gestión de las aguas subterráneas, y por ello implican medidas de gobernanza del agua. Por otro lado,

las soluciones basadas en la entrada de recursos no convencionales, como desalinización, recarga artificial y las prácticas agrícolas innovadoras, requerirán conocer en detalle los costes económicos en futuros avances.

Teniendo en cuenta la multitud de factores intervinientes, las relaciones complejas y la estructura repetitiva, el empleo de técnicas probabilísticas novedosas y modulares como los “Sistemas de redes bayesianas orientadas a objetos” (Object-Oriented Bayesian Networks, OOBN), han permitido que se hayan diseñado de forma similar para cada uno de los cuatro sitios piloto (Campo de Cartagena, Llobregat, Adour-Garona y Ribatejo). No obstante, para el caso del Campo de Cartagena el estudio ha sido de mucho más detalle.

Las OOBNs cumplen con los requisitos de la DMA como una herramienta simple, participativa e integradora. Se han considerado escenarios de no intervención, intervención parcial e intervención total. Esta metodología puede ser extrapolable a cualquier zona del ámbito SUDOE, con implementación de predicciones de Cambio Climático y sus eventos extremos asociados.

CONTENIDO

Síntesis	2
1. Introducción	9
2. Estado del arte	11
3. Materiales y métodos	19
3.1 Caracterización del comportamiento hidrodinámico temporal del nivel freático	20
3.1.1 Contexto metodológico	20
3.1.2 Modelización causal bayesiana (BCM)	21
3.1.3 Metodología	21
3.2 Construcción de un Sistema de Apoyo a la Decisión basado en BNs	23
3.2.1 Sitio piloto Campo de Cartagena	23
3.2.1.1 Identificación de las principales variables involucradas	23
3.2.1.2 Análisis de la estructura lógica	29
3.2.1.3 Identificación de diferentes escenarios de gestión del agua	29
3.2.1.4 Postproceso y análisis de los resultados obtenidos	29
3.2.2 Sitio piloto Delta del Llobregat	31
3.2.3 Sitio piloto Adour-Garona	32
3.2.4 Sitio piloto Ribatejo	33
4. Caso de estudio de detalle	34
5. Resultados	37
5.1 Hidrología Predictiva	37
5.1.1 Método gráfico basado en el análisis de los picos	37
5.1.1.1 Caracterización de las precipitaciones	37
5.1.1.2 Análisis de la evolución piezométrica temporal	37
5.1.1.3 Representatividad de la relación entre pluviometría y piezometría	38
5.2 Traducción de modelos causales bayesianos (BCMT)	39
5.2.1. Aprendizaje y entrenamiento	39
5.2.2. Simulación	40
5.3 Análisis coste-beneficio de los escenarios simulados mediante análisis del Sistema de Apoyo a la decisión basado en redes bayesianas	40

5.3.1	Análisis coste-beneficio de los escenarios simulados para el sitio piloto	
	Campo de Cartagena-Mar Menor	40
	Escenario 1. Business as Usual (BAU)	41
	Escenario 2. Maximización del precio del agua.....	41
	Escenario 3. Minimización del precio del agua.....	41
	Escenario 4. Maximización de la demanda hídrica para regadío	42
	Escenario 5. Minimización de la demanda hídrica para regadío	42
5.3.2	Análisis coste-beneficio de los escenarios simulados para el resto de	
	casos de estudio	45
6.	Conclusiones	50
	6.1 Hidrología predictiva	50
	6.2 Sistema de apoyo a la decisión mediante redes bayesianas	52
	Referencias.....	54

ÍNDICE DE FIGURAS

Figura 1. Metodología general.....	19
Figura 2. Metodología específica para el estudio hidrodinámico predictivo.	22
Figura 3. Sistema de Apoyo a la Decisión basado en Redes Bayesianas. Aplicación al sistema acuífero del Campo de Cartagena.....	30
Figura 4. SAD diseñada para el caso de estudio del Delta del Llobregat.	31
Figura 5. SAD diseñada para el caso de estudio de Adour-Garona.	32
Figura 6. SAD diseñada para el caso de estudio de Ribatejo.	33
Figura 7. Localización del acuífero Cuaternario del Campo de Cartagena.	35
Figura 8. Evolución temporal de las precipitaciones (estación pluviométrica 06A01P01).....	37
Figura 9. Relación Precipitación-Piezometría. Datos de precipitación horaria registrados en la estación 06A01P01 y nivel piezométrico del punto SM006.	38
Figura 10. Relación Precipitación- Incremento de la Piezometría. Datos de precipitación horaria tomados en la estación 06A01P01 e incremento de nivel piezométrico tomado de piezómetro SM006	39
Figura 11. a) Estructura lógica del modelo causal bivalente b) Simulación de la media c) Simulación del evento máximo. Fuente: Hugin Expert. Versión 8.9	40
Figura 12. Escenario 1. BAU.	43
Figura 13. Escenario 2. Maximización del precio del agua.	43
Figura 14. Escenario 3. Minimización del precio del agua.....	44
Figura 15. Escenario 4. Maximización de la demanda hídrica para regadío.....	44
Figura 16. Escenario 4. Maximización de la demanda hídrica para regadío.....	45
Figura 17. Sistema de apoyo a la decisión general y cualitativo.....	46

ÍNDICE DE TABLAS

Tabla 1. Variables involucradas en el SAD basado en BNs.....	24
Tabla 1. Estados de la variable “SeaWater Desalination INPUT (Hm ³ /year)”	24
Tabla 2. Estados de la variable “TSWT INPUT (Hm ³ /year)”	25
Tabla 3. Estados de la variable “Aquifer abstraction (Hm ³ /year)”	25
Tabla 4. Estados de la variable “Aquifer recharge (Hm ³ /year)”	25
Tabla 5. Estados de la variable “Aquifer Budget (Hm ³ /year)”	25
Tabla 6. Estados de la variable “Water Demand for Agriculture (Hm ³ /year)”	26
Tabla 7. Estados de la variable “Direct Employments (Employments/ha)”	26
Tabla 8. Estados de la variable “Water Price (Cent€/m ³)”	26
Tabla 9. Estados de la variable “Agricultural water profitability (Mil€/hm ³)”	26
Tabla 10. Estados de la variable “Agricultural volumetric productivity (Tn/hm ³)”	27
Tabla 11. Estados de la variable “Agricultural Production (MilTn/year)”	27
Tabla 12. Estados de la variable “Agricultural productivity (MilTn/ha)”	27
Tabla 13. Estados de la variable “Net Irrigated Surface (Ha)”	27
Tabla 14. Estados de la variable “Agricultural Gross Unit Income (Mil€/ha)”	28
Tabla 15. Estados de la variable “Aquifer quantitative status (Exploitation Index)”	28
Tabla 16. Estados de la variable “Agricultural Gross Income (Mil€/year)”	28
Tabla 17. Estados de la variable “Total Direct Employments”	28
Tabla 18. Escenario 1. Business as Usual (BAU).....	41
Tabla 19. Escenario 2. Maximización del precio del agua.	41
Tabla 20. Escenario 2. Minimización del precio del agua.	41
Tabla 21. Maximización de la demanda hídrica para regadío.	42

Tabla 22. Minimización de la demanda hídrica para regadío.....	42
Tabla 23. Escenario 1. Business as Usual (BAU).....	47
Tabla 24. Maximización del precio del agua.....	47
Tabla 25. Minimización del precio del agua.....	47
Tabla 26. Maximización de la demanda hídrica para regadío.	48
Tabla 27. Minimización de la demanda hídrica para regadío.....	48
Tabla 28. Escenario 6. Maximización de la demanda hídrica para industria.....	48
Tabla 29. Escenario 7. Minimización de la demanda hídrica para industria.....	49
Tabla 30. Maximización de la demanda hídrica para uso doméstico.....	49
Tabla 31. Escenario 9. Minimización de la demanda hídrica para uso doméstico.	49

1. Introducción

En un contexto actual, marcado por la grave incidencia del Cambio Climático en los patrones hidrológicos, y con una presión cada vez más elevada de la demanda de agua subterránea, este estudio se realiza con el objetivo principal de generar herramientas para la ayuda en la toma de decisión para la mejora de sostenibilidad hídrica de diferentes casos de estudio. Como objetivos secundarios destacan caracterizar la relación de la hidrología superficial con el comportamiento hidrodinámico del nivel freático y realizar un análisis predictivo de su evolución temporal.

Para atender al objetivo principal de generar herramientas de ayuda en la toma de decisiones, se ha desarrollado completamente un Sistema de Apoyo a la Decisión (SAD) basado en Redes Bayesianas Orientas a Objetos (OOBNs), específicamente diseñado para el sistema acuífero del Campo de Cartagena. Se han construido además otros tres SADs para los correspondientes tres casos de estudio que incluye el proyecto Interreg-Sudoe AQUIFER. Dichos SADs tienen una naturaleza cualitativa y la simulación de sus escenarios de gestión pueden ayudar a la futura toma de decisiones de intervenciones de gestión a implementar.

Además, para atender a los objetivos secundarios planteados en la oferta, se ha considerado necesario realizar un desarrollo muy potente de modelización causal. En este sentido, el análisis de las relaciones causales de los procesos hidrológicos es un campo muy inexplorado. Está aún menos investigado el uso de la modelización del Razonamiento Causal para el estudio de los procesos hidrodinámicos de las aguas subterráneas. En este caso, el objetivo es analizar y modelar la relación del binomio Precipitación-Piezometría. Para ello, se ha captado, analizado e interpretado la causalidad inherente contenida en los registros de datos temporales. Esto se ha hecho mediante el Razonamiento Causal Bayesiano que es una técnica perteneciente a la inteligencia artificial basada en el Teorema Bayesiano. Los datos de precipitaciones y niveles de agua subterránea (piezometría) se han tomado en registros de datos horarios.

La metodología comprende dos etapas principales, en primer lugar, un método analítico de análisis de regresión clásico, y, en segundo lugar, una traducción de modelización causal bayesiana que a su vez comprende varios pasos iterativos. Esta investigación se convierte

finalmente en una herramienta para la gestión de los acuíferos que comprende una función bivariada compuesta por dos variables: precipitación y piezometría. Esta metodología innovadora se ha aplicado con éxito en el acuífero Cuaternario de la masa de agua subterránea del Campo de Cartagena, uno de los sitios piloto del proyecto, se trata de un sistema acuífero que está directamente conectado a la laguna costera del Mar Menor (región de Murcia, SE de España). Este sistema ha estado en el punto de mira de todo el mundo debido a los importantes problemas medioambientales, estrechamente relacionados con la falta de gestión de las aguas subterráneas.

Este manuscrito está organizado como sigue. La introducción es seguida por un estado del arte que comprende los principales enfoques y técnicas existentes en los que se basa este estudio. En la siguiente sección se describe la metodología aplicada para en el siguiente apartado mostrar los principales resultados extraídos de la investigación para el caso de estudio de detalle como su aplicación al resto de sitios piloto. La última sección está dedicada a las conclusiones alcanzadas.

2. Estado del arte

Los patrones meteorológicos e hidrológicos están siendo considerablemente perturbados debido al calentamiento global del clima antropogénico (O'Gorman 2015; Pfahl et al. 2017). Por lo tanto, los sistemas de recursos hídricos y se están transformando rápidamente (Allan y Soden 2008; Chang et al. 2015; Kalra et al. 2013; Trenberth 2011; Al-Rawas et al. 2019). En este sentido, la estacionariedad en las series temporales hidrológicas estacionarias tradicionales (lluvia-escurrimiento-recarga de acuíferos) ya no prevalece (Back 2011; Donat et al. 2016; Huff 1990; Wasko y Sharma 2015). En este sentido, los eventos extremos como las inundaciones (Vogel et al. 2018) o las sequías (Marcos-García 2017) y sus impactos, son cada vez más recurrentes (Jyrkama y Sykes 2007). En consecuencia, existe una fuerte demanda de desarrollo de métodos analíticos potentes y fiables para construir modelos precisos que simulen y predigan/prevean la hidrodinámica de un sistema hídrico (Hao y Singh 2016; Xu et al. 2015). La precisión en la modelización predictiva comprende, en primer lugar, el tratamiento de la aleatoriedad y la variabilidad inherentes a las series temporales hidrológicas y, en segundo lugar, la incorporación de la incertidumbre (Kong et al. 2017). También existe una fuerte necesidad de construir modelos predictivos considerando el comportamiento repentino de los sistemas hidrológicos. En este sentido, se requieren métodos/modelos basados en datos y pasos de tiempo minutales, horarios o diarios para ello.

Marotzke et al. (2017) definen el "tiempo" como el resultado de la "interacción de procesos termodinámicos y dinámicos que determinan los patrones de circulación y precipitación". Además, Nobre et al. (2017) definen la variabilidad climática como "las fluctuaciones naturales del sistema climático en torno a la tendencia a largo plazo". Sin embargo, esas variaciones están siendo cada vez más alteradas debido al impacto del Cambio Climático (CC). En la actualidad, el CC impulsa varios procesos hidrológicos: a) estructuras climáticas de mayor escala como El Niño-Oscilación del Sur (ENSO), el anti-ENSO llamado La Niña, la Oscilación del Atlántico Norte (NAO) principalmente, b) eventos hidrológicos extremos, c) aumento del nivel del mar, d) derretimiento de los glaciares de montaña y del hielo polar, e) expansión térmica del agua del mar y f) disminución de la disponibilidad general de agua (Chang et al. 2015; Kalra et al. 2013). Este fenómeno mundial está fuertemente relacionado con el efecto del calentamiento global (IPCC 2021), muy intensificado por las acciones antropogénicas (Marotzke et al. 2017). Min et al. (2011), Zhang et al. (2013) y O'Gorman (2015) aportan

pruebas de una contribución antropogénica a los cambios observados en los extremos de precipitación. La NAO es la principal causa de la variabilidad estacional e interdecadal de la circulación atmosférica en el continente europeo (Qian et al. 2000). Rodrigo et al. (2000) determinaron que la NAO es la causa más probable de las alteraciones de las precipitaciones en el sur de España. Rodríguez-Puebla et al. (2001) muestran que la NAO es la principal fuente de variabilidad interanual sobre la Península Ibérica.

La incertidumbre, la aleatoriedad y la variabilidad son características propias de las series temporales hidrológicas. En cuanto a los procesos meteorológicos locales, su recurrencia también está siendo alterada mostrando mayores picos y frecuencia de procesos masivos de lluvia-escurrimiento en territorios reducidos. La ocurrencia de lluvias intensas suele dar lugar a episodios de inundación que pueden tener un mayor o menor impacto socioeconómico en función del grado de vulnerabilidad de las sociedades. Una mejor planificación de las infraestructuras en general permitirá reducir el grado de vulnerabilidad a estos eventos extremos determinando su probabilidad de ocurrencia y, por tanto, el mayor o menor riesgo de exposición al fenómeno.

En concreto, para el caso de estudio del acuífero Cuaternario del Campo de Cartagena localizado la Demarcación Hidrográfica del Segura (DHS) situada en el SE de España. Esta DHS con una superficie relativamente pequeña, presenta una compleja configuración orográfica marcada fundamentalmente por dos extensas llanuras o depresiones, la del Segura y la del Guadalentín, así como por importantes cadenas montañosas pertenecientes a las estribaciones del sistema subbético y otras cordilleras prelitorales. La morfología de la cuenca y las intensas precipitaciones que suelen producirse en la región (CHS 2018; Melgarejo-Moreno et al. 2021)) aumentan su nivel de riesgo ante episodios de inundación. En los últimos 70 años, la precipitación media anual para el conjunto de la DHS no ha sufrido cambios significativos, aunque sí se ha producido una disminución del número anual de días de lluvia y, por tanto, del número de días de lluvia y, por tanto, de la intensidad media diaria de las precipitaciones, así como una mayor frecuencia de eventos superiores a 40 mm en 24 horas (Lizondo-Osset y García Valero 2020). Este último cambio está en consonancia con el aumento de la frecuencia e intensidad de los eventos de precipitación más intensos en la cuenca mediterránea de la Península Ibérica obtenido en Oria (2021), así como en el sureste peninsular observado en Acero et al. (2011).

Ambos resultados son compatibles con el aumento de la ocurrencia de Depresiones Aisladas en Niveles Altos observado en Muñoz et al. (2020). Atribuir estos cambios al cambio climático antropogénico no es sencillo debido principalmente a la alta variabilidad interanual de la precipitación observada sobre la región (Lizondo-Osset y García Valero 2020), lo que es indicativo de una alta variabilidad interna, y mucho más si se refiere a eventos de precipitación intensa. Sin embargo, algunos de estos cambios están en consonancia con las proyecciones de cambio climático (Cardoso et al. 2020; Donat et al. 2016), que no están exentas de gran incertidumbre y baja confianza cuando se trata de eventos intensos (Stocker 2014). La precipitación máxima anual de 24 horas es una variable considerada como poco probable y que tradicionalmente se ha utilizado como índice para evaluar el riesgo utilizando sus series para determinar periodos de retorno de ciertos umbrales tras el ajuste a una función de distribución de valores extremos de tipo general, Gumbell, SQRT-ET max (Ministerio de Fomento 1999) etc. Conocer la posible existencia de tendencias en esta variable podría ser un indicio de que tal vez el riesgo esté cambiando y, por tanto, deba ser reevaluado. Dentro de esta investigación se han analizado varios estudios destinados a evaluar las posibles tendencias de la precipitación máxima anual en las diferentes subcuencas de la DHS y el análisis de los posibles cambios en los periodos de retorno asociados a esta variable (CHS 2018; García-Valero 2021).

Los cambios previstos sobre variables meteorológicas como la temperatura o la precipitación pueden provocar variaciones significativas sobre la hidrodinámica de los acuíferos como las tasas de recarga (Jyrkama y Sykesa 2007), o los niveles piezométricos. No existe un consenso claro sobre el impacto del cambio climático en el comportamiento de los acuíferos. En este sentido, varios estudios prevén disminuciones en la recarga de los acuíferos (Herrera-Pantoja y Hiscock 2008; Merritt et al. 2006; Molina et al. 2013; Molina et al. 2021), mientras que otros predicen aumentos (Döll 2009; Green et al. 2007; Gurdak y Roe 2010; Jyrkama y Sykes 2007; Kovalevskii 2007; Yusoff et al. 2002). Además, otras contribuciones lo ponen en duda (Molina et al. 2013; Pulido-Velázquez 2015). Especialmente en las regiones áridas y semiáridas, la disponibilidad de recursos hídricos puede reducirse, modificando la interacción corriente-acuífero, las tasas de coste de bombeo y, eventualmente, provocando la contaminación de los acuíferos.

Se necesitan modelos matemáticos de flujo de agua subterránea para simular y predecir la futura variabilidad de la dinámica del agua subterránea bajo diferentes escenarios de gestión. Hay muchos desarrollos de modelos de simulación numérica en todo el mundo. Por supuesto, hay diferentes tipos de modelos numéricos, pero todos tienen algo en común que es el poder y la capacidad de representar físicamente la alta variabilidad espacio-temporal de las propiedades del acuífero y las condiciones inherentes (Coppola et al. 2005; Molina et al. 2009). Sin embargo, la forma de analizar, cuantificar e integrar la incertidumbre a esos modelos sigue siendo un tema no resuelto y un reto, especialmente para la predicción de desarrollos. Además, los códigos físicos matemáticos y los desarrollos suelen estar limitados por el volumen de datos necesarios y por la anisotropía y la mezcla de características físicas que deben ser representadas por demasiados parámetros para los que los datos son escasos. En consecuencia, el coste de desarrollo de estos modelos físicos es un reto en muchos contextos. El inevitable e inherente error e incertidumbre significativos generados dentro de las diferentes iteraciones del desarrollo de esos modelos hacen que, en muchos casos, estos modelos no sean tan efectivos y útiles como se desea (Szidarovszky et al. 2007).

En la actualidad, las técnicas de inteligencia artificial (IA), debido al avance de la informática, es el paradigma más popular de técnicas para implementar el análisis de datos masivos. En este sentido, las redes neuronales artificiales (RNA) son una de las técnicas de IA (Derbela y Nouri 2020; Yang et al. 2017a). Las RNAs que se han utilizado para muchos propósitos como la previsión de la demanda de agua potable (Ghiassi et al. 2008), la predicción de precipitaciones extremas (Bodri y Cermak 2000), la caracterización y predicción de enfermedades (Khan et al. 2001), la predicción de la demanda de electricidad (Kandananond 2011), la evaluación de la seguridad de la aviación civil (Zhou et al. 2017), modelar el caudal de los ríos (Aichouri et al. 2015), predecir la evapotranspiración de referencia (Mosavi y Edalatifar 2019), estimar la capacidad de las presas (Üneş et al. 2019), o para la predicción hidrodinámica del nivel de las aguas subterráneas. En este sentido, muchos estudios han utilizado las RNA para resolver problemas de investigación hidrogeológica a diferentes escalas temporales (Banadkooki et al. (2020); Chitsazan et al. (2015); Coppola et al. (2005); Feng et al. (2008); Sun et al. Üneş et al. (2017); Üneş et al. (2019). La mayor limitación de la RNA es que no incorpora la incertidumbre en su análisis porque es una técnica determinista. En consecuencia, los procesos estocásticos no pueden ser analizados o modelados de forma realista y precisa.

Además, en los últimos tiempos se dispone de una gran cantidad de fuentes de datos y ha surgido una rápida aparición de nuevas técnicas en hidrología basadas en la Teoría de la Información y la inteligencia artificial. En este sentido, otras técnicas y aplicaciones importantes pueden comprender el estudio de las relaciones de dependencia a través de la Teoría de la Entropía (Singh 2011), o la mejora de las previsiones mediante el enfoque bayesiano (Zhao et al. 2015) o las técnicas de Machine Learning (Lima et al. 2016), las predicciones de sequía (Kousari et al. 2017), y la explotación de embalses a través de la minería de datos y de la inteligencia artificial (Hejazi y Cai 2011; Yang et al. 2017b 2016), entre otras.

La relación entre las variables hidrológicas y sus series temporales se puede captar a través de muchas formas, desde el principal análisis básico (Coeficiente de Pearson) hasta mucho más riguroso basado en técnicas de IA como la dependencia condicional probabilística. Esta organización comprende un conjunto de relaciones de dependencia triviales y no triviales (inducidas y difusas) que explican su comportamiento temporal general (Hao y Singh 2016; Wang et al. 2009). Además, las estructuras de dependencia entre diferentes variables aleatorias deben ser cuantificadas y consideradas para el análisis, modelado y predicción de eventos hidrológicos. (Hao y Singh 2016). La relación entre las variables también puede ser analizada a través de la dependencia. Esta ha sido analizada para estudios hidrológicos a través de muchos métodos (Hao y Singh 2016). La medida de dependencia más convencional es el coeficiente de correlación de Pearson basado en la hipótesis de distribución normal para medir la dependencia lineal. Sin embargo, en muchos casos el comportamiento normal no es válido, y la dependencia lineal es demasiado simplista para caracterizar configuraciones de dependencia mucho más complejas (Hao y Singh 2016). Otra técnica común son las correlaciones de Spearman y Kendall. También se ha implementado tradicionalmente como indicador de dependencia complementario para caracterizar la dependencia no lineal de las variables hidrológicas, como se ha demostrado recientemente con los modelos de cópula (Nelsen 2006). En Hidrología, las aplicaciones de la cópula se iniciaron a partir del trabajo (De Michele y Salvadori 2003), donde se probaron las cópulas de Frank para un estudio conjunto de la intensidad y duración de las tormentas asociadas negativamente. Otros trabajos de investigación como (Zhang y Singh 2006, 2007) incorporaron cópulas para un análisis extremo de eventos de lluvia y sequía. La modelización de dependencias para y entre

eventos extremos es actualmente muy estudiada (Davison y Huser 2015; Duffoy et al. 2014; Vogel 2018). La dependencia en eventos extremos debe ser evaluada a través de técnicas diseñadas como distribución extrema como el coeficiente de dependencia de la cola. Esto se ha utilizado comúnmente en la investigación de los extremos hidroclimáticos, como la precipitación y la temperatura (Serinaldi et al. 2014). Estos eventos extremos impulsan los procesos principales de recarga de los acuíferos y deben ser considerados como una fuente importante de ingresos de los acuíferos en los presupuestos de agua.

Otra importante y reciente área de investigación es la construcción de una distribución multivariante en la modelización de diferentes estructuras de dependencia (Sarabia-Alzaga y Gómez-Déniz 2008). Esto se aplica a la hidrología en forma de análisis de frecuencias, downscaling, simulación de caudales o precipitaciones, interpolación geoestadística, corrección de sesgos, etc. Otros métodos, como la distribución paramétrica multivariante (Balakrishnan y Lai 2009), la entropía (Molina et al. 2016; Singh 2013), la cópula (Nelsen 2006), se han desarrollado para modelar diversas estructuras de dependencia de variables multivariantes a través de la construcción de la distribución conjunta o condicionada.

La regla de Bayes implementada a través de la Inferencia Bayesiana y las Redes Bayesianas (BNs) o Redes Bayesianas Dinámicas (DBNs) pueden ser consideradas como una técnica popular de IA (Molina et al. 2013, 2016, 2020). Otras técnicas relacionadas con la anterior son la regresión logística multinomial (Wu et al. 2015) y el Campo Aleatorio de Markov (MRF; Lee et al. 2012). El MRF o modelo gráfico no dirigido es un conjunto de variables aleatorias que tienen una propiedad de Markov descrita por un grafo no dirigido. Las BN son dirigidas y acíclicas (no hay posibilidad de bucles de retroalimentación cercanos), mientras que los MRF son no dirigidos y pueden ser cíclicos (posibilidad de bucles de retroalimentación cercanos). Así, una red de Markov puede representar ciertas dependencias que una red bayesiana no puede (como las dependencias cíclicas); por otro lado, no puede representar ciertas dependencias que una red bayesiana sí puede, como las dependencias inducidas y difusas (del Sagrado Martínez 2003). La identificación y cuantificación de estas dependencias no es un tema menor y el análisis causal es un muy buen método para capturar estas relaciones (Molina y Zazo 2017). La demanda de habilidades para trabajar con relaciones complejas y construir distribuciones de probabilidad hacen que estos nuevos enfoques sean apropiados.

Estas habilidades pueden resumirse como sigue La capacidad de utilizar datos brutos de campo (Zounemat-Kermani y Teshnehlab 2008) que pueden ser calibrados dentro del mismo análisis; entonces, no se necesita información "a priori" del proceso (Nourani et al. 2011); entonces, son capaces de procesar una gran cantidad de datos. En consecuencia, son útiles para identificar relaciones físicas que no están completamente identificadas o comprendidas. En este sentido, las BNs se han utilizado en gran medida para la gestión de las aguas subterráneas como sistema de apoyo a la decisión para la gestión integrada de los recursos hídricos.

Las BNs se están utilizando para modelar diversos problemas de alta complejidad para aplicaciones de gestión del agua (Molina et al. 2010). Sin embargo, las BNs, la Inferencia Bayesiana (BI) o el Razonamiento Causal Bayesiano (BCR) no han sido utilizados exclusivamente hasta ahora para reproducir el comportamiento físico hidrodinámico en la hidrología subterránea. En este sentido, poder desarrollar herramientas técnicas basadas en BCR implementadas por BNs es un campo inexplorado que esta investigación pretende cubrir para el campo de la hidrología subterránea.

Los enfoques comunes no incorporan ninguna causalidad en sus cálculos. Los enfoques clásicos del periodo de retorno sólo comprenden un valor medio que representa la inversa de la probabilidad de un determinado periodo temporal, generalmente llamado intervalo de recurrencia. Para percibir mejor las diferencias y la precisión de los resultados, este estudio se aplica a un sistema monitorizado que comprende una estación de pluviometría y una estación de nivel piezométrico en tiempo real. La metodología propuesta puede ser aplicable a cualquier otro sistema acuífero como alternativa y complemento adecuado a los enfoques tradicionales.

El objetivo principal de este estudio predictivo es proporcionar una evaluación cuantitativa a través de la BCM de la relación de dependencia horaria entre la evolución temporal de las precipitaciones y el nivel freático y sus implicaciones en la hidrodinámica de los acuíferos. A partir de estas series temporales se desarrolla un análisis causal (Teorema de Bayes) que calcula, muestra y define la interacción probabilística de dos variables. Este análisis proporciona el conocimiento del nivel de relación de dependencia entre esas variables en un paso de tiempo horario. Este enfoque difiere de los enfoques tradicionales, como los

coeficientes de correlación de Pearson o el coeficiente de correlación de rango de Spearman, que miden la dependencia en el cuerpo principal de datos sin considerar plenamente la incertidumbre (Hao y Singh 2016).

3. Materiales y métodos

La metodología general de este estudio consta de 5 fases consecutivas, con un enfoque “top-down” y “bottom-up”, que se muestran en la Figura 1. En primer lugar, se realizará una búsqueda y recopilación de información hidrogeológica e hidrológica existente. A continuación, se llevará a cabo una caracterización del comportamiento hidrodinámico del nivel freático en régimen hidrológico medio. Después, se hará una identificación de las principales variables involucradas. Posteriormente, se realizará un análisis de la estructura lógica de los 4 sistemas hidrológicos en estudio para el diseño y construcción del Sistema de Apoyo a la Decisión (SAD) basado en Redes Bayesianas Orientadas a Objetos (Molina et al. 2010). La quinta fase será la de identificación y simulación mediante el SAD de los diferentes escenarios de gestión del agua. La sexta y última fase será la del postproceso y análisis de los resultados obtenidos, incluyendo un análisis Coste-Beneficio de los escenarios simulados previamente.

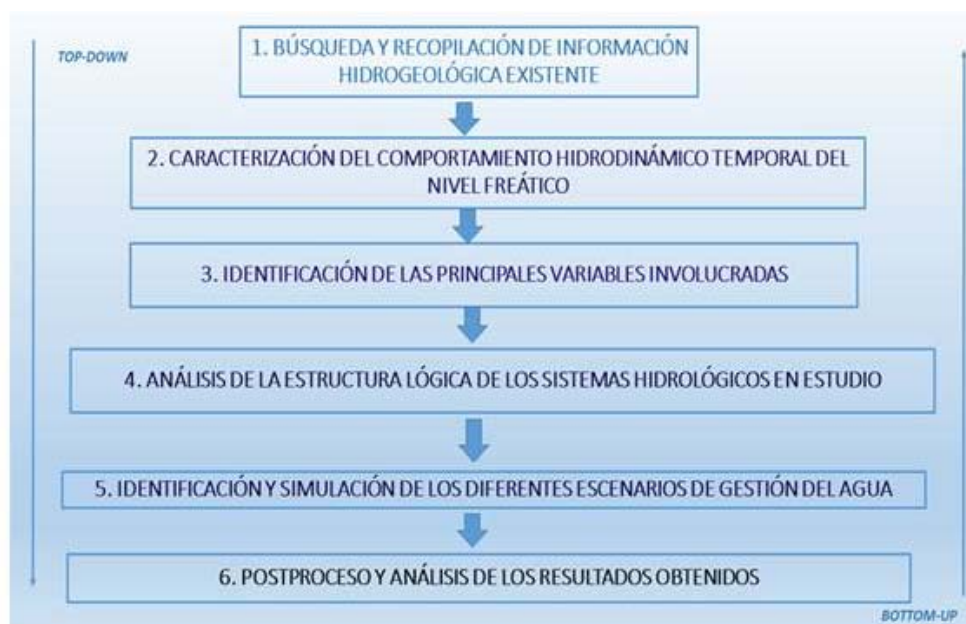


Figura 1. Metodología general.

3.1 Caracterización del comportamiento hidrodinámico temporal del nivel freático

3.1.1 Contexto metodológico

Las BNs son modelos gráficos probabilísticos (Pearl 1988) y proporcionan probabilidad multivariante. La distribución conjunta $P(X_1, X_2, \dots, X_n)$ contiene información sobre todos los aspectos de las relaciones entre las n variables aleatorias. En teoría, se puede responder a cualquier consulta sobre las relaciones entre las variables basándose en la probabilidad conjunta. Son muy útiles para definir las relaciones lógicas entre las variables en modelos complejos mediante la evaluación de la probabilidad marginal a través de la causalidad. En consecuencia, una probabilidad conjunta proporciona una imagen completa sobre cómo se relacionan las variables aleatorias, mientras que la marginación permite centrarse en un aspecto de la imagen.

Las BNs permiten analizar el comportamiento temporal de las series para cada paso de tiempo, como se muestra en Molina y Zazo (2017) y Molina et al. (2016). Esta propiedad permite disponer de una herramienta dinámica del proceso simulado. Además, las BNs permiten desarrollar un análisis riguroso y una cuantificación de la dependencia condicional entre las variables hidrológicas. Para la calibración y validación de este análisis, la Teoría de la Información es una disciplina desde la que se diseñan específicamente algunos indicadores. Estos indicadores comprenden la Información Mutua, la Entropía Total y Condicional, la Independencia Mutua, entre otros (Nourani et al. 2015; Pearl 1988).

La Probabilidad Condicional a través del Teorema Bayesiano permite cuantificar la fuerza de relación de las variables a través de la regla de Bayes (Molina y Zazo 2018; Macian-Sorribes et al. 2020). Para los eventos A y B :

$$P(A|B) = \frac{P(A, B)}{P(B)} = \frac{P(A \cap B)}{P(B)}$$

dónde: $P(A|B)$ es la probabilidad en el evento A asumiendo que el evento B es verdadero, $P(A, B)$ es la probabilidad conjunta en los eventos A y B , $P(B)$ es la probabilidad en B .

3.1.2 Modelización causal bayesiana (BCM)

Las series se introducen en el proceso de aprendizaje y entrenamiento del modelo bayesiano causal. Esta primera etapa de la BCM es crucial, ya que incluye el descubrimiento y la caracterización de la estructura lógica y no trivial de la interdependencia temporal que subyace en las series hidrológicas (de precipitaciones).

Calibración: El modelo se ha calibrado continuamente con registros históricos de precipitaciones extremas, y datos históricos de niveles piezométricos.

Análisis de sensibilidad: el simulador predictivo de niveles pluviométricos-acuíferos se valida finalmente mediante indicadores de inteligencia artificial y Teoría de la Información como: Valor P, Información Mutua, Entropía Condicional y Entropía Total.

La implementación de la Inferencia Bayesiana a través de Redes Bayesianas se denomina generalmente Razonamiento Causal (RC). Esta es una línea de investigación muy activa y productiva en los últimos años, y tiene la posibilidad de utilizar las Redes Bayesianas para descubrir dependencias causales en datos hidrológicos casi sin procesar (Molina et al. 2013; Pearl 2000; Spirtes 2000; Koehrsen 2018).

La aplicación innovadora de esta investigación tiene como objetivo contribuir a una gestión adecuada y sostenible de los acuíferos. En este sentido, la evaluación precisa de la correlación probabilística entre la precipitación y la hidrodinámica del agua subterránea para series no estacionarias es crucial para alcanzar una comprensión profunda y robusta del comportamiento y la gestión de los acuíferos.

3.1.3 Metodología

Este trabajo tiene como objetivo principal mostrar el desarrollo de un método llamado "AquiferLevel_PredicT" basado en BCM. Este método puede mejorar la capacidad de predicción de la relación precipitación instantánea-piezometría. "AquiferLevel_PredicT" sigue una metodología que comprende 2 etapas principales (Fig. 2).

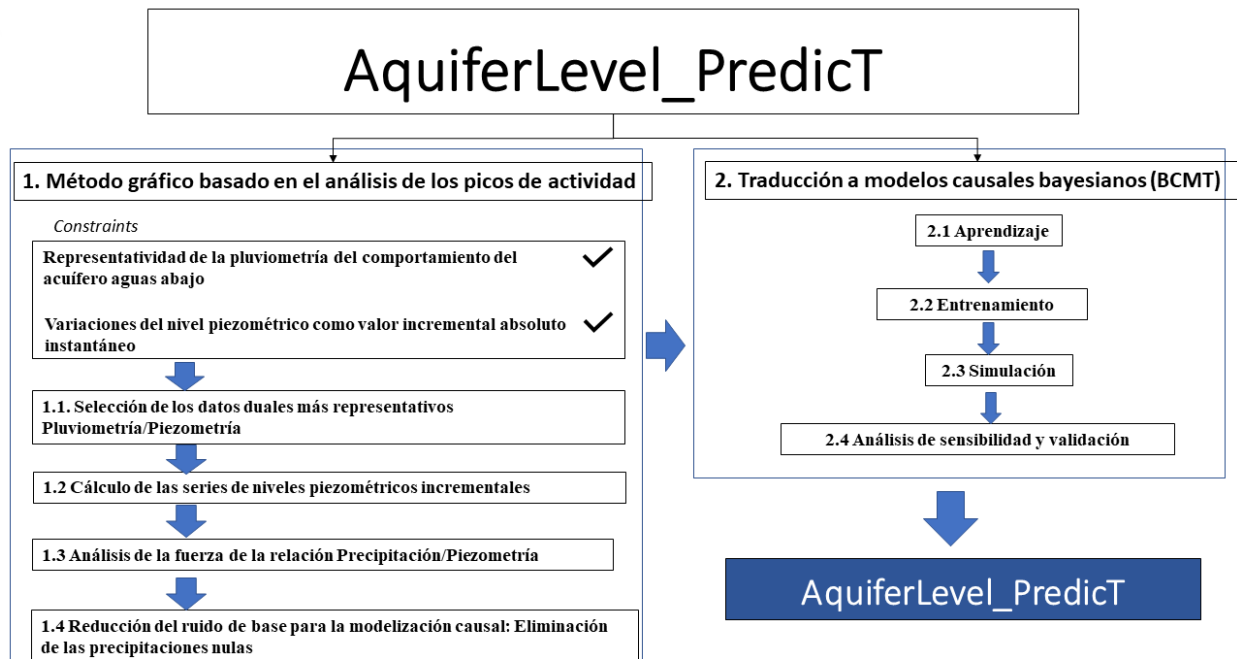


Figura 2. Metodología específica para el estudio hidrodinámico predictivo.

La primera comprende un método gráfico basado en el análisis de los eventos pico. Esta etapa está condicionada por dos restricciones iniciales que son, por un lado, a) la estación de pluviometría es representativa del nivel del acuífero aguas abajo, es decir, del comportamiento del flujo subterráneo, por lo que hay una precipitación representativa de la respuesta del acuífero; por otro lado, b) las variaciones del nivel piezométrico deben ser consideradas como un valor incremental absoluto instantáneo.

Esta primera etapa comprende subfases como:

- 1.1. Selección de los datos duales más representativos de Precipitación y Nivel Piezométrico.
- 1.2 Cálculo de las series incrementales de nivel piezométrico.
- 1.3 Análisis de la fuerza de la relación Precipitación-Nivel Piezométrico.
- 1.4 Eliminación de los datos nulos de precipitación para reducir el ruido de base de la siguiente etapa causal.

La segunda etapa principal se denomina Traducción de la modelización causal bayesiana (BCMT) que comprende:

- 2.1 Aprendizaje.
- 2.2 Entrenamiento.
- 2.3 Simulación mediante modelización BCM.
- 2.4 Análisis de sensibilidad y validación.

El modelo final se compone de un sistema bivalente conjunto formado por una independencia (nodo padre) que representa la "Precipitación" y una probabilidad de distribución condicional (nodo hijo), que representa el "Nivel del acuífero o piezometría".

3.2 Construcción de un Sistema de Apoyo a la Decisión basado en BNs

3.2.1 Sitio piloto Campo de Cartagena

3.2.1.1 Identificación de las principales variables involucradas

El SAD del acuífero Cuaternario del Campo de Cartagena basado en BNs está formado por 17 variables o nodos interrelacionados. Dichas variables se han agrupado en cuatro categorías en función de tres bloques temáticos y de si representan objetivos finales del estudio. Se sintetizan en la Tabla 1; hidrológicas (color azul), económicas (color amarillo), sociales (color naranja) y objetivos finales del sistema (color rojo). Las siguientes tablas, de la 2 a 18 recogen las variables con sus estados.

Tabla 1. Variables involucradas en el SAD basado en BNs

GRUPO	NOMBRE	EXPLICACIÓN
1. Hidrológicas	SeaWater Desalination INPUT (Hm ³ /year)	INPUT de agua desalada al sistema, en Hm ³ /año
	TSWT INPUT (Hm ³ /year)	INPUT de agua del Traspase Tajo-Segura al sistema, en Hm ³ /año
	Aquifer recharge (Hm ³ /year)	INPUT de agua al acuífero por recarga anual en Hm ³ /año
	Aquifer abstraction (Hm ³ /year)	Extracción anual de agua del acuífero en Hm ³ /año
	Aquifer Budget (Hm ³ /year)	Balance hídrico del acuífero en Hm ³ /año.
2. Sociales	Water Demand for Agriculture (Hm ³ /year)	Demanda hídrica para agricultura en Hm ³ /año
	Direct Employments (Employments/ha)	Número de empleos directos generados en agricultura por hectárea
3. Económicas	Water Price (Cent€/m3)	Precio del agua en céntimos de € por m3
	Agricultural water profitability (Mil€/hm3)	Rentabilidad agrícola del agua
	Agricultural volumetric productivity (Tn/hm3)	Productividad volumétrica agrícola
	Agricultural Production (MilTn/year)	Producción agrícola
	Agricultural productivity (MilTn/ha)	Producción agrícola por hectárea
	Net Irrigated Surface (Ha)	Área de regadío en hectáreas
	Agricultural Gross Unit Income (Mil€/ha year)	Renta bruta agrícola por hectárea
5. Objetivos finales	Aquifer quantitative status (Exploitation Index)	Índice de Explotación (IE) de la MASb
	Agricultural Gross Income (Mil€/year)	Renta agrícola bruta en millones de €
	Total Direct Employments	Número de empleos directos generados por la actividad agrícola

Tabla 1. Estados de la variable “SeaWater Desalination INPUT (Hm³/year)”

VARIABLE	(Hm ³ /año)
SeaWater Desalination INPUT (Hm ³ /year)	0-10
	10-20
	20-30

Tabla 2. Estados de la variable “TSWT INPUT (Hm³/year)”

VARIABLE	(Hm ³ /año)
TSWT INPUT (Hm ³ /year)	0-30
	30-60
	60-90
	90-120

Tabla 3. Estados de la variable “Aquifer abstraction (Hm³/year)”

VARIABLE	(Hm ³ /año)
Aquifer abstraction (Hm ³ /year)	0-30
	30-60
	60-90
	90-120

Tabla 4. Estados de la variable “Aquifer recharge (Hm³/year)”

VARIABLE	(Hm ³ /año)
Aquifer recharge (Hm ³ /year)	0-30
	30-60
	60-90
	90-120

Tabla 5. Estados de la variable “Aquifer Budget (Hm³/year)”

VARIABLE	(Hm ³ /año)
Aquifer Budget (Hm ³ /year)	< 0
	0-40
	40-80
	>80

Tabla 6. Estados de la variable “Water Demand for Agriculture (Hm³/year)”

VARIABLE	(Hm ³ /año)
Water Demand for Agriculture (Hm ³ /year)	100-150
	150-200
	200-250

Tabla 7. Estados de la variable “Direct Employments (Employments/ha)”

VARIABLE	(Nº Empleos/ha)
Direct Employments (Employments/ha)	0-0.5
	0.5-1
	➤ 1

Tabla 8. Estados de la variable “Water Price (Cent€/m³)”

VARIABLE	(Nº Empleos/ha)
Water Price (Cent€/m ³)	0-0.5
	0.5-1
	➤ 1

Tabla 9. Estados de la variable “Agricultural water profitability (Mil€/hm³)”

VARIABLE	(Mil€/hm ³)
Agricultural water profitability (Mil€/hm ³)	0-0.5
	0.5-1
	➤ 1

Tabla 10. Estados de la variable “Agricultural volumetric productivity (Tn/hm³)”

VARIABLE	(Tn/hm ³)
Agricultural volumetric productivity (Tn/hm ³)	0-2000
	2000-4000
	4000-6000
	6000-8000

Tabla 11. Estados de la variable “Agricultural Production (MilTn/year)”

VARIABLE	(MilTn/año)
Agricultural Production (MilTn/year)	200-400
	400-600
	600-800

Tabla 12. Estados de la variable “Agricultural productivity (MilTn/ha)”

VARIABLE	(MilTn/ha)
Agricultural productivity (MilTn/ha)	0-10
	10-20
	20-30
	30-40

Tabla 13. Estados de la variable “Net Irrigated Surface (Ha)”

VARIABLE	(Ha)
Net Irrigated Surface (Ha)	200-400
	400-600
	600-800

Tabla 14. Estados de la variable “Agricultural Gross Unit Income (Mil€/ha)”

VARIABLE	(Mil€/ha)
Agricultural Gross Unit Income (Mil€/ha year)	200-400
	400-600
	600-800

Tabla 15. Estados de la variable “Aquifer quantitative status (Exploitation Index)”

VARIABLE	(Mil€/hm ³)
Aquifer quantitative status (Exploitation Index)	200-400
	400-600
	600-800

Tabla 16. Estados de la variable “Agricultural Gross Income (Mil€/year)”

VARIABLE	(Mil€/hm ³)
Agricultural Gross Income (Mil€/year)	200-400
	400-600
	600-800

Tabla 17. Estados de la variable “Total Direct Employments”

VARIABLE	(Mil€/hm ³)
Total Direct Employments	200-400
	400-600
	600-800

3.2.1.2 Análisis de la estructura lógica

El SAD está dividido en 4 grandes grupos en función de la naturaleza temática de las variables involucradas. El primer grupo lo forman las variables socioeconómicas, el segundo grupo es el hidrológico, representan el balance hídrico del sistema; el tercero las variables sociales y, por último, las variables objetivo. En cuanto a tipo de variables en función de su dependencia/independencia, las variables padre (independientes) son “Water Demand for agriculture” y “Water Price”. En las figuras 3 a 6 se muestran los SAD de los 4 sitios piloto.

3.2.1.3 Identificación de diferentes escenarios de gestión del agua

Los escenarios de gestión hídrica contemplados son los siguientes:

- Escenario 1. Business as usual (BAU)
- Escenario 2. Maximización del precio del agua
- Escenario 3. Minimización del precio del agua
- Escenario 4. Maximización de la demanda hídrica para regadío
- Escenario 5. Minimización de la demanda hídrica para regadío
- Escenario 6. Maximización de la demanda hídrica para industria
- Escenario 7. Minimización de la demanda hídrica para industria
- Escenario 8. Maximización de la demanda hídrica para uso doméstico
- Escenario 9. Minimización de la demanda hídrica para uso doméstico

3.2.1.4 Postproceso y análisis de los resultados obtenidos

Una vez compilada la red se ha realizado el análisis de los diferentes impactos producidos acorde con los escenarios de gestión hídrica anteriormente comentados.

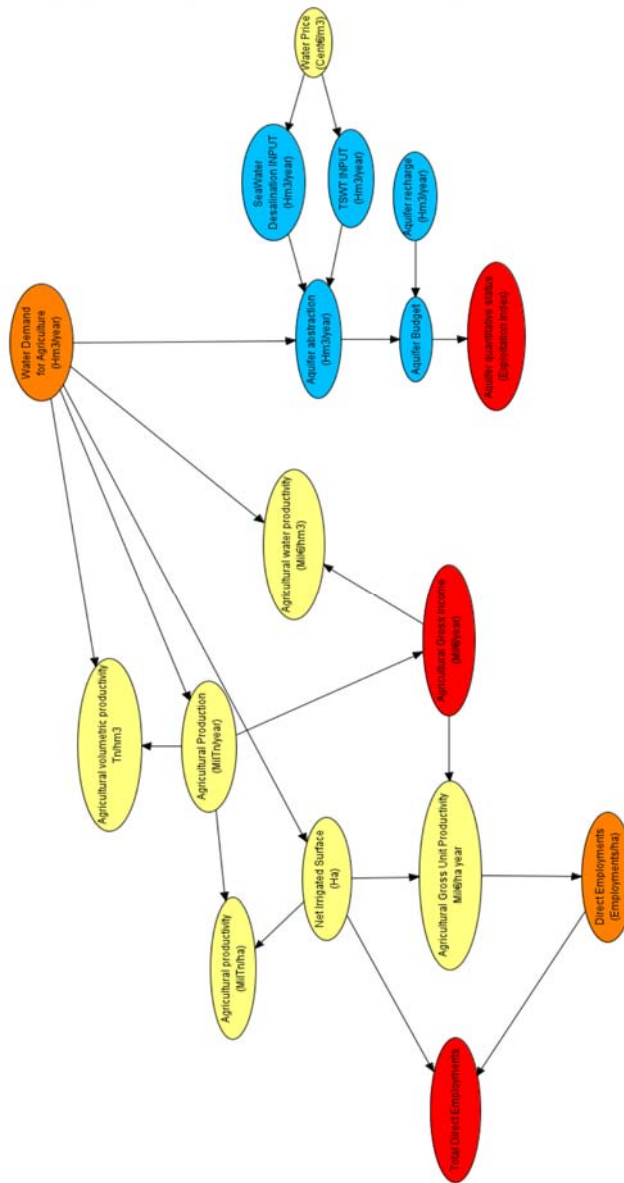


Figura 3. Sistema de Apoyo a la Decisión basado en Redes Bayesianas. Aplicación al sistema acuífero del Campo de Cartagena.

3.2.2 Sitio piloto Delta del Llobregat

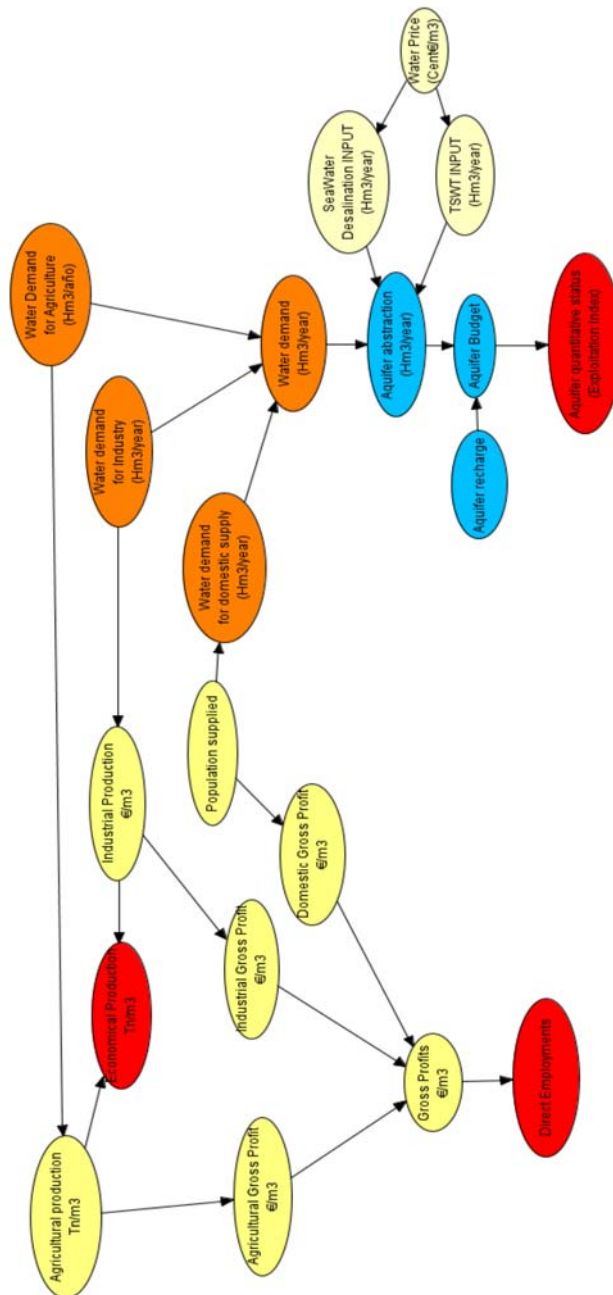


Figura 4. SAD diseñada para el caso de estudio del Delta del Llobregat.

3.2.3 Sitio piloto Adour-Garona

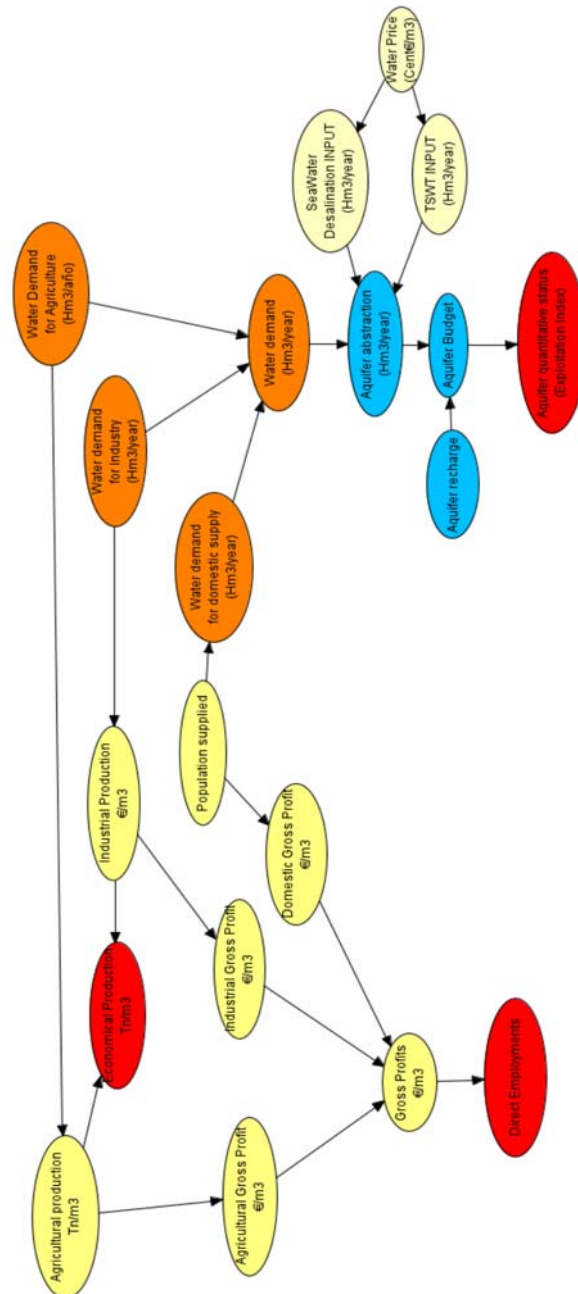


Figura 5. SAD diseñada para el caso de estudio de Adour-Garona.

3.2.4 Sitio piloto Ribatejo

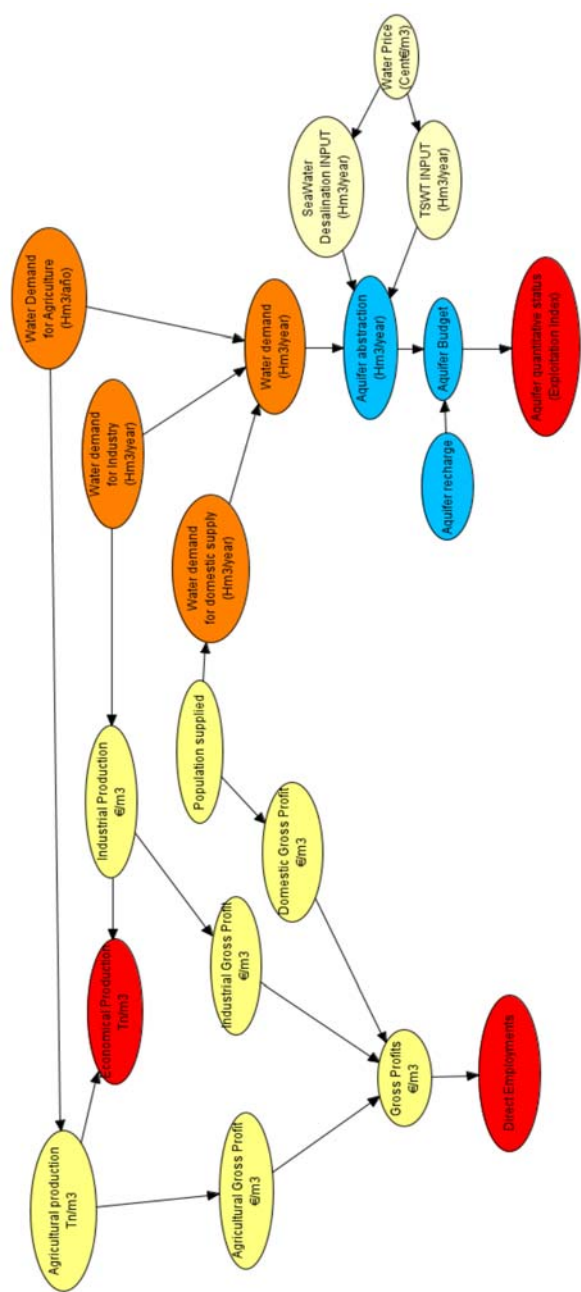


Figura 6. SAD diseñada para el caso de estudio de Ribatejo.

4. Caso de estudio de detalle

La masa de agua subterránea del Campo de Cartagena comprende una región subhorizontal de unos 1236 km² situada en el sureste de España. Está rodeada por pequeñas cadenas montañosas como la Sierra de los Victorias y la Sierra Cartagena-La Unión en todos sus límites excepto en el Este, donde se abre al Mar Mediterráneo. Una laguna costera hipersalina, el Mar Menor, destaca en el paisaje situado entre la llanura y el Mar Mediterráneo (Fig. 7).

La región se caracteriza por un clima semiárido, con 18° de temperatura media anual y unos 300 mm de precipitación media anual (Hunink et al. 2015), distribuidos de forma desigual en una serie de eventos intensos muy variables en el espacio y en el tiempo, aunque principalmente en primavera y otoño. La evapotranspiración potencial es de 1275 mm/año de media. La agricultura constituye la principal actividad económica. La superficie total de regadío aumentó de 32366 ha en 2011 a 41065 ha en la actualidad, pero fluctúa en función de las asignaciones anuales de agua (Hunink et al. 2015).

Los cultivos de secano más representativos son el almendro, los cereales de invierno y el olivo, mientras que los principales cultivos de regadío son los hortícolas en hilera (lechuga, brócoli, melón y otros), y los cítricos (naranjas y limones). En las parcelas en las que predominan los cultivos en hilera, es habitual la rotación de cultivos de otoño-invierno (lechuga, alcachofa) y de primavera-verano (melón). El goteo es el principal método de riego (96%) debido a la escasez de agua y a la necesidad de conservarla (Hunink et al. 2015). Los suelos no cultivados tienen una baja permeabilidad, bajo contenido en carbono orgánico y están poco desarrollados (García-Pintado et al. 2009). El trasvase Tajo-Segura (TSWT) proporciona más de un tercio de la demanda total de agua para el riego. Sin embargo, durante las últimas décadas, la demanda insatisfecha de agua para la agricultura de regadío y el desarrollo turístico llevó a la construcción de varias plantas de desalinización. Por un lado, las plantas de desalinización de agua de mar tienen su máxima producción durante los periodos de verano y sequía, para cubrir los picos de demanda de agua; sin embargo, los costes operativos relativamente altos y los problemas de calidad limitan su uso generalizado para el riego (Lapuente 2012; Martín-Górriz et al. 2014). La mayoría de ellas están por debajo de su capacidad máxima de desalinización (March et al. 2015).

Por otro lado, los agricultores instalaron pequeños equipos de desalinización para reducir la salinidad de las aguas subterráneas bombeadas de baja calidad (aguas subterráneas

salobres) y mezclarlas con recursos hídricos superficiales de mejor calidad (es decir, el trasvase Tajo-Segura) para obtener agua adecuada para el riego; el bombeo de aguas subterráneas en algunos casos, y la gestión de la salmuera de rechazo no han contado con el suficiente apoyo administrativo ni con las infraestructuras adecuadas, lo que ha dado lugar a procedimientos judiciales con importantes repercusiones. Por último, el agua regenerada constituye la última fuente de agua disponible para satisfacer la demanda de agua agrícola.

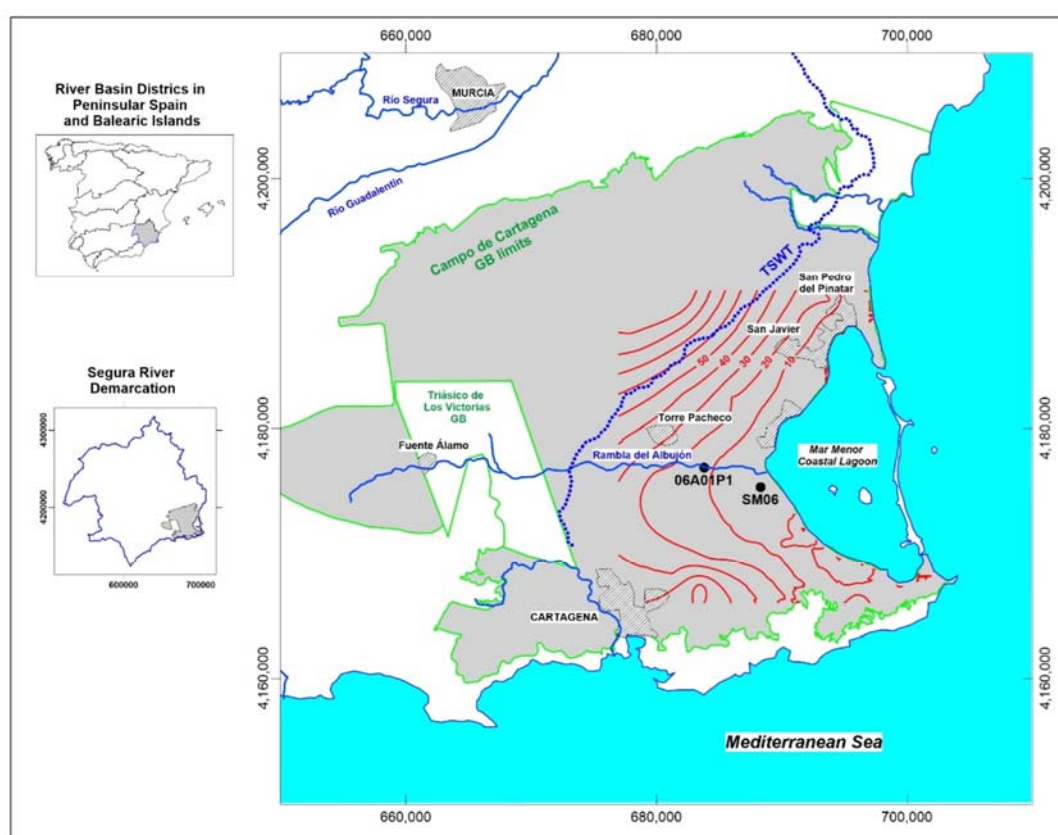


Figura 7. Localización del acuífero Cuaternario del Campo de Cartagena.

El hidrosistema está fuertemente antropizado y el papel de las aguas subterráneas se ha revelado muy significativo para mitigar los impactos sobre los ecosistemas asociados (Jiménez-Martínez et al. 2016). Se han dado pasos importantes en la modelización hidrogeológica (Alcolea et al. 2019), siendo necesario mejorar los datos necesarios para que los modelos sean más fiables y útiles para la toma de decisiones de gestión.

Para la parte del estudio de hidrología predictiva para predecir el comportamiento hidrodinámico instantáneo del acuífero Cuaternario se han utilizado dos conjuntos de datos de registros horarios que cubren el período comprendido entre el 01/01/2020 y el 31/12/2021. En primer lugar, los datos de pluviometría se tomaron de la estación pluviométrica con el código 06A01P01 (Fig. 7); a continuación, los datos piezométricos se tomaron del sondeo piezométrico codificado como SM006 (Fig. 7); ambas son estaciones oficiales de la Confederación Hidrográfica del Segura.

5. Resultados

5.1 Hidrología Predictiva

5.1.1 Método gráfico basado en el análisis de los picos

5.1.1.1 Caracterización de las precipitaciones

Se seleccionó un conjunto de datos de precipitaciones horarias para el período comprendido entre el 01/01/2020 y el 31/12/2021 (Fig. 8). A continuación, se eliminaron los valores nulos con el fin de reducir el ruido de base de la etapa causal.




Figura 8. Evolución temporal de las precipitaciones (estación pluviométrica 06A01P01).

5.1.1.2 Análisis de la evolución piezométrica temporal

Para esta investigación se utilizó un registro de datos sobre el nivel piezométrico para el mismo indicado en el apartado anterior (Fig. 9). Una vez analizados los datos, se creó una serie de niveles piezométricos incrementales. Esto se hizo con el fin de objetivar esta investigación. Por lo tanto, se calculó un valor absoluto de la serie temporal incremental sobre el nivel piezométrico para convertirse en la respuesta continua y repentina de los acuíferos a las variaciones de la precipitación. La figura 9 muestra la representación de la precipitación frente a la piezometría para los datos y el período seleccionado.




Figura 9. Relación Precipitación-Piezometría. Datos de precipitación horaria registrados en la estación 06A01P01 y nivel piezométrico del punto SM006.

5.1.1.3 Representatividad de la relación entre pluviometría y piezometría

Esta fase se ha desarrollado mediante una evaluación puramente gráfica de los picos (Fig. 10). La cuestión crucial es prestar especial atención a los picos de lluvia y el efecto sobre los eventos de incremento positivo del nivel piezométrico. La respuesta del acuífero a los pulsos repentinos de lluvia es clave aquí. Con el fin de reducir el ruido de base para la siguiente fase de CRM, e incrementar la causalidad entre ambos procesos (precipitación y piezometría), se eliminaron los datos nulos de precipitación. A continuación, las subfases de Aprendizaje y Entrenamiento demostraron esta buena correlación de datos de ambos fenómenos (Precipitación vs Piezometría).




Figura 10. Relación Precipitación- Incremento de la Piezometría. Datos de precipitación horaria tomados en la estación 06A01P01 e incremento de nivel piezométrico tomado de piezómetro SM006.

5.2 Traducción de modelos causales bayesianos (BCMT)

5.2.1. Aprendizaje y entrenamiento

El aprendizaje se realizó de forma automática a través de un asistente de aprendizaje implementado en HUGIN® Expert versión 8.9 (HUGIN 2021). El aprendizaje comprendió dos series de datos "Rainfall" y "Absolute_IncrementalPL", una serie por cada variable involucrada en este modelo. Ambas series fueron discretizadas en cinco intervalos y luego, en la fase de restricción de estructura, se conectan desde el nodo "precipitación" (padre) hasta el nodo "escorrentía" que es el hijo. La fase de entrenamiento se desarrolló con la parte inicial de la serie (720 horas) y luego se comparó con el ajuste gráfico desarrollado en la fase 1 y la experiencia del acuífero de los expertos.

5.2.2. Simulación

El evento simulado comprendía 17544 horas de datos que representaban la máxima precipitación del año con 9 mm (l/m²h). Como ya se ha dicho, el nodo "Precipitación" se discretizó en cinco intervalos de igual rango: 0,1-2,94 mm/h; 2,94-5,78 mm/h; 5,78-8,62 mm/h; 8,62-11,46 mm/h; 11,46-14,3 mm/h. Los resultados muestran un comportamiento muy similar con el ajuste gráfico y matemático. En este sentido, la probabilidad media de incremento del nivel piezométrico es de 0,26 cm/h mientras que en el pico máximo es de 2,3 cm/h (Fig. 11).

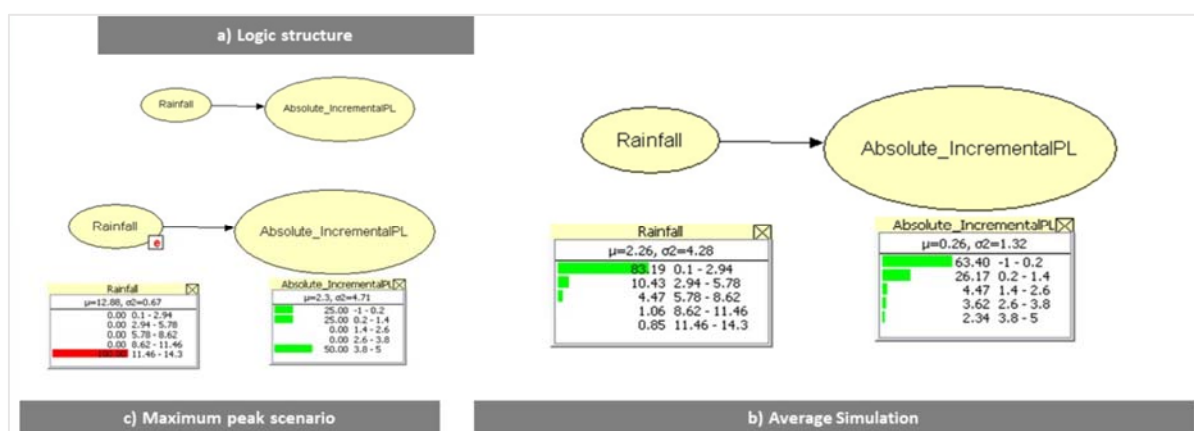


Figura 11. a) Estructura lógica del modelo causal b) Simulación de la media c) Simulación del evento máximo. Fuente: Hugin Expert. Versión 8.9

5.3 Análisis coste-beneficio de los escenarios simulados mediante análisis del Sistema de Apoyo a la decisión basado en redes bayesianas

5.3.1 Análisis coste-beneficio de los escenarios simulados para el sitio piloto Campo de Cartagena-Mar Menor

En las siguientes figuras, de 12 a 16 y tablas, de 19 a 23, se muestran los datos y resultados cuantitativos de las simulaciones de los diferentes escenarios para las principales variables.

Para el resto de los casos de estudio se ha planteado un modelo bayesiano y análisis cualitativo y teórico de escenarios de simulación, considerando las peculiaridades de cada caso de estudio, cuyo resumen se muestra a continuación (Fig. 17).

Escenario 1. Business as Usual (BAU)

Tabla 18. Escenario 1. Business as Usual (BAU).

VARIABLE	VALOR	UNIDAD
Nº Empleos	0.35	Por hectárea
Renta Agraria media	4444	mil €/ha
Producción Agrícola	486	milTn/ha
Renta agraria bruta	167320	mil€/año
Demanda hídrica para agricultura	145	hm ³ /año
Estado cuantitativo del acuífero	0.63	Bueno

Escenario 2. Maximización del precio del agua

Tabla 19. Escenario 2. Maximización del precio del agua.

VARIABLE	VALOR	UNIDAD
Nº Empleos	0.35	Por hectárea
Renta Agraria media	4444	mil €/ha
Producción Agrícola	486	milTn/ha
Renta agraria bruta	167320	mil€/año
Demanda hídrica para agricultura	145	hm ³ /año
Estado cuantitativo del acuífero	0.74	Bueno

Escenario 3. Minimización del precio del agua

Tabla 20. Escenario 2. Minimización del precio del agua.

VARIABLE	VALOR	UNIDAD
Nº Empleos	0.35	Por hectárea
Renta Agraria media	4444	mil €/ha
Producción Agrícola	486	milTn/ha
Renta agraria bruta	167320	mil€/año
Demanda hídrica para agricultura	145	hm ³ /año
Estado cuantitativo del acuífero	0.52	Bueno

Escenario 4. Maximización de la demanda hídrica para regadío

Tabla 21. Maximización de la demanda hídrica para regadío.

VARIABLE	VALOR	UNIDAD
Nº Empleos	0.39	Por hectárea
Renta Agraria media	6250	mil €/ha
Producción Agrícola	700	milTn/ha
Renta agraria bruta	250000	mil€/año
Demanda hídrica para agricultura	225 MAXIMIZADA	hm ³ /año
Estado cuantitativo del acuífero	0.52	Bueno

Escenario 5. Minimización de la demanda hídrica para regadío

Tabla 22. Minimización de la demanda hídrica para regadío.

VARIABLE	VALOR	UNIDAD
Nº Empleos	0.35	Por hectárea
Renta Agraria media	4210	mil €/ha
Producción Agrícola	440	milTn/ha
Renta agraria bruta	150400	mil€/año
Demanda hídrica para agricultura	125 MINIMIZADA	hm ³ /año
Estado cuantitativo del acuífero	0.52	Bueno

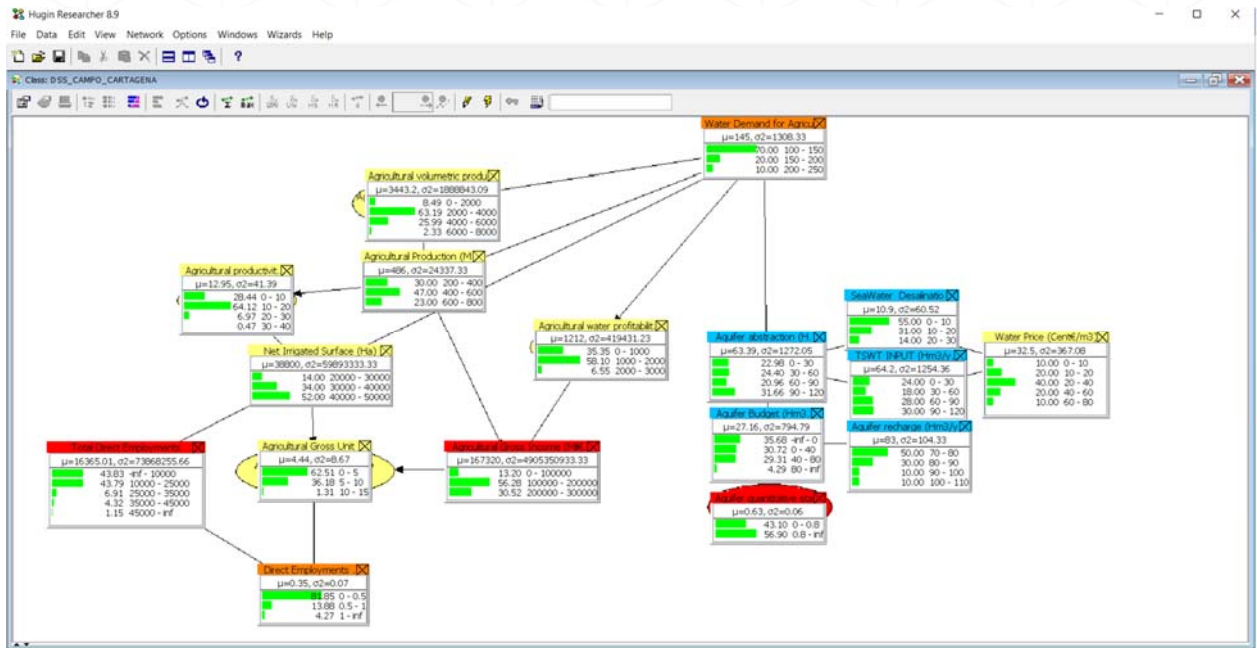


Figura 12. Escenario 1. BAU.

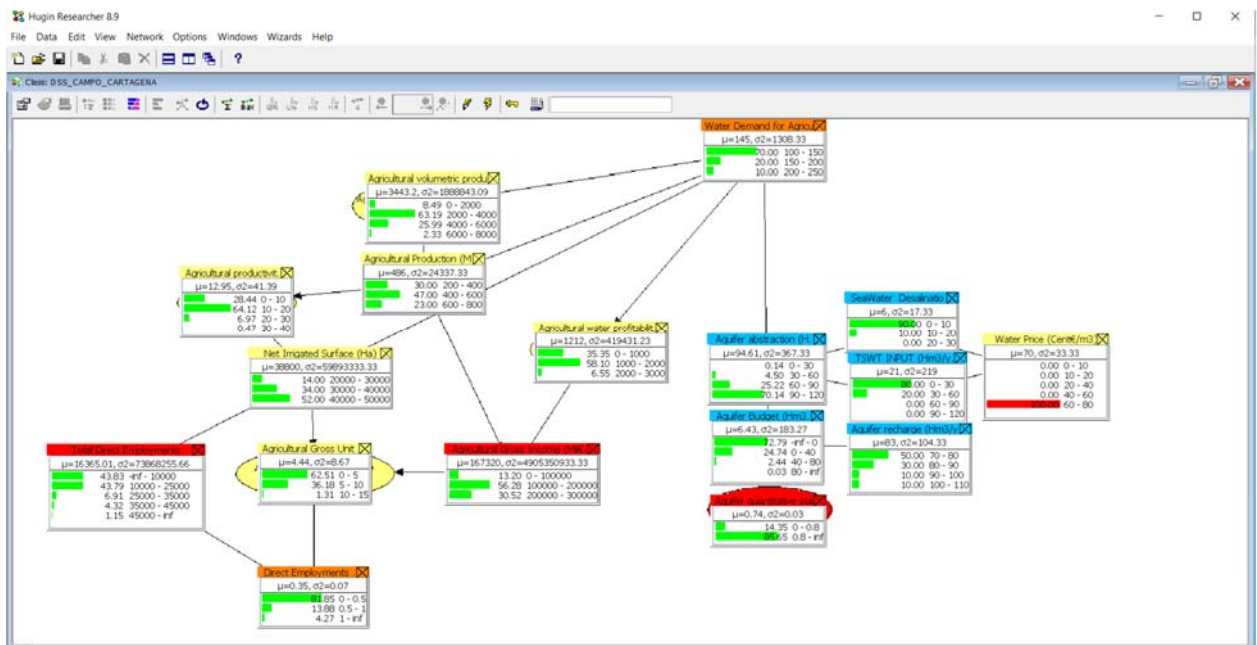


Figura 13. Escenario 2. Maximización del precio del agua.

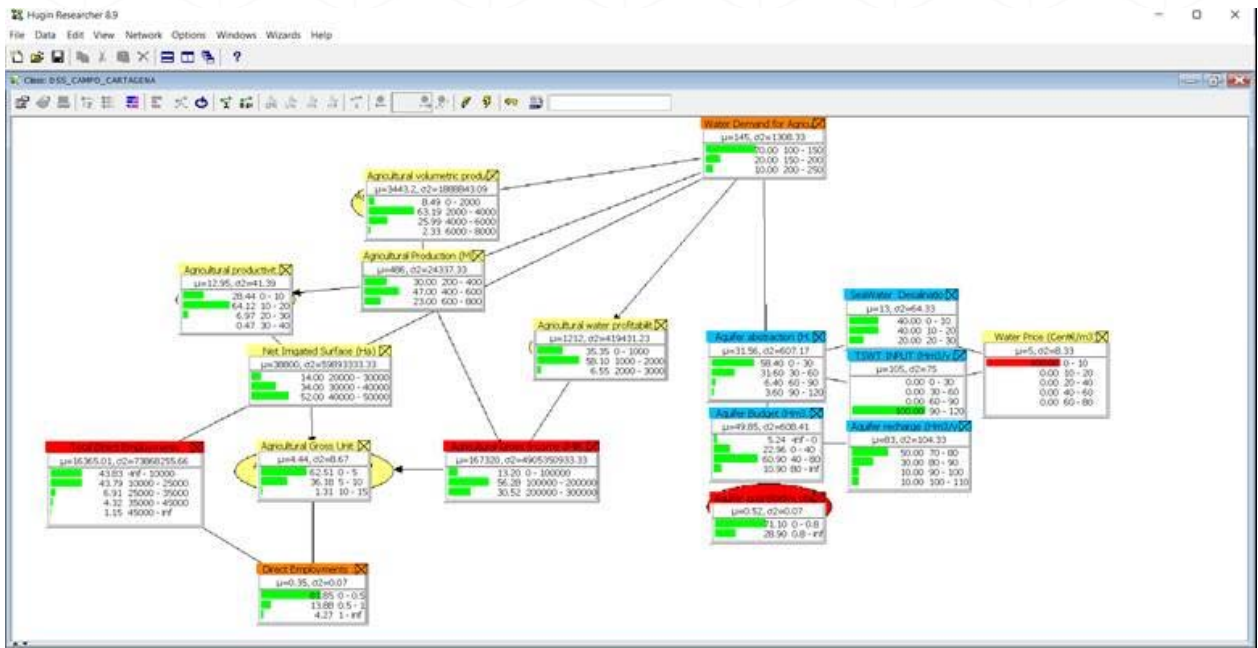


Figura 14. Escenario 3. Minimización del precio del agua.

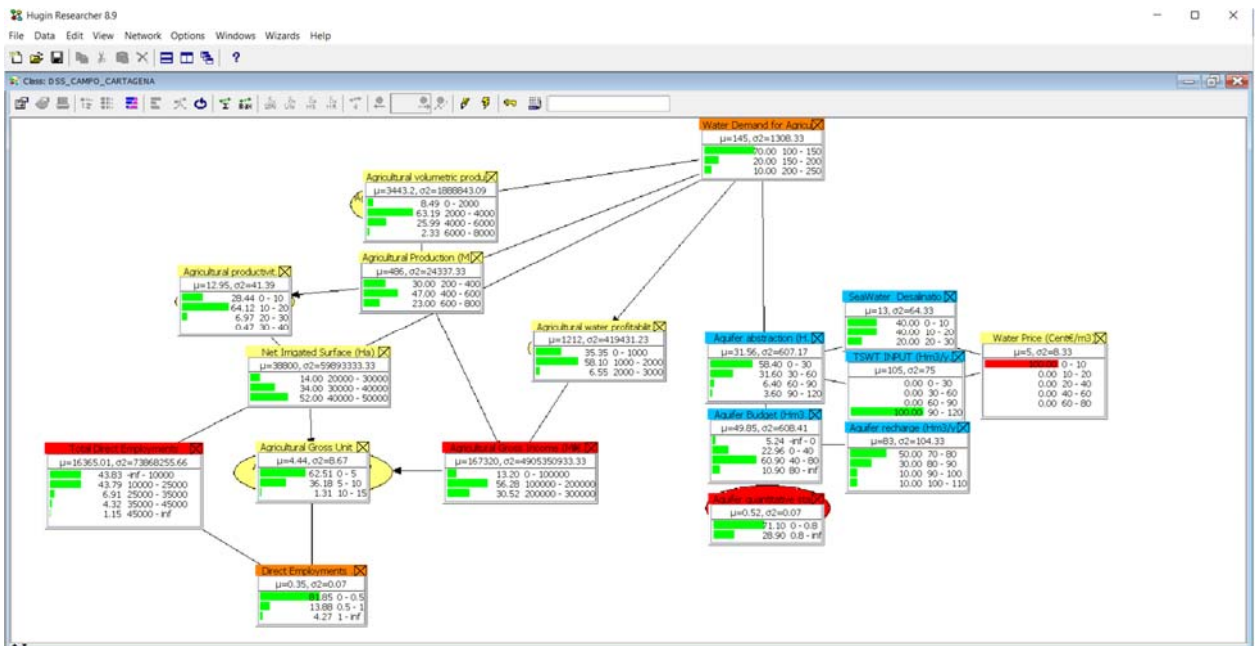


Figura 15. Escenario 4. Maximización de la demanda hídrica para riego.

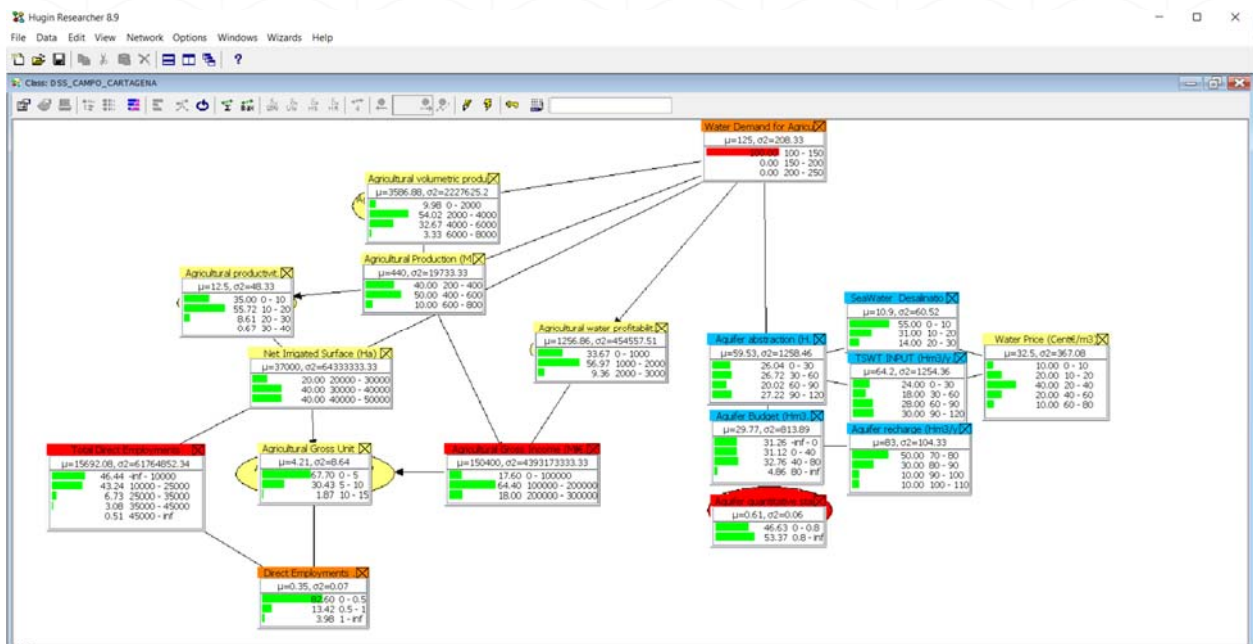


Figura 16. Escenario 4. Maximización de la demanda hídrica para riego.

5.3.2 Análisis coste-beneficio de los escenarios simulados para el resto de casos de estudio

Los resultados cualitativos de las simulaciones de escenarios para las principales variables están descritos en las tablas siguiente.

Los resultados se deben tomar como un estado promedio para los tres casos de estudio: sitio piloto Delta del Llobregat, sitio piloto Adour-Garona y sitio piloto Ribatejo.

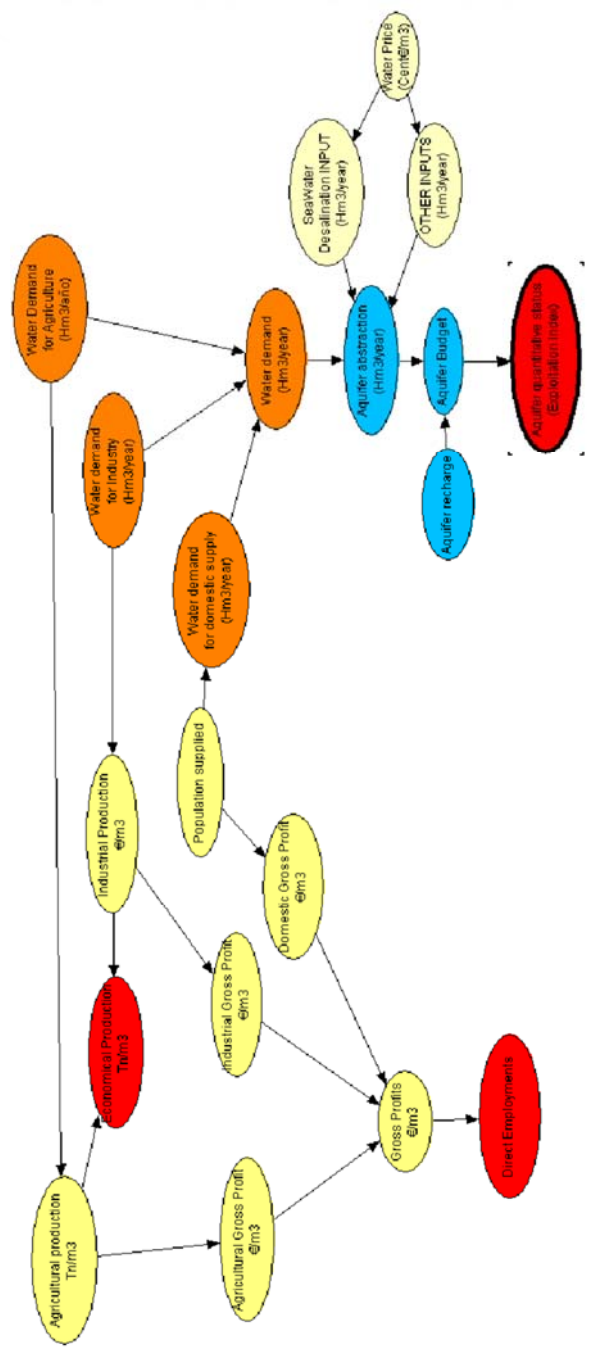


Figura 17. Sistema de apoyo a la decisión general y cualitativo.

Escenario 1. Business as Usual (BAU).

Tabla 23. Escenario 1. Business as Usual (BAU).

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	63.75 %	Al año	ALTA
Renta volumétrica media bruta	63.75%	€/M ³	ALTA
Producción Agrícola	50%	Tn/m ³	ALTO
Productividad agraria	50%	€/m ³	ALTO
Producción económica	62.5 %	Tn/m ³	BAJA
Estado cuantitativo del acuífero	51.23 %	Según Índice de Explotación	BUENO

Escenario 2. Maximización del precio del agua.

Tabla 24. Maximización del precio del agua.

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	63.75 %	Al año	ALTA
Renta volumétrica media bruta	63.75%	€/M ³	ALTA
Producción Agrícola	50%	Tn/m ³	ALTO
Productividad agraria	50%	€/m ³	ALTO
Producción económica	62.5 %	Tn/m ³	BAJA
Estado cuantitativo del acuífero	51.23 %	Según Índice de Explotación	BUENO

Escenario 3. Minimización del precio del agua.

Tabla 25. Minimización del precio del agua.

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	63.75 %	Al año	ALTA
Renta volumétrica media bruta	63.75%	€/M ³	ALTA
Producción Agrícola	50%	Tn/m ³	ALTO
Productividad agraria	50%	€/m ³	ALTO
Producción económica	62.5 %	Tn/m ³	BAJA
Estado cuantitativo del acuífero	50.33 %	Según Índice de Explotación	BUENO

Escenario 4. Maximización de la demanda hídrica para regadío.

Tabla 26. Maximización de la demanda hídrica para regadío.

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	67.35 %	Al año	ALTA
Renta volumétrica media bruta	66%	€/M ³	ALTA
Producción Agrícola	70%	Tn/m ³	ALTO
Productividad agraria	66%	€/m ³	ALTA
Producción económica	52.5 %	Tn/m ³	ALTA
Estado cuantitativo del acuífero	52.63 %	Según Índice de Explotación	BUENO

Escenario 5. Minimización de la demanda hídrica para regadío.

Tabla 27. Minimización de la demanda hídrica para regadío.

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	60.15 %	Al año	ALTA
Renta volumétrica media bruta	66%	€/M ³	BAJA
Producción Agrícola	70%	Tn/m ³	BAJA
Productividad agraria	66%	€/m ³	BAJA
Producción económica	77.5 %	Tn/m ³	BAJA
Estado cuantitativo del acuífero	52.63 %	Según Índice de Explotación	BUENO

Escenario 6. Maximización de la demanda hídrica para industria.

Tabla 28. Escenario 6. Maximización de la demanda hídrica para industria.

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	70.95 %	Al año	ALTA
Renta volumétrica media bruta	70.95%	€/M ³	ALTA
Producción Agrícola	50%	Tn/m ³	BAJA
Productividad agraria	50%	€/m ³	BAJA
Producción económica	47.5 %	Tn/m ³	ALTA
Estado cuantitativo del acuífero	52.63 %	Según Índice de Explotación	BUENO

Escenario 7. Minimización de la demanda hídrica para industria.

Tabla 29. Escenario 7. Minimización de la demanda hídrica para industria.

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	56.55 %	Al año	ALTA
Renta volumétrica media bruta	56.65%	€/M ³	ALTA
Producción Agrícola	50%	Tn/m ³	BAJA
Productividad agraria	50%	€/m ³	BAJA
Producción económica	27.5 %	Tn/m ³	ALTA
Estado cuantitativo del acuífero	49.84 %	Según Índice de Explotación	BUENO

Escenario 8. Maximización de la demanda hídrica para uso doméstico.

Tabla 30. Maximización de la demanda hídrica para uso doméstico.

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	77.35 %	Al año	ALTA
Renta volumétrica media bruta	78.65%	€/M ³	ALTA
Producción Agrícola	50%	Tn/m ³	BAJA
Productividad agraria	50%	€/m ³	BAJA
Producción económica	37.5 %	Tn/m ³	ALTA
Estado cuantitativo del acuífero	52.63 %	Según Índice de Explotación	BUENO

Escenario 9. Minimización de la demanda hídrica para uso doméstico.

Tabla 31. Escenario 9. Minimización de la demanda hídrica para uso doméstico.

VARIABLE	VALOR EN PORCENTAJE	UNIDAD	ESTADO
Nº Empleos	50.15 %	Al año	ALTA
Renta volumétrica media bruta	51.65%	€/M ³	ALTA
Producción Agrícola	50%	Tn/m ³	BAJA
Productividad agraria	50%	€/m ³	BAJA
Producción económica	37.5 %	Tn/m ³	ALTA
Estado cuantitativo del acuífero	49.84 %	Según Índice de Explotación	BUENO

6. Conclusiones

Este trabajo consiste en el desarrollo de dos partes diferenciadas en el enfoque y la escala espaciotemporal pero comunes en cuanto a la técnica y al algoritmo de cálculo, que es el Teorema de Bayes. El primer paquete de trabajos, llamado “Hidrología Predictiva” tiene como finalidad analizar las relaciones de dependencia entre el comportamiento temporal de la lluvia versus el del nivel piezométrico. Como resultado se ha desarrollado una herramienta informática llamada “AquiferLevel:PredicT”. La segunda parte del trabajo tiene como principal objetivo el desarrollo de Sistemas de Apoyo a la Decisión (SADs) basadas en Redes Bayesianas para el análisis de diferentes escenarios de gestión del agua para los cuatro casos de estudio.

6.1 Hidrología predictiva

Este trabajo tiene como objetivo principal mostrar el desarrollo de un método denominado "AquiferLevel_PredicT" basado en la modelización causal bayesiana (BCM), una técnica dentro de la inteligencia artificial (IA). Este enfoque de modelización se convierte en un modelo causal bivariante conjunto, generado para predecir la piezometría/nivel piezométrico de un acuífero dado un dato de precipitación horaria. La simplicidad del proceso del BCM no debería ser una debilidad de este método, ya que cuanto más fuerte sea el preprocesamiento de los datos, más simple puede ser el BCM. En otras palabras, el análisis detallado de la información que alimenta el BCM es crucial para desarrollar un modelo causal simple pero robusto.

Los valores de las probabilidades para la variable posterior "AquiferLevel" a través de la simulación media y la simulación de pico (Fig. 11) muestra una similitud muy alta con el comportamiento observado en la estación piezométrica (SM006). El evento simulado comprendía datos de precipitación horaria y piezométricos que cubrían un periodo de 2 años, lo que asegura suficientes datos para construir un desarrollo de BCM robusto y fiable (Zazo et al. 2022). Para el BCM, se eliminaron los datos nulos de precipitación porque introducen ruido de base e incertidumbre en la causalidad. Además, los datos nulos no aportan ninguna ventaja a la modelización física. Este método y su aplicación son el inicio de una línea de

investigación innovadora sobre la predicción probabilística de la hidrodinámica de los acuíferos. Los próximos desarrollos incluirán, entre otros: analizar y modelizar con otras escalas temporales (diaria, mensual), desarrollar un BCM que incluya la tasa de recarga, enriquecer el método con la caracterización, análisis y modelización de otros tipos de eventos, o analizar y modelizar de forma probabilística los escenarios climáticos para poder anticipar también los principales eventos meteorológicos que originan los principales eventos hidrodinámicos.

Los bajos valores de Información Mutua y los altos valores de Entropía dentro del análisis de sensibilidad del BCM se justifican por la gran cantidad de precipitaciones mínimas que no alteran el nivel del acuífero. A medida que aumentan los datos de intensidad de las precipitaciones, también aumenta el efecto en la alteración del nivel piezométrico. Esto se debe a que la recarga del acuífero se produce principalmente en el pulso más fuerte de las precipitaciones. Sin embargo, el índice extremadamente bajo del valor P ($3 \cdot 10^{-10}$) que es el grado de independencia entre la relación causal de dos variables, asegura una gran dependencia de la relación hidrológica entre precipitación-piezometría.

La piezometría fue introducida y calculada como una función incremental para la variable "Absolute_IncrementalPL". Se ha encontrado que este indicador/variable es muy eficaz porque muestra directamente el cambio absoluto (positivo o negativo) en el nivel freático del acuífero. Por lo tanto, es una forma analítica que permite reproducir la relación natural entre las precipitaciones y la variación asociada del nivel piezométrico.

AquiferLevel_PredicT es un método que predice de forma robusta y sencilla la piezometría de un acuífero asociada a las precipitaciones diarias. Esto hace que este método sea muy potente para anticipar el comportamiento futuro de las aguas subterráneas, así como los impactos negativos sobre la naturaleza y el medio ambiente humano. El hecho de que los valores de las probabilidades estén completamente alineados con otros análisis de regresión clásicos valida el método para estos datos hidrológicos (precipitación diaria y nivel del acuífero). Para anticipar el valor del nivel del acuífero, la única información necesaria sería la distribución de probabilidad de las precipitaciones en la estación pluviométrica controlada. Esto proporcionaría automáticamente el valor incremental o decreciente del nivel del acuífero de forma continua.

Toda esta metodología se convertiría en un paquete digital y tecnológico en forma de aplicación digital y software que podría extrapolarse a varios casos de estudio similares. Esto podría ir unido a dispositivos posteriores para la prevención de consecuencias negativas, especialmente relacionadas con la calidad del agua y los problemas de contaminación (si el nivel del acuífero sube muy rápidamente), en forma de Sistemas de Apoyo a la Decisión, Sistema de Alerta Temprana de Riesgos Múltiples (MH-EWS) u otros.

6.2 Sistema de apoyo a la decisión mediante redes bayesianas

Los sistemas de apoyo a la decisión diseñados han resultado ser muy eficaces y potentes como herramienta para el análisis coste-beneficio de los escenarios de gestión del agua simulados. La técnica de las Redes Bayesianas permite contar con una gran flexibilidad a la hora de plantear las relaciones lógicas y causales entre las variables involucradas. Además, esto permite una evaluación de impactos muy precisa, ya que se puede contabilizar fácilmente la diferencia entre los valores de probabilidad para cada estado. El caso de estudio del Campo de Cartagena-Mar Menor ha sido estudiado con mucho grado de detalle debido a la disponibilidad de datos. Para el resto de casos de estudio se ha hecho una evaluación cualitativa y promedio que, en posteriores fases, se podrá refinar y hacer más específica para cada caso.

Los resultados obtenidos pueden permitir orientar las políticas agrarias y de gestión del agua y más concretamente de los acuíferos involucrados. De esta forma, la hibridación de Sistemas de Apoyo a la Decisión junto con desarrollos predictivos más específicos y de detalle, es un campo de la Hidrología que está actualmente en auge. Esto se produce gracias a las técnicas pertenecientes al campo de la inteligencia artificial como es el caso de la técnica de Redes Bayesianas, entre otras.

En el caso del caso de estudio del Campo de Cartagena, para el escenario BAU, los principales valores de las variables más importantes reflejan un valor de 0.35 empleos por hectárea, una renta agraria media de unos 4444 mil€/ha, una producción agrícola de 486 milTn/ha, así como una renta agraria bruta de 167320 mil€/año, una demanda hídrica para agricultura de 145 hm³/año, con un valor de Índice de Explotación, del estado cuantitativo del

acuífero de 0.63. Para el escenario 2 (Maximización del precio del agua), se aprecia un aumento del Índice de Explotación a 0.74, y para el escenario 3 (Minimización del precio del agua), se aprecia una disminución a 0.52. Para el escenario 4 de Maximización de la demanda hídrica para regadío, se obtiene un N° de Empleos de 0.39, por hectárea, una Renta Agraria media de 6250 mil €/ha, una Producción Agrícola de 700 milTn/ha, una Renta agraria bruta de 250000 mil€/año, un Estado cuantitativo del acuífero con un Índice de Explotación de 0.52. Para el escenario 5 de Minimización de la demanda hídrica para regadío, se obtiene un N° de Empleos de 0.35 por hectárea, una Renta Agraria media de 4210 mil €/ha, una Producción Agrícola de 440 milTn/ha, una Renta agraria bruta de 150400 mil€/año, y un Estado cuantitativo del acuífero de 0.52.

Para el resto de casos de estudio, el escenario 2 de maximización del precio del agua no parece tener un efecto importante en el resto de variables; el escenario 3 de minimización del precio del agua si que produce una ligera bajada en el índice de explotación del acuífero. Posteriormente, en el escenario 4, de Maximización de la demanda hídrica para regadío, si se producen cambios significativos en las variables, en el sentido de aumentar la rentabilidad sectorial, pero aumentar también el índice de explotación del acuífero. En el escenario 5, de minimización de la demanda hídrica para regadío, el efecto es el contrario, con cambios significativos. En el escenario 6, de Maximización de la demanda hídrica para industria, se producen cambios relevantes en las variables, en el sentido de aumentar la rentabilidad industrial y su número de empleos asociados. Por el contrario, en el escenario 7 de Minimización de la demanda hídrica para industria, se produce el efecto contrario, con una bajada del índice de explotación del acuífero y una mejora con respecto al escenario de minimización de demanda hídrica para agricultura. En el escenario 8 de Maximización de la demanda hídrica para uso doméstico se producen cambios similares al escenario 6. Por último, el escenario 9, de Minimización de la demanda hídrica para uso doméstico también produce resultados equiparables al escenario 7.

Por último, cabe destacar la gran replicabilidad de estas metodologías a cualquier caso de estudio para la gestión del agua. Esto es especialmente interesante en zonas semiáridas, con problemas acuciantes de decreciente disponibilidad y demanda creciente.

Referencias

- Acero, F.J., García, J.A., Gallego, M.C., (2011). Peaks-over-Threshold Study of Trends in Extreme Rainfall over the Iberian Peninsula. *Journal of Climate*, 24:1089-1105.
- Aichouri, I., Hani, A., Bougherira, Nabil., Djabri, L., Chaffai, H., Lallahem, S. (2015). River flow model using artificial neural network. International Conference on Technologies and Materials for Renewable Energy, Environment and Sustainability, TMREES15. *Energy Procedia* 74 1007 – 1014
- Alcolea, A. Contreras, S., Hunink, J.E., García-Aróstegui. J.L., Jiménez-Martínez, J. (2019). Hydrogeological modelling for the watershed management of the Mar Menor coastal lagoon (Spain). *Science of the Total Environment* 663, 901–914.
- Allan, R. P., Soden, B. J. (2008). Atmospheric Warming and the Amplification of Precipitation Extremes. *Science*, 321,1481-1484. DOI: 10.1126/science.1160787.
- Al-Rawas, G. A., Valeo, C. (2009). “Characteristics of rainstorm temporal distributions in arid mountainous and coastal regions”. *J. Hydrol.*, 376(1-2), 318-326.
- Back, A. J. (2011). “Time distribution of heavy rainfall events in Urussanga, Santa Catarina State, Brazil”. *Acta Sci. Agron.*, 33(4), 583-588.
- Balakrishnan, N. and Lai, C.D. (2009) Continuous Bivariate Distributions. 2nd Edition, Springer, New York.
- Bodri, L., Cermák, V. (2000). Prediction of extreme precipitation using a neural network: application to summer flood occurrence in Moravia. *Advances in Engineering Software*, 31, 311-321.
- Cardoso, S., Marta-Almeida, M., Carvalho, A.C., Rocha, A. (2021). Extreme precipitation events under climate change in the Iberian Peninsula. *International Journal of Climatology*, 40:1255–1278. DOI: 10.1002/joc.6269.
- Chang, B., Guan, J., Aral, M. M. (2015). “Scientific discourse: Climate change and sea-level rise.” *J. Hydrol. Eng.*, 10.1061/(ASCE)HE.1943-5584.0000860, A4014003.
- Chitsazan, M., Rahmani, G., Neyamadpour, A. (2015). Forecasting groundwater level by artificial neural networks as an alternative approach to groundwater modeling. *J Geol Soc India* 85:98–106. [https:// doi. org/ 10. 1007/ s12594- 015- 0197-4](https://doi.org/10.1007/s12594-015-0197-4).
- CHS, 2018. Revisión y actualización de la evaluación preliminar del riesgo de inundación. EPRI. 2º ciclo.
- Coppola, E., Anthony, R., Poulton, M., Szidarovszky, F., Uhl, V., (2005). A neural network model for predicting water table elevations, *Groundwater*, 43. DOI.10.1111/j.1745-6584.2005.0003.x
- Davison, A. C. and Huser, R. (2015). Statistics of Extremes, *Annu. Rev. Stat. Its Appl.*, 2(1), 203–235.
- De Michele, C., Salvadori, G. (2003). A generalized Pareto intensity duration model of storm rainfall exploiting 2-copulas. *Journal of Geophysical Research: Atmospheres*, 108(D2).
- Del Sagrado, J., Moral, S. (2003). Qualitative combination of Bayesian networks. *International Journal of Intelligent Systems*. 18, 2, 237-249.

- Derbela M., Nouiri I. (2020). Intelligent approach to predict future groundwater level based on artificial neural networks (ANN). *Euro-Mediterranean Journal for Environmental Integration*. 5:51. <https://doi.org/10.1007/s41207-020-00185-9>
- Döll, P. (2009). Vulnerability to the impact of climate change on renewable groundwater resources: a global-scale assessment. *Environ. Res. Lett.* 4 (3), 035006.
- Donat, M. G., Lowry, A. L., Alexander, L. V., O’Gorman, P. A., and Maher, N. (2016). “More extreme precipitation in the world’s dry and wet regions.” *Nat. Clim. Change*, 6(5), 508–513.
- Dutfoy, A., Parey, S. and Roche, N. (2014). Multivariate Extreme Value Theory. A Tutorial with Applications to Hydrology and Meteorology, *Depend. Model.*, 2(1), 30–48.
- García-Pintado, J., Martínez-Mena, M., Erena, M., Castillo, V. M. (2009). Caracterización y evaluación de fuentes antropicas de nutrientes transportados por la rambla del albuja hacia el Mar Menor. *El Mar Menor. Estado Actual de Conocimiento Científico*. Fundación Instituto Euromediterráneo del Agua.
- García-Valero (2018). Análisis de los cambios en las precipitaciones máximas anuales y en sus periodos de retorno en la demarcación hidrográfica del Segura. *Inundaciones y sequías: Análisis multidisciplinar para mitigar el impacto de los fenómenos climáticos extremos / coord. por Joaquín Melgarejo Moreno, Inmaculada López Ortiz, Patricia Fernández Aracil*, 2021, ISBN 978-84-1302-138-6, pp. 343-352.
- Ghiassi, M., Zimbra, D., & Saidane, H., (2008). “Urban water demand forecasting with a dynamic artificial neural network model.” *J. Water Resour. Plann. Manage.*, 10.1061/(ASCE)0733-9496(2008)134:2 (138), 138–146.
- Green, T.R., Bates, B.C., Charles, S.P., Fleming, P.M. (2007). Physically based simulation of potential effects of carbon dioxide-altered climates on groundwater recharge. *Vadose Zone J.* 6 (3): 597–609.
- Gurdak, J.J., Roe, C.D. (2010). Review: recharge rates and chemistry beneath playas of the High Plains aquifer, USA. *Hydrogeol. J.* 18 (8), 1747–1772.
- Hao, Z., Singh, V.P. (2016). “Review of Dependence Modeling in Hydrology and Water Resources”. *Prog. Phys. Geogr.*, 40, 549–578.
- Herrera-Pantoja, M., Hiscock, K.M. (2008). The effects of climate change on potential groundwater recharge in Great Britain. *Hydrol. Process.* 22 (1), 73–86.
- Huff, F. A. (1990). Time distributions of heavy rainstorms in Illinois. Circular 173. Champaign, IL: Illinois State Water Survey.
- HUGIN. (2021). Available online: <http://www.hugin.com> (accessed on 20 January 2021).
- Hunink, J.E., Contreras, S., Soto-García, M., Martín-Gorriza, B., Martínez-Álvarez, V., Baillea, A. (2015). Estimating groundwater use patterns of perennial and seasonal crops in a Mediterranean irrigation scheme, using remote sensing. *Agricultural Water Management*, 162, 47–56.
- IPCC. (2021). Intergovernmental Panel on Climate Change. Sixth Assessment Report (AR6). In Press. <https://www.ipcc.ch/reports/> (accessed on 3 May 2021).
- Jiménez-Martínez, J., García-Aróstegui, J.L., Hunink, J.E., Contreras, S., Baudron, P., Candela, L. (2016). The role of groundwater in highly human-modified hydrosystems: a review of impacts and mitigation options in the Campo de Cartagena-Mar Menor coastal plain (SE Spain). *Environmental Reviews*. <https://doi.org/10.1139/er-2015-0089>

- Jyrkama, M.I., Sykesa, J.F., 2007. The impact of climate change on spatially varying groundwater recharge in the grand river watershed (Ontario). *J. Hydrol.* 338, 237– 250
- Kalra, A., Ahmad, S., Nayak, A., (2013). Increasing Streamflow Forecast Lead Time for Snowmelt Driven Catchment Based on Large Scale Climate Patterns. *Advances in Water Resources*, 53, 10.1016/j.advwatres.2012.11.003.
- Kandananond, K., (2011). Forecasting Electricity Demand in Thailand with an Artificial Neural Network Approach. *Energies*, 4, 1246-1257; doi:10.3390/en4081246.
- Khan, J., Wei J.S., Ringner, M., Saal, L.H., Ladanyi, M., Westermann, F., Berthold, F., Schwab, M., Antonescu, C.R., Peterson, C., Meltzer, P.S. (2001). Classification and diagnostic prediction of cancers using gene expression profiling and artificial neural networks. *Nat Med*, 7:673-679.
- Koehrsen, W. (2018). *Introduction to Bayesian linear regression*. Medium. Retrieved December 29, 2021, from <https://towardsdatascience.com/introduction-to-bayesian-linear-regression-e66e60791ea7>
- Kong, X., Huang, G., Fan, Y., Li, Y., Zeng, X., and Zhu, Y. (2017). “Risk analysis for water resources management under dual uncertainties through factorial analysis and fuzzy random value-at-risk.” *Stochastic Environ. Res. Risk Assess*, 31(9), 2265.
- Kovalevskii, V.S. (2007). Effect of climate changes on groundwater. *Water Resour.* 34 (2), 140-152.
- Lapunte, E. (2012). Full cost in desalination. A case study of the Segura River Basin. *Desalination*, 300, 40–45.
- Lee, H., Higdon, D., Bi, Z., Ferreira, M., West, M., (2000). Markov Random Field Models for High-Dimensional Parameters in Simulations of Fluid Flow in Porous Media. *Technometrics*. 230-241, 44, 3 DOI: 10.1198/004017002188618419
- Lizondo-Osset, C., García Valero, J.A., (2020). Regionalización de la precipitación diaria en la Península Ibérica. Aplicación al análisis de tendencias de eventos extremos. *Acta de las Jornadas Científicas de la Asociación Meteorológica Española*.
- Macian-Sorribes, H., Molina, J.L., Zazo, S., Pulido-Velázquez, M. (2020). “Analysis of spatio-temporal dependence of inflow time series through Bayesian causal modelling”. *J. Hydrol.*, 125722.
- March, H. (2015). The politics, geography, and economics of desalination: a critical review. *WIREs Water*, 2:231–243. doi: 10.1002/wat2.1073.
- Marcos-Garcia, P., Lopez-Nicolas, A., Pulido-Velazquez, M. (2017). “Combined use of relative drought indices to analyze climate change impact on meteorological and hydrological droughts in a Mediterranean basin”. *J. Hydrol.* 554, 292–305.
- Marotzke, J., Jakob, C., Bony, S., Dirmeyer, P.A., O’Gorman, P.A., Hawkins, E., Perkins-Kirkpatrick, S., Le Quere, C., Nowicki, S., Paulavets, K., et al. (2017). “Climate Research must Sharpen its View”. *Nat. Clim. Chang.*, 7, 89–91.
- Martin-Gorriz, B., Soto-García, M., Martínez-Alvarez, V. (2014). Energy and greenhouse-gas emissions in irrigated agriculture of SE (southeast) Spain. Effects of alternative water supply scenarios. *Energy* 77, 478-488.

- Melgarejo-Moreno, J., López-Ortiz, I., Fernández-Aracil, P. (2021). Inundaciones y sequías: Análisis multidisciplinar para mitigar el impacto de los fenómenos climáticos extremos. Edit: Joaquín Melgarejo Moreno, Inmaculada López Ortiz, Patricia Fernández Aracil, 2021, ISBN 978-84-1302-138-6
- Merritt, W., Alila, Y., Barton, M., Taylor, B., Cohen, S., Neilsen, D. (2006). Hydrologic response to scenarios of climate change in the Okanagan basin, British Columbia', *Journal of Hydrology* 326, 79–108. 55, 59, 60.
- Min, S. K., Zhang, X., Zwiers, F.W., Hegerl, G. C. (2011). Human contribution to more-intense precipitation extremes. *Nature*, 470, 378–381, <https://doi.org/10.1038/nature09763>.
- Ministerio de Fomento, (1999). Máximas lluvias diarias en la España Peninsular. Series Monográficas.
- Molina, J.L. Bromley, J., García-Aróstegui, J.L. Sullivan, C., Benavente, J. (2010). Integrated water resources management of overexploited hydrogeological systems using Object-Oriented Bayesian Networks. *Environmental Modelling & Software*, 115.
- Molina J.L., Pulido-Velázquez D., García-Arostegui J.L., Pulido-Velazquez M. (2013). "Dynamic Bayesian Networks as a Decision Support tool for assessing Climate Change impacts on highly stressed groundwater systems". *J. Hydrol* 479, 113–129.
- Molina, J.L., Zazo, S., Rodriguez-Gonzalvez, P., Gonzalez-Aguilera, D. (2016). "Innovative Analysis of Runoff Temporal Behavior through Bayesian Networks". *Water*, 8, 484.
- Molina, J.L., Zazo, S. (2017). "Causal Reasoning for the Analysis of Rivers Runoff Temporal Behavior". *Water Resour. Manag.*, 31, 4669–4681.
- Molina, J.L., Zazo, S. (2018). "Assessment of Temporally Conditioned Runoff Fractions in Unregulated Rivers". *J. Hydrol. Eng.*, 23, 04018015.
- Molina, J.L., Zazo, S., Martín, A. M. (2019). "Causal reasoning: Towards dynamic predictive models for runoff temporal behavior of high dependence rivers". *Water*, 11(5), 877.
- Molina, J.L., Zazo, S., Martín-Casado, A., Patino-Alonso, M. (2020). "Rivers' temporal sustainability through the evaluation of predictive runoff methods". *Sustainability* 12, 1720.
- Molina, J.L., Lagüela, S., Zazo, S. (2021). Methodology to Evaluate Aquifers Water Budget Alteration Due to Climate Change Impact on the Snow Fraction. *Water Resources Management*, 35, 8, 2569-2583.
- Mosavi, A., Edalatifar, M. (2019). A hybrid neuro-fuzzy algorithm for prediction of reference evapotranspiration. in *Lecture Notes in Networks and Systems*, pp. 235–243. Springer.
- Muñoz, C., Schultz, D., Vaughan, G. (2020). A Midlatitude Climatology and Interannual Variability of 200- and 500-hPa Cut-Off Lows. *Journal of Climate*, 33(6), 2.201-2.222.
- Nelsen, R. B. (2006). *An introduction to Copulas*, Second Edition. Springer Science & Business Media, New York.
- Nobre, G.G., Jongman, B., Aerts, J., Ward, P.J. (2017). The role of climate variability in extreme floods in Europe. *Environ. Res. Lett.* 12 084012.
- Nourani, V., Ejlali, R.G., Alami, M.T., 2011. Spatiotemporal groundwater level forecasting in coastal aquifers by hybrid artificial neural network-geostatistics model: a case study. *Environ. Eng. Sci.* 28 (3), 217–228.

- Nourani, V., Taghi Alami, M., Vousoughi, F.D. (2015). Wavelet-entropy data pre-processing approach for ANN-based groundwater level modelling. *Journal of Hydrology* 524, 255–269.
- O’Gorman, P.A. (2015). “Precipitation Extremes under Climate Change”. *Curr. Clim. Chang. Rep.*, 1, 49–59.
- Oria (2021). ¿Se están volviendo más frecuentes o intensos los grandes temporales de precipitación en la Península Ibérica?. Aemetblog. www.aemetblog.es
- Pearl, J., (1988). *Probabilistic Reasoning in Intelligent Systems*. Morgan Kaufmann, San Mateo, CA.
- Pearl, J. (2000): *Causality: Models, Reasoning, and Inference*, New York: Cambridge University Press, second ed., 2009
- Pfahl, S., O’Gorman, P. A., and Fischer, E. M. (2017). “Understanding the regional pattern of projected future changes in extreme precipitation.” *Nat. Clim. Change*, 7(6), 423–427.
- Pulido-Velázquez, D.; García-Arostegui, J.; Molina González, J.L.; Pulido-Velazquez, M. (2015). Assessment of future groundwater recharge in semi-arid regions under climate change scenarios (Serral-Salinas aquifer, SE Spain). Could increase rainfall variability increase the recharge rate?. *Hydrological Processes*. 29(6):828-844. doi:10.1002/hyp.10191
- Qian, B., Corte-Real, J., and Xu, H. (2000). “Is the North Atlantic Oscillation the most important atmospheric pattern for precipitation in Europe?” *J. Geophys. Res. Atmos.*, 105, 11901–11910.
- Rodrigo, F.S., Esteban-Parra, M.J., Pozo-Vázquez, F., Castro-Díez, Y. (2000). On the variability of rainfall in southern Spain in decadal to centennial time scales. *Int J Climatol* 20:721–732.
- Rodríguez-Puebla, C., encinas, A.H. y saenz, J. (2001). Winter precipitation over the Iberian peninsula and its relationship to circulation indices. *Hydrology and Earth System Sciences*, 5(2), 233-244.
- Ross, P. J. (1990). "SWIM: A simulation model for soil water infiltration and movement. Townsville, Queensland, Australia: CSIRO Division of Soils.
- Sarabia-Alzaga, J.M., Gómez-Déniz, E. (2011). Construction of multivariate distributions: A review of some recent results (with discussions). *Statistics and Operations Research Transactions* 32: 3–36.
- Serinaldi, F., Kilsby, CG.. (2014). Rainfall extremes: toward reconciliation after the battle of distributions. *Water Resour Res* 50(1):336–352.
- Spirtes, P., C. Glymour, and R. Scheines (2000): *Causation, Prediction, and Search*, Cambridge, MA: MIT Press, 2nd edition.
- Szidarovszky, F., Coppola E.A., Long, J., Hall, A.D., Poulton, M.M. (2007). A hybrid artificial neural network-numerical model for ground water problems. *Ground Water*. Sep-Oct;45(5):590-600. doi: 10.1111/j.1745-6584.2007.00330.x. PMID: 17760585.
- Stocker, T.F., Plattner, G.K. (2014). Comment: Rethink IPCC reports. *Nature* 513, 163-165.
- Sun, Y., Wendi, D., Kim, D. E., and Liang, S. Y. (2016). Technical note: Application of artificial neural networks in groundwater table forecasting-a case study in a Singapore swamp forest, *Hydrol. Earth Syst. Sci.*, 20(4), 1405–1412, doi:10.5194/hess-20-1405- 535.

Trenberth, K.E., (2011). Water Cycles and Climate Change. ChapterDOI: HB_GlobalEnvChange_30 from : Book Title: Global Environmental Change.

Üneş, F., Demirci, M., Taşar, B., Ziya-Kaya, Y., Hakan, K., Varçin. H. (2019). Estimating Dam Reservoir Level Fluctuations Using Data-Driven Techniques. *Pol. J. Environ. Stud.* 28,5, 3451-3462.

Üneş F., Demirci, M., Ispir, E., Kaya, Y.Z., Mamak, M., Tasar, B. (2017). Estimation of Groundwater Level Using Artificial Neural Networks: a Case Study of Hatay-Turkey. *Environmental Engineering 10th International Conference*, DOI: <https://doi.org/10.3846/enviro.2017.092>

Vogel, K., Weise, L., Schröeter, K., Thielen, A.H. (2018). "Identifying driving factors in flood-damaging processes using graphical models". *Water Resour. Res.* 54, 8864–8889.

Yusoff, I., Hiscock, K.M., Conway, D. (2002). Simulation of the impacts of Climate change on groundwater resources in eastern England. In: Hiscock, K.M., Rivett, M.O., Davison, R.M. (Eds.), *Sustainable Groundwater Development*. Geological Survey of London, London, 325–344.

Wasko, C., & Sharma, A. (2015). Steeper temporal distribution of rain intensity at higher temperatures within Australian storms. *Nature Geoscience*, 8(7), 527– 529. <https://doi.org/10.1038/ngeo2456>

Xu, Y., Huang, K., Yu, Y., Wang, X. (2015). Changes in water footprint of crop production in Beijing from 1978 to 2012: a logarithmic mean Divisia index decomposition analysis. *J. Clean. Prod.*, 87 (1), 180-187.

Yang, F., Lu, H., Yang, K., He, J., Wang, W., Wright, J.S. (2017a). Evaluation of multiple forcing data sets for precipitation and shortwave radiation over major land areas of China. *Hydrol. Earth Syst. Sci.*, 21 (2017), pp. 5805-5821.

Yang, L., Feng, Q., Yin, Z., Wen, X., Si, J., Li, C. (2017b). Identifying separate impacts of climate and land use/cover change on hydrological processes in upper stream of Heihe River Northwest China. *Hydrol. Process.*, 31 (2017), pp. 1100-1112.

Zhang, L., Singh, V. P. (2006). Bivariate Flood Frequency Analysis Using the Copula Method. *Journal of Hydrologic Engineering*, 11, 2. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2006\)11:2\(150\)](https://doi.org/10.1061/(ASCE)1084-0699(2006)11:2(150)).

Zhang, L., Singh, Vijay P. (2007). Bivariate rainfall frequency distributions using Archimedean copulas. *Journal of Hydrology*, 332 (1). 93-109 doi:10.1016/j.jhydrol.2006.06.033.

Zhang, X., Wan, H., Zwiers, F. W., Hegerl, G. C., Min, S. K. (2013). Attributing intensification of precipitation extremes to human influence. *Geophys. Res. Lett.*, 40, 5252–5257, <https://doi.org/10.1002/grl.51010>.

Zazo, S., Martín, A.M., Molina, J.L., Macian-Sorribes, H., Pulido-Velázquez, M. (2022). Performance assessment of Bayesian Causal Modelling for runoff temporal behaviour through a novel stability framework. *Journal of Hydrology*. Under review.

Zhou, X., Gong, W., Fu, W., Du, F. (2017). IEEE/ACIS 16th International Conference on Computer and Information Science (ICIS) IEEE. Application of deep learning in object detection; pp. 631–634.

Zounemat-Kermani, M. Teshnehlab, M. (2008). Using adaptive neuro-fuzzy inference system for hydrological time series prediction. *Applied Soft Computing*, 8, 928–936.