



UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA

FACULTAD DE INGENIERÍA, ARQUITECTURA Y DISEÑO



PROGRAMA DE MAESTRÍA Y DOCTORADO EN CIENCIAS E INGENIERÍA

***ESTIMACIÓN DEL BOMBEO DE AGUA SUBTERRÁNEA EN EL ACUÍFERO DE OJOS
NEGROS CON BASE EN EL MODELADO DEL FLUJO DE AGUA SUBTERRÁNEA***

TESIS

Que para cubrir parcialmente los requisitos necesarios para obtener el grado de

DOCTOR EN CIENCIAS

Presenta:

Marco Antonio Meza Gastelum

Ensenada, Baja California, México, Noviembre de 2024

UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA

FACULTAD DE INGENIERÍA, ARQUITECTURA Y DISEÑO

PROGRAMA DE MAESTRÍA Y DOCTORADO EN CIENCIAS E INGENIERÍA

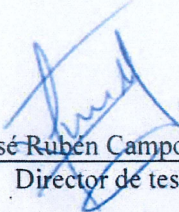
**ESTIMACIÓN DEL BOMBEO DE AGUA SUBTERRÁNEA EN EL ACUÍFERO DE OJOS
NEGROS CON BASE EN EL MODELADO DEL FLUJO DE AGUA SUBTERRÁNEA**

TESIS

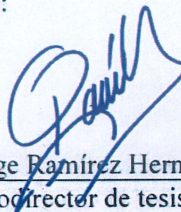
Que para obtener el grado de Doctor en Ciencias presenta:

Marco Antonio Meza Gastelum

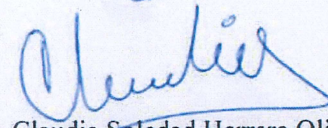
Aprobada por el siguiente comité:



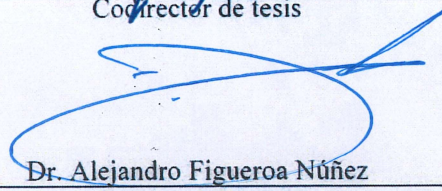
Dr. José Rubén Campos Gaytán
Director de tesis



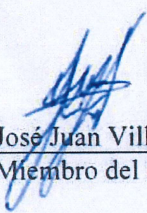
Dr. Jorge Ramírez Hernández
Cofrector de tesis



Dra. Claudia Soledad Herrera Oliva
Miembro del comité



Dr. Alejandro Figueroa Núñez
Miembro del comité



Dr. José Juan Villegas León
Miembro del comité

Ensenada, Baja California, Noviembre de 2024.

RESUMEN de la tesis de **Marco Antonio Meza Gastelum**, presentada como requisito parcial para la obtención del grado de DOCTOR EN CIENCIAS
Ensenada, Baja California, México, Noviembre de 2024.

ESTIMACIÓN DEL BOMBEO DE AGUA SUBTERRÁNEA EN EL ACUÍFERO DE OJOS NEGROS CON BASE EN EL MODELADO DEL FLUJO DE AGUA SUBTERRÁNEA

Resumen aprobado por:



Dr. José Rubén Campos Gaytán
Director de Tesis



Dr. Jorge Ramírez Hernández
Codirector de Tesis

Los acuíferos del Valle de Ojos Negros, en Ensenada, BC, México, son la principal fuente de agua para las comunidades locales. A lo largo del tiempo, se ha registrado un descenso en los niveles freáticos de estos acuíferos, principalmente, debido a las extracciones mediante bombeo. Esta situación ha resultado en un deterioro generalizado durante las últimas dos décadas, reflejado en un déficit en el volumen de almacenamiento de los acuíferos según los datos piezométricos disponibles.

Este estudio presenta una metodología para estimar el bombeo de agua subterránea en los acuíferos del Valle de Ojos Negros, mediante la implementación de un modelo de flujo basado en MODFLOW y un modelo de Redes Neuronales Artificiales (RNA), desarrollado en MATLAB. Además, se identificó la respuesta de los cultivos y la vegetación natural durante los años secos, cuando el agua subterránea se convierte en la única fuente de agua utilizando el NDVI. El modelo de flujo se adaptó y calibró para reducir las discrepancias con los registros de nivel freático (NF). La RNA se entrenó con los datos generados por el modelo de flujo, logrando estimar las descargas de agua subterránea. La distribución de las descargas mostró un patrón que refleja la fuerte explotación en las zonas central y sur del Acuífero de Ojos Negros, así como en las áreas norte y centro del Acuífero de Real del Castillo. La RNA logró redistribuir eficazmente los flujos hacia áreas de mayor demanda, especialmente, durante períodos de alta explotación.

Palabras clave: Acuíferos de Ojos Negros, Bombeo de agua subterránea, redes neuronales artificiales, NDVI.

ABSTRACT of the thesis of **Marco Antonio Meza Gastelum**, presented as a partial requirement to obtain the DOCTOR IN SCIENCES degree. Ensenada, Baja California, Mexico, August 2024.

ESTIMATION OF GROUNDWATER PUMPING IN THE OJOS NEGROS AQUIFER BASED ON GROUNDWATER FLOW MODELING

ABSTRACT

The aquifers of the Ojos Negros Valley, in Ensenada, BC, Mexico, are the main source of water for local communities. Over time, a decline in the water table levels of these aquifers has been observed, primarily due to extraction through pumping. This situation has resulted in a widespread deterioration over the last two decades, reflected in a deficit in the aquifer's storage volume according to available piezometric data.

This study presents a methodology to estimate groundwater pumping in the Ojos Negros Valley aquifers through the implementation of a flow model based on MODFLOW and an Artificial Neural Network (ANN) model developed in MATLAB. Additionally, the response of crops and natural vegetation during dry years, when groundwater becomes the only water source, was identified using the NDVI. The flow model was adjusted and calibrated to reduce discrepancies with water table records. The ANN was trained with data generated by the flow model, successfully estimating discharges. The distribution of discharges showed a pattern reflecting heavy exploitation in the central and southern areas of the Ojos Negros Aquifer, as well as in the northern and central areas of the Real del Castillo Aquifer. The ability of the ANN to effectively redistribute flows to areas of higher demand was especially prominent during periods of high exploitation.

Key words: Ojos Negros Aquifers, Groundwater Pumping, Artificial Neural Networks, NDVI.

DEDICATORIA

A Dios, por guiarme en cada paso de este camino.

A mis padres, Rosa Gastelum Verdugo y Marco Meza Patrón, por su infinita paciencia y esfuerzo, que me han permitido llegar a cumplir hoy un sueño más. Gracias por ser el pilar fundamental en mi vida y por inculcarme, desde muy joven, el ejemplo de esfuerzo, valentía y perseverancia. Sus enseñanzas sobre la importancia de no temer las adversidades y de enfrentar cada desafío con determinación han sido una guía constante en mi camino.

AGRADECIMIENTOS

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por financiar mis estudios de doctorado.

A mi director de tesis, Dr. José Rubén Campos Gaytán, por haberme guiado con sabiduría y paciencia, no solo en la elaboración de este trabajo de titulación, sino a lo largo de toda mi carrera universitaria. Su apoyo constante y su dedicación han sido fundamentales para mi desarrollo profesional y personal. Gracias a su liderazgo y a sus valiosos consejos, he podido enfrentar y superar los desafíos académicos, así como cultivar y fortalecer mis valores. Su ejemplo de excelencia y compromiso ha dejado una huella imborrable en mi formación.

A mi codirector de tesis, Dr. Jorge Ramírez Hernández, por su invaluable apoyo y aportes en el desarrollo de este proyecto de tesis, así como en los trabajos derivados de este. Gracias a sus sabios consejos, su dedicación, constante apoyo. Por facilitar mi visita a CONAGUA, cuya información fue de suma importancia para el desarrollo de este trabajo.

A la Dra. Claudia Soledad Herrera Oliva, por sus consejos, correcciones, y por el constante apoyo que siempre me ha brindado. Su contribución y orientación en mi desarrollo académico ha sido esencial para que hoy pueda culminar este trabajo.

Al Dr. Alejandro Figueroa Núñez y Dr. José Juan Villegas León, distinguidos miembros de mi comité de tesis. Al dedicar su tiempo, esfuerzo a este proyecto.

A mi amada Alejandra Duran Carrera, quien ha sido el pilar esencial en mi vida. Tu apoyo incondicional y tu compañía durante este trayecto han sido una parte esencial de mi existencia. Tu amor y tu presencia han iluminado cada paso de este camino, y estoy profundamente agradecido por tenerte a mi lado.

A mi gran amigo Luis Alonso Ceja Velazco. En los momentos en que el camino se tornaba difícil, su presencia y aliento fueron un bálsamo para el alma. Su amistad ha sido un regalo invaluable que valoro más de lo que puedo expresar con palabras. Estoy profundamente agradecido por su constante apoyo moral, brindándome fuerza y ánimo en cada paso del camino.

A mis amigos, quienes en conjunto enriquecieron el proceso de aprendizaje tanto académico como personal.

Y por último en memoria de mi querido amigo, cuya partida dejó un vacío en mi corazón, pero cuyo amor y compañía siempre serán recordados con cariño.

CONTENIDO

	Página
I. INTRODUCCIÓN.....	3
I.1. Planteamiento del problema	4
I.2. Objetivo General	4
I.2.1. Objetivos específicos.....	4
I.3. Descripción de la zona de estudio	4
I.3.1. Localización	5
I.3.2. Geología	7
I.3.3. Climatología	3
II. ANTECEDENTES.....	10
II.1. Trabajos académicos realizados en la zona de estudio.....	10
II.2. Antecedentes sobre el empleo de los métodos para la estimación del bombeo	11
II.2.1. Enfoques directos para estimar la GWW	13
II.2.2. Enfoques indirectos para estimar la GWW	14
II.3. Antecedentes sobre aplicaciones NDVI.....	18
II.4. Conceptos básicos para la aplicación de modelos.....	18
II.4.1. Modelo Numérico	18
II.4.2. Modelo Conceptual Hidrogeológico	19
II.4.3. Modelo Matemático	19
II.5. Herramienta de simulación (modelización)	20
II.6. Modelos en Diferencias Finitas.....	21
II.7. Modelos en Redes Neuronales Artificiales	21
II.7.1. La neurona artificial	22
II.7.2. Arquitectura de una RNA.....	22
II.7.3. Pesos sinápticos.....	23
II.7.4. Función de activación.....	24
II.7.5. El bias o parámetro umbral	25
II.7.6. Aprendizaje de una RNA	25
II.7.7. Aprendizaje supervisado	25
II.7.8. Perceptrón simple.....	25
II.7.9. La estructura de la red neuronal “Backpropagation” (retropropagación de errores, BP).....	26
II.7.10. Función de pérdida (Loss Function).....	27
II.7.11. Algoritmo de entrenamiento de un perceptrón.....	28
II.7.12. Algoritmo de optimización ADAM	30
II.7.13. Fases de entrenamiento y validación.....	31
II.7.14. Número de épocas	31
II.7.15. Sobreajustar los datos de entrenamiento	32
II.8. Error cuadrático medio.....	32
III. METODOLOGIA	33
III.1. Ecuaciones del flujo de agua subterránea en un acuífero	33
III.2. Datos espectrales.....	35
III.2.1. Procesamiento de datos espectrales	35
III.2.2. Análisis de variaciones interanuales	36
III.3. Selección de arquitecturas o modelos para las RNA	36
III.3.1. Entradas y salidas.....	38
III.3.2 Tratamiento previo de los datos	39
III.3.3 Evaluación del modelo de RNA usando un modelo de acuífero sintético...	40

CONTENIDO (CONTINUACIÓN)	Pagina
III.4 Descripción de los Datos Usados para La Implementación de los Modelos Neuronales y del Modelo Sintético.....	41
III.4.1. Registros del nivel freático	41
III.4.2. Ubicación de los puntos de observación	44
III.4.3. Asignación de los registros de nivel freático	46
III.4.4. Registros de precipitación.....	48
III.4.5. Conductividad hidráulica	50
III.4.6. Topografía Superficial y Basamento Impermeable	52
III.4.7. Evapotranspiración	56
III.4.8. Segmentación de Pozos de Descarga para la RNA: Dos Rangos de Entrenamiento.....	60
III.4.9. Entrenamiento de la RNA.....	62
III.4.10. Proceso de análisis de los datos	64
III.4.11. Datos utilizados en el modelo sintético.....	64
IV. RESULTADOS Y DISCUSIONES	67
IV.1 Configuración Del Modelo De Flujo Del Agua Subterránea.....	67
IV.1.1 Condiciones iniciales	67
IV.1.2. Dominio del modelo y discretización	68
IV.1.3. Discretización temporal	70
IV.1.4. Recarga y Descarga	71
IV.1.5. Coeficiente de almacenamiento	76
IV.2. Calibración del Modelo de Flujo	77
IV.2.1 Condición Inicial del Modelo de Flujo.....	79
IV.2.2 Condiciones Transitorias del Modelo de Flujo.....	81
IV.3. Registros de NDVI	84
IV.4. Resultados de la Simulación del Modelo de Flujo	92
IV.5. Resultados del Modelo Sintético con Aplicación de la RNA.....	95
IV.6 Resultados del modelo de flujo con la aplicación de RNA	97
IV.6.1. Resultados del modelo de RNA: julio de 1989.....	97
IV.6.1.1 Estimación de la descarga mediante RNA.....	101
IV.6.2 Resultados del modelo de RNA para agosto de 2013.....	107
IV.6.2.1 Estimación de la descarga mediante la RNA para agosto de 2013.....	111
IV.6.3 Resultados del modelo de RNA para noviembre de 2013	116
IV.6.3.1 Estimación de la descarga mediante la RNA para noviembre de 2013	120
IV.6.4 Resultados del modelo de RNA para noviembre de 2017	125
IV.6.4.1 Estimación de la descarga mediante la RNA para Noviembre de 2017 ...	129
V. ESTIMACIÓN DEL BOMBEO ANUAL DETERMINADO POR LA RNA.....	134
V.1. Mejoras en el modelo de flujo con la implementación de la RNA	136
VI. CONCLUSIONES	139
VII. LITERATURA CITADA	143
APÉNDICE A.....	152
APÉNDICE B.....	172
APÉNDICE C.....	174
APÉNDICE D.....	181
APÉNDICE E.....	182
APÉNDICE F.....	183

LISTA DE TABLAS

TABLA		Página
1	Características del modelo sintético adaptado de Figueroa (2018)	40
2	Datos del nivel freático empleados para la calibración del modelo de flujo. El símbolo "-" indica la falta de información disponible. AON hace referencia al acuífero de ON y ARC representa al acuífero de RC.....	42
3	Distribución de cada caso utilizado para la asignación del registro de nivel freático a la RNA. Los valores marcados con "-" indican fechas que no fueron modeladas por la RNA.	48
4	Registro de precipitación mensual (en mm) llevado a cabo durante el periodo 1983-2020 en las estaciones climatológicas del Valle de San Rafael (celda sombreada con un Color Morado) y Ojos Negros (celda sombreada con un Color azul), operadas por la CONAGUA y SIMARBC, respectivamente.....	49
5	Valores estimados de la conductividad hidráulica (k) (en m/mes), Anderson y Woessner (1992).....	50
6	Parámetros de topografía superficial, basamento impermeable y conductividad hidráulica para los pozos, periodo 1983 a 1991. Simbología: Topografía superficial en msnm (T); Basamento impermeable en msnm (B); Conductividad hidráulica en m/mes (K) y Coordenadas dentro del modelo en MODFLOW: columna (C) y renglón (R)	54
7	Parámetros de topografía superficial, basamento impermeable y conductividad hidráulica para los pozos, periodo 1991 a 2018. Simbología: Topografía superficial en msnm (T); Basamento impermeable en msnm (B); Conductividad hidráulica en m/mes (K); y Coordenadas dentro del modelo en MODFLOW: columna (C) y renglón (R)	55
8	Valores estimados por pérdidas de evapotranspiración para el periodo Primavera-Verano (P-V). Tomado de INIFAP (2016).....	56
9	Valores estimados por pérdidas de evapotranspiración para el periodo Otoño-Invierno (O-I). Tomado de INIFAP (2016).....	57
10	Áreas de cultivos de acuerdo con el INIFAP para las temporadas 2015-2016.....	58
11	Distribución de pozos de descarga para el periodo 1983 a 1991, segmentados en rangos entre 0 a 100,000 m ³ /mes (celda sombreada con Color Naranja) y 100,000 a 250,000 m ³ (celda sombreada con Color azul)	60
12	Distribución de pozos de descarga para el periodo 1992 a 2018, segmentados en rangos entre 0 a -100,000 m ³ /día (celda sombreada con Color Naranja) y -100,000 a 250,000 m ³ día (celda sombreada con Color azul)	61
13	Registro climatológico ingresado a MODFLOW y la RNA. Tomados de la base de datos CLICOM, estación meteorológica Olivares Mexicanos. Los datos de descarga y registros de NF corresponden al pozo_1 que se utilizó en el modelo de MODFLOW. Datos utilizados durante la validación (Color azul).....	65
14	Puntos de recarga horizontal por escurrimiento de las serranías interiores al dominio de flujo	73
15	Precipitación media anual (mm) para el periodo 1983-2021. Datos obtenidos de las estaciones climatológicas de Ojos Negros y Valle de San Rafael. Nota: El símbolo '-' indica que no hay información o datos disponibles	79
16	Valores promedio del NDVI en un área de 250x250 m alrededor de cada pozo seleccionado y registros del nivel freático (msnm). Nota: NF indica nivel freático. El símbolo '-' indica que no hay información o datos disponibles. Las celdas marcadas en verde representan fechas en las que la precipitación media anual fue mayor o igual a 150 mm.....	86

LISTA DE TABLAS (CONTINUACIÓN)

TABLA		Página
17	Valores promedios del RMSE. Nota: El símbolo "-" indica que no se dispone de información o datos. La columna de puntos de observación indica el número de pozos considerados con registro del NF.....	93
18	Resultados del entrenamiento de la RNA. Nota: Las RNA 1 y 3 indican el segmento de datos -100,000 a -250,000 m ³ /mes, y la RNA 2 valores de 0 a -100,000 m ³ /mes.....	99
19	Valores de descargas estimados por la RNA vs descargas previamente reportadas.	102
20	Resultados de la descarga estimada por la RNA en 1989.....	103
21	Comparación de los errores de ajuste vertical entre los NF observados contra los calculados con el modelo de Campos-Gaytán (2002), el modelo MODFLOW desarrollado en este trabajo, así como con el modelo MODFLOW desarrollado en este trabajo considerando la descarga estimada mediante la RNA.....	105
22	Resultados del entrenamiento de la RNA. Nota: La RNA 1 indica el segmento de datos 0 a -100,000 m ³ /mes, la RNA 2 indica de -100,000 a -250,000 m ³ /mes, ambos segmentos para RC.....	109
23	Descarga estimada por la RNA vs descarga previamente reportada para agosto 2013.....	111
24	Descarga estimada por la RNA para agosto 2013 en el ARC.....	112
25	Comparación de resultados obtenidos de la RNA comparados con el modelo de flujo para Agosto de 2013.....	114
26	Resultados del entrenamiento y validación de la RNA. Nota: La RNA 1 indica el segmento de datos 0 a -100,000 m ³ /mes, y la RNA 2 indica de segmento de -100,000 a -250,000 m ³ /mes.....	118
27	Descarga estimada por la RNA para Noviembre de 2013 vs descarga reportada. Simbología: C: Columna, R: Renglón, A: Descarga reportada (original; m ³ /mes), B: Descarga estimada por la RNA (m ³ /mes), E: Diferencia entre ambas descargas (%).....	120
28	Descarga estimada por la RNA para Noviembre de 2013 en el AON.....	121
29	Comparación de los resultados obtenidos de la RNA contra los calculados con el modelo de flujo para Noviembre de 2013.....	123
30	Resultados del entrenamiento y validación de la RNA para Noviembre de 2017. Nota: La RNA 1 indica el segmento de datos 0 a -100,000 m ³ /mes, y la RNA 2 indica de segmento de -100,000 a -250,000 m ³ /mes.....	127
31	Descarga estimada por la RNA para Noviembre de 2017 vs descarga previamente reportada. Simbología: C: Columna, R: Renglón, A: Descarga reportada (original; m ³ /mes), B: Descarga estimada por la RNA (m ³ /mes), E: Diferencia entre ambas descargas (%).....	129
32	Descarga estimada por la RNA para Noviembre de 2017 vs descarga previamente reportada. Simbología: C: Columna, R: Renglón, A: Descarga reportada (original; m ³ /mes), B: Descarga estimada por la RNA (m ³ /mes), E: Diferencia entre ambas descargas (%).....	130
33	Comparación de los resultados obtenidos de la RNA contra los calculados con el modelo de flujo para Noviembre de 2017.....	132
34	Registro de la descarga estimada por la RNA (m ³ /año).....	135
35	Error de ajuste vertical en el modelado. Nota: El símbolo “-” representa ausencia de datos.....	138

LISTA DE FIGURAS

Figura		Página
1	Localización de acuíferos en la cuenca de Guadalupe	5
2	Geología del VON (INEGI, 1997)	7
3	Precipitación media anual en el VON. A) Del período 1980-2022. B) Porcentaje del esquema de precipitación media mensual, con base en el registro histórico medido en las estaciones meteorológicas ubicadas dentro del VON y realizado por la CONAGUA	9
4	Proceso de búsqueda, selección e identificación de estudios de acuerdo con el diagrama de flujo PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) para nuevas revisiones sistemáticas, que incluyó búsquedas en bases de datos, registros y otra fuente (Page et al., 2021)	12
5	Representación gráfica de una neurona artificial. Las X_i dentro de los círculos en color verde representan las entradas de la red. La sumatoria dentro del círculo color azul representa la operación que realiza la neurona; la y_j dentro del círculo en color azul claro representa la salida de la red. La f dentro del recuadro negro representa una función de activación, y b_i es el bias. Modificada de Hagan et al. (2014)	22
6	Estructura general de las Redes Neuronales Artificiales. Las x_i dentro de los círculos verdes representan las entradas de la red. Las sumatorias dentro de los círculos de color azul representan la operación que realizan las neuronas, las y_j dentro de los círculos azul claro representan la salida de la red. Modificada de Hagan et al. (2014)	23
7	Funciones de activación utilizadas en una RNA	24
8	Diagrama de topología de una red BP. Modificada de Tian et al. (2022)	27
9	Cubo representativo del flujo en tres direcciones	34
10	Arquitectura o modelo de RNA seleccionada: donde x_1 = Precipitación; x_2 = Registro de nivel freático; x_3 = Conductividad hidráulica; x_4 = Topografía superficial; x_5 = Basamento impermeable, y x_6 = Evapotranspiración ...	38
11	Modelo sintético adaptado de Figueroa-Núñez (2018)	41
12	Registro de elevaciones del nivel freático en aprovechamientos de agua subterránea situados en el VON	43
12	CONTINUACIÓN. Registro de elevaciones del nivel freático en aprovechamientos de agua subterránea situados en el VON	44
13	Distribución de pozos de observación situados en el VON, periodo de observación 1989-1999, cuyo registro del NF fue empleado para reproducirse con la RNA	45
14	Distribución de pozos de observación situados en el VON, periodo de observación 2005-2018, cuyo registro del NF fue empleado para reproducirse con la RNA	46
15	Código de Conductividad Hidráulica (K en m/mes) para los Acuíferos de Ojos Negros y Real del Castillo	51
16	Elevaciones topográficas en el VON. a) Topografía superficial. b) Topografía del basamento impermeable. c) Isométrico elaborado con información de las topografías superficial y del basamento impermeable en el VON	53

LISTA DE FIGURAS (CONTINUACIÓN)

Figura		Página
17	Evapotranspiración de los cultivos y un área atribuida a cada cultivo de acuerdo con los Polígonos de Thiessen, en relación a la temporada y periodo de bombeo	59
18	Diagrama de flujo para el entrenamiento de la RNA	63
19	Topografía ingresada al modelo sintético en MODFLOW	66
20	Datos del NF en el AON durante el periodo 1972-1997 (extraídos de Beltrán, 1997).....	68
21	Características hidrológicas y aproximación del dominio de flujo del agua subterránea. Los límites irregulares de los acuíferos de estudio se reemplazaron con una configuración de líneas rectas	70
22	Recarga de agua subterránea, celdas con recarga de agua subterránea por infiltración directa de la precipitación media anual y recarga del frente de montaña	72
23	Descarga de aguas subterráneas: Ubicación de los pozos de bombeo considerados durante todo el período de simulación.....	75
24	Comparación de registros de las elevaciones del NF, calculadas vs observadas, para los AVON	77
25	Superficies piezométricas del NF calculados y observados. a) Estado estacionario para los AVON, enero de 1983. b) Estado transitorio para los AVON, noviembre de 2009 (después de 322 meses de simulación), 1983-2009. c) Estado transitorio para el AON, noviembre de 2011 (después de 346 meses de simulación), 1983-2011. d) Estado transitorio para el AON, abril de 2018 (después de 423 meses de simulación), 1983-2018.....	80
26	Hidrogramas de los pozos ubicados en los Acuíferos de Ojos Negros y Real del Castillo.....	82
27	Resultados para el análisis del NDVI en los AVON durante el periodo 2005 – 2018.....	88
28	Registro del NDVI promedio y del nivel freático	90
29	Resultados del entrenamiento para el caso de estudio sintético	95
30	Resultados de validación para caso de estudio sintético	96
31	Puntos de observación y pozos de descarga para julio de 1989	98
32	Resultados del entrenamiento del modelo neuronal para julio 1989. Entrenamiento y validación de la RNA: a) Para 9 pozos del AON. Rango de descarga considerado: -100,000 y -250,000 m ³ /mes. b) Para 12 pozos del AON. Rango de descarga considerado: 0 hasta-100,000 m ³ /mes. c) Para 5 pozos del ARC. Rango de descarga considerado: -100,000 hasta -250,000 m ³ /mes	100
33	Ajustes del NF para julio de 1989. a) Modelado del flujo de agua subterránea sin considerar las descargas estimadas mediante las RNA, y b) Modelado del flujo de agua subterránea considerando las descargas estimadas mediante las RNA.....	104
34	Registro del nivel freático (a) y mapa de residuales para julio de 1989 (b) ...	106
35	Puntos de descarga y registro del NF utilizados en el entrenamiento de la RNA para agosto 2013 en el ARC	108
36	Resultados del entrenamiento y validación para agosto 2013 en el ARC, únicamente: a) RNA para 14 pozos. b) RNA para 9 pozos	110

LISTA DE FIGURAS (CONTINUACIÓN)

Figura		Página
37	Ajustes del NF para agosto de 2013. a) Modelado del flujo de agua subterránea considerando la descarga estimada por la RNA contra los registros del NF interpolados; b) Modelado del flujo de agua subterránea considerando la descarga estimada por la RNA contra los registros oficiales, y c) Modelo de flujo sin considerar la descarga estimada por la RNA	113
38	Registros del nivel freático (a) y mapa de residuales para agosto de 2013 (b)..	115
39	Puntos de descarga y registros del nivel freático utilizados en el entrenamiento y validación de la RNA para noviembre de 2013.....	117
40	Resultados del entrenamiento y validación de la RNA para noviembre 2013 en el AON únicamente. a) RNA 1 con 29 pozos y considerando valores en el orden de -100,000 a -250,000 m ³ /mes, y b) RNA 2 con 25 pozos y considerando valores en el orden de 0 a -100,000 m ³ /mes.....	119
41	Ajustes del NF para Noviembre de 2013. a) Modelado del flujo agua subterránea considerando la descarga estimada por la RNA contra el registro del NF interpolado; b) Modelado del flujo de agua subterránea considerando la descarga estimada mediante por la RNA contra el registro oficial del NF, y c) Modelado del flujo de agua subterránea sin considerar la descarga estimada por la RNA	122
42	Registro del NF (a) y mapa de residuales (b) para Noviembre de 2013.....	124
43	Puntos de descarga y registro del NF utilizados en el entrenamiento y validación de la RNA para Noviembre de 2017	126
44	Resultados del entrenamiento y validación de la RNA para noviembre 2017. a) RNA 1 con 27 pozos, y b) RNA 2 con 32 pozos.....	128
45	Ajustes del NF para Noviembre de 2017. a) Modelado del flujo de agua subterránea considerando la descarga estimada por la RNA contra el registro del NF interpolado; b) Modelado del flujo de agua subterránea considerando la descarga estimada por la RNA contra el registro oficial del NF, y c) Modelado del flujo de agua subterránea sin considerar la descarga estimada por la RNA	131
46	Registro del NF (a) y mapa de residuales (b) para Noviembre de 2017.....	133

I. INTRODUCCIÓN

La escasez de agua representa un desafío crítico para la humanidad, agravado por la presión sobre los recursos hídricos debido al crecimiento poblacional, la agricultura intensiva, y la demanda industrial (Petronici et al., 2019). Se estima que el 98.7% del agua dulce líquida disponible se encuentra en forma subterránea (Ayibotele, 1992). Debido a que el agua subterránea abastece a una gran parte de la población, sufre estrés en términos de cantidad y calidad, especialmente en regiones áridas y semiáridas donde la demanda supera la oferta, llevando a la sobreexplotación de acuíferos (Margat, 2006; Martínez-Santos et al., 2018; Kundzewicz & DÖLI, 2009). Este recurso apoya la salud humana, el desarrollo económico y la biodiversidad (Rejani, Jha, Panda, & Mull, 2007). La agricultura es el principal consumidor de agua subterránea, representando casi el 70% de las extracciones, y en algunos países en desarrollo, hasta el 95% (FAO, 2017). Además, su accesibilidad y fiabilidad en tiempos de sequía lo convierten en un recurso clave para el desarrollo socioeconómico (Giordano, 2006). A pesar de su importancia para el suministro de agua dulce, la administración de este recurso suele estar mal controlada, por lo que resulta difícil, y a veces imposible, elaborar una imagen coherente de su disponibilidad (Famiglietti, 2011). Esto provoca que dicho recurso se vea afectado por una serie de factores, como la salinización, la contaminación y el rápido agotamiento (Wada et al., 2010). Para evitar una catástrofe, es necesario gestionar adecuadamente su explotación y protección (Chang et al., 2017; Panahi et al., 2020; Shao et al., 2014).

Por consiguiente, entender el uso del agua subterránea es crucial para la hidrogeología de los sistemas acuíferos y su planificación adecuada (Harris y Diehl, 2017; Murkowski, 2014). La capacidad de anticipar la respuesta de un acuífero al bombeo puede prevenir daños y garantizar una gestión sustentable del recurso (Hera-Portillo et al., 2021; Kent et al., 2020). Aunque la descarga de agua subterránea (GWW por sus siglas en inglés) es un componente de suma importancia en los modelos de balance hídrico, frecuentemente, es poco considerado y generalmente descuidado (Ruud, Harter y Naugle, 2004). La síntesis de datos sobre registros de pozos, descargas, recargas y propiedades de los acuíferos es fundamental para aplicaciones a escala global, pero aún está en sus etapas iniciales (Vörösmarty, Lévêque, y Revenga, 2005). La falta de métodos precisos y económicos para cuantificar la GWW en áreas extensas resalta la necesidad urgente de desarrollar estimaciones confiables, particularmente a través de pozos de bombeo (Castaño, Sanz y Gómez-Alday, 2010; Harris y Diehl, 2017; Hosseini et al., 2019).

En México, de los 653 acuíferos identificados, entre 100 y 106 se clasifican anualmente como sobreexplotados. A nivel mundial, México ocupa el séptimo lugar en extracción de agua, con un volumen anual de 87.4 (miles de millones de m³/año), y de esta cantidad, el 76% se utiliza en la agricultura (Comisión Nacional del Agua (CONAGUA), 2018).

En el ámbito estatal, Baja California cuenta con un total de 88 acuíferos, de los cuales 14 están sobreexplotados, la mayoría de estos afectados por intrusión salina (CONAGUA, 2018). Además, si consideramos que Baja California posee un clima árido y semiárido con bajos niveles anuales de precipitación, esto propicia que los recursos hídricos subterráneos adquieran gran importancia y requieran de un estudio integral, ya que es el recurso clave en el desarrollo económico de la región (Padilla Morín, 2013).

A pesar de los desafíos mencionados, el estado de Baja California desempeña un papel crucial en la agricultura comercial de México, destacándose por sus tres principales zonas agrícolas: el Valle de Mexicali, la Costa del Pacífico y la Zona Central. Esta última incluye áreas clave como el Valle de la Trinidad, Ojos Negros y el Valle de Guadalupe (Moreno Mena, 1999). El Valle de Ojos Negros (VON), en particular, importante para el desarrollo económico a nivel municipal y estatal, contribuye con el 3.09% al valor de la producción agropecuaria de Baja California (SEFOA, 2015). Dado que el Acuífero de Ojos Negros (AON) y el Acuífero de Real del Castillo (ARC) constituyen las únicas fuentes de agua para la agricultura en el VON (Ponce, 2009), es crucial contar con un procedimiento óptimo que asegure una precisión aceptable en la estimación de la GWW y que también minimice los errores de medición de manera significativa (Luckey, 1972). Por lo tanto, resulta crucial obtener estimaciones precisas de la GWW y comprender a fondo la dinámica de ambos acuíferos.

1.1. Planteamiento del problema

Administrativamente, los Acuíferos del Valle de Ojos Negros (AVON) pertenecen al Organismo de Cuenca Península de Baja California. Su territorio se encuentra completamente vedado y sujeto a las disposiciones del "Decreto por el que se establece veda para el alumbramiento de aguas del subsuelo en el Estado de Baja California"; cuya veda se clasifica como tipo III, en la que la capacidad de los mantos acuíferos permite extracciones limitadas para usos domésticos, industriales, de riego y otros (CONAGUA, 2018). La evolución anual del AON muestra un abatimiento, indicando que en general el acuífero está perdiendo volumen de agua subterránea (Comité Técnico de Aguas Subterránea del VON (COTAS), 2017). Si esta tendencia continúa, el acuífero enfrentará mayores dificultades para extraer agua para los cultivos. Por lo tanto, es necesario proponer alternativas que ayuden a mitigar esta escasez. Entre estas alternativas, se deben considerar el tipo y la cantidad de fuentes de recarga, así como otras formas de abastecimiento a largo plazo.

Con base en información de la CONAGUA (1997), el AON ha estado sometido a un régimen de sobreexplotación, lo que ha provocado modificaciones en sus condiciones naturales. En la actualidad, no se presentan salidas por flujo subterráneo, ni evapotranspiración debido a que los niveles del agua se han profundizado drásticamente. Asimismo, la explotación del recurso hídrico subterráneo es responsable del abatimiento del nivel freático (NF) en el AON, el cual fluctúa desde menos de 1m a un máximo de 13m, con un promedio espacial de 0.32m al año (Ponce et al., 2003). En los últimos años, se han desarrollado modelos de flujo de agua subterránea para los AVON con buenos resultados (Campos-Gaytán, 2002; Padilla Morín, 2013). No obstante, la incertidumbre en las prácticas de bombeo, donde cada usuario decide de manera independiente, junto con una gestión ineficaz de los recursos hídricos y posibles errores de medición, pueden inducir errores significativos en la estimación del bombeo necesario para la implementación de un modelo de flujo (Massuel et al., 2017).

Este estudio busca desarrollar un modelo conceptual en dos dimensiones del flujo de agua subterránea en los AVON, que permita una estimación más precisa de las GWW. El objetivo es lograr la mínima discrepancia vertical entre las elevaciones del NF observadas y las calculadas, prestando especial atención en las GWW a través de un procedimiento fundamentado en Redes Neuronales Artificiales (RNA)

1.2. Objetivo General

Estimar el bombeo de agua subterránea en los AVON mediante el empleo de un modelo conceptual geohidrológico en dos dimensiones del flujo de agua subterránea.

1.2.1. Objetivos específicos

Los objetivos particulares del presente proyecto de investigación son:

- Diseñar y aplicar un modelo del flujo de agua subterránea para estimar la descarga de los AVON y evaluar su eficacia.
- Estimar el bombeo de agua subterránea a través de una metodología basada en RNA.
- Reproducir las elevaciones históricas del NF en los AVON y estimar el volumen de explotación en los acuíferos ON y RC
- Es posible estimar el bombeo de agua de los acuíferos AVON a partir de las mediciones de elevación del NF utilizando RNA, el modelo de flujo y las mediciones históricas del NF.

1.3. Descripción de la zona de estudio

1.3.1. Localización

El VON está situado en el estado de Baja California, aproximadamente, a 40 km al noreste de Ensenada, con coordenadas 31°52' a 31° 57' de latitud Norte y 116° 12' a 116° y 19' de longitud oeste, su principal vía de acceso es la carretera No. 2 Ensenada-San Felipe (Ponce, 2009). El valle se encuentra separado fisiográficamente por el Cerro del Talco, el cual sitúa al sur a Ojos Negros (ON) y al norte Real del castillo (RC) (Campos-Gaytán, 2002; UABC,1999). La región estudiada es una depresión natural, con zonas montañosa a los alrededores, cubre un área de aproximadamente 173 km², los cuales corresponden a la superficie acuífera (Ponce et al., 2003), misma que forma parte de las tres subcuencas que componen la Cuenca Guadalupe, al noroeste del estado de Baja California, en la Región Hidrológica (Fig. 1) (Instituto Nacional de Estadística y Geografía (INEGI), 2017). La diferencia topográfica presente en el valle varía desde los 720 metros sobre el nivel del mar (msnm) en las zonas altas al sureste de ON y hasta los 670 msnm hacia el extremo noroeste de RC (Padilla Morín, 2013).

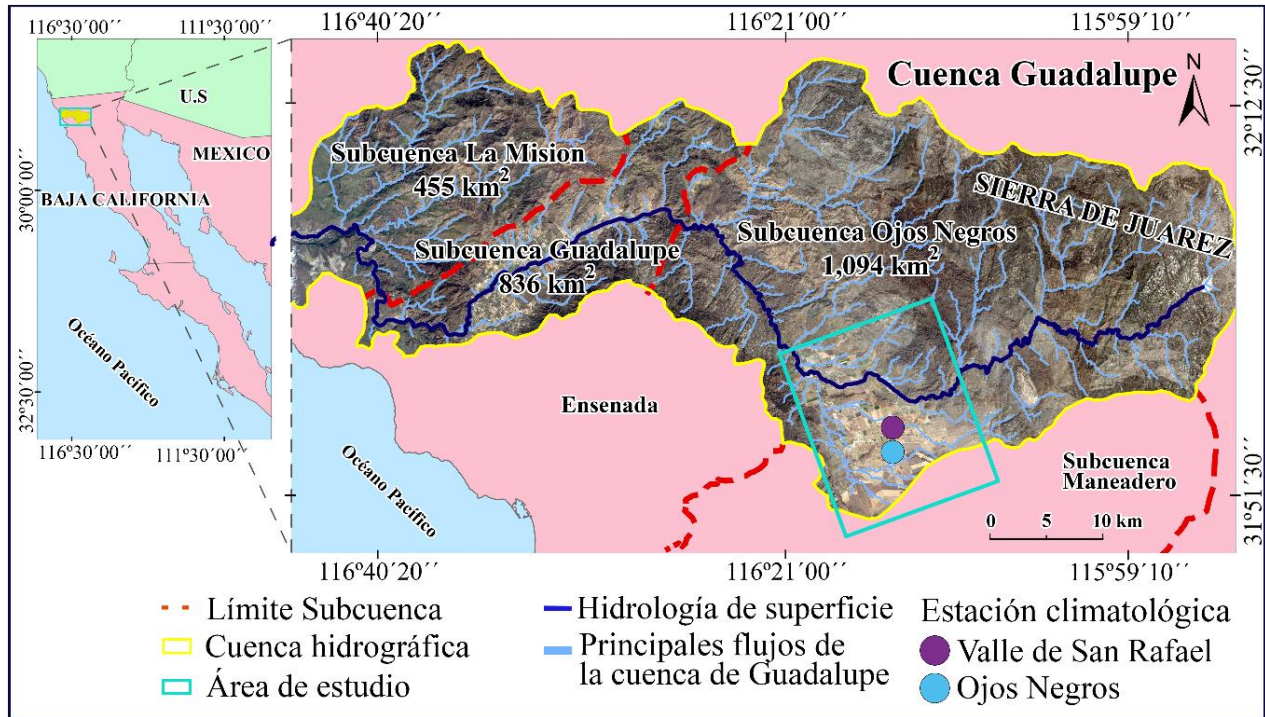


Figura 1. Localización de acuíferos en la cuenca de Guadalupe

1.3.2. Geología

El sistema hidrogeológico del VON comprende depósitos aluviales de diferentes espesores, formados por una combinación de arcillas, arenas y gravas. Debajo de estos depósitos se encuentran rocas metamórficas, ígneas intrusivas y extrusivas, que se manifiestan como afloramientos a lo largo de los márgenes del valle y en las serranías internas. El Gneis y los Esquistos son las rocas metamórficas predominantes en la zona, derivadas de rocas básicas y pelíticas sometidas a metamorfismo a través de procesos de contacto asociados con eventos plutónicos térmicos (Gastil et al., 1975).

Según COTAS (2017), el VON muestra una forma irregular con una orientación de Este a Oeste y una extensión promedio de 10.0 km por 11.3 km. En la parte oriental, está bordeado por el Cerro Las Flores y varios afloramientos de rocas ígneas, que actúan como barreras impermeables. Hacia el Oeste se encuentran las cadenas montañosas que separan las Subcuencas Ensenada y ON, compuestas por rocas metamórficas de origen ígneo. En el lado Sur, hay suelo residual de la meteorización de rocas ígneas, así como el Cerro Doña Eulalia, ubicado cerca de ON, que desempeña un papel hidráulico clave en el acuífero (COTAS, 2017).

Ercan (1999) menciona que el valle está clasificado como un graben, una depresión tectónica delimitada por dos fallas. Esta configuración geológica contribuye a la formación del relieve particular del valle, que se caracteriza por su nivel de elevación uniforme y predominantemente plano. Sin embargo, se pueden observar diferencias topográficas en el valle debido a la presencia de una cadena de cerros (Cerro del Talco) que se extienden en dirección Este-Oeste. Principalmente, compuestas por rocas ígneas ultramáficas y metamórficas, formando las Subcuencas de RC al Norte y ON al Sur (Secretaría de Agricultura y Recursos Hidráulicos (SARH, 1979) (Fig. 2).

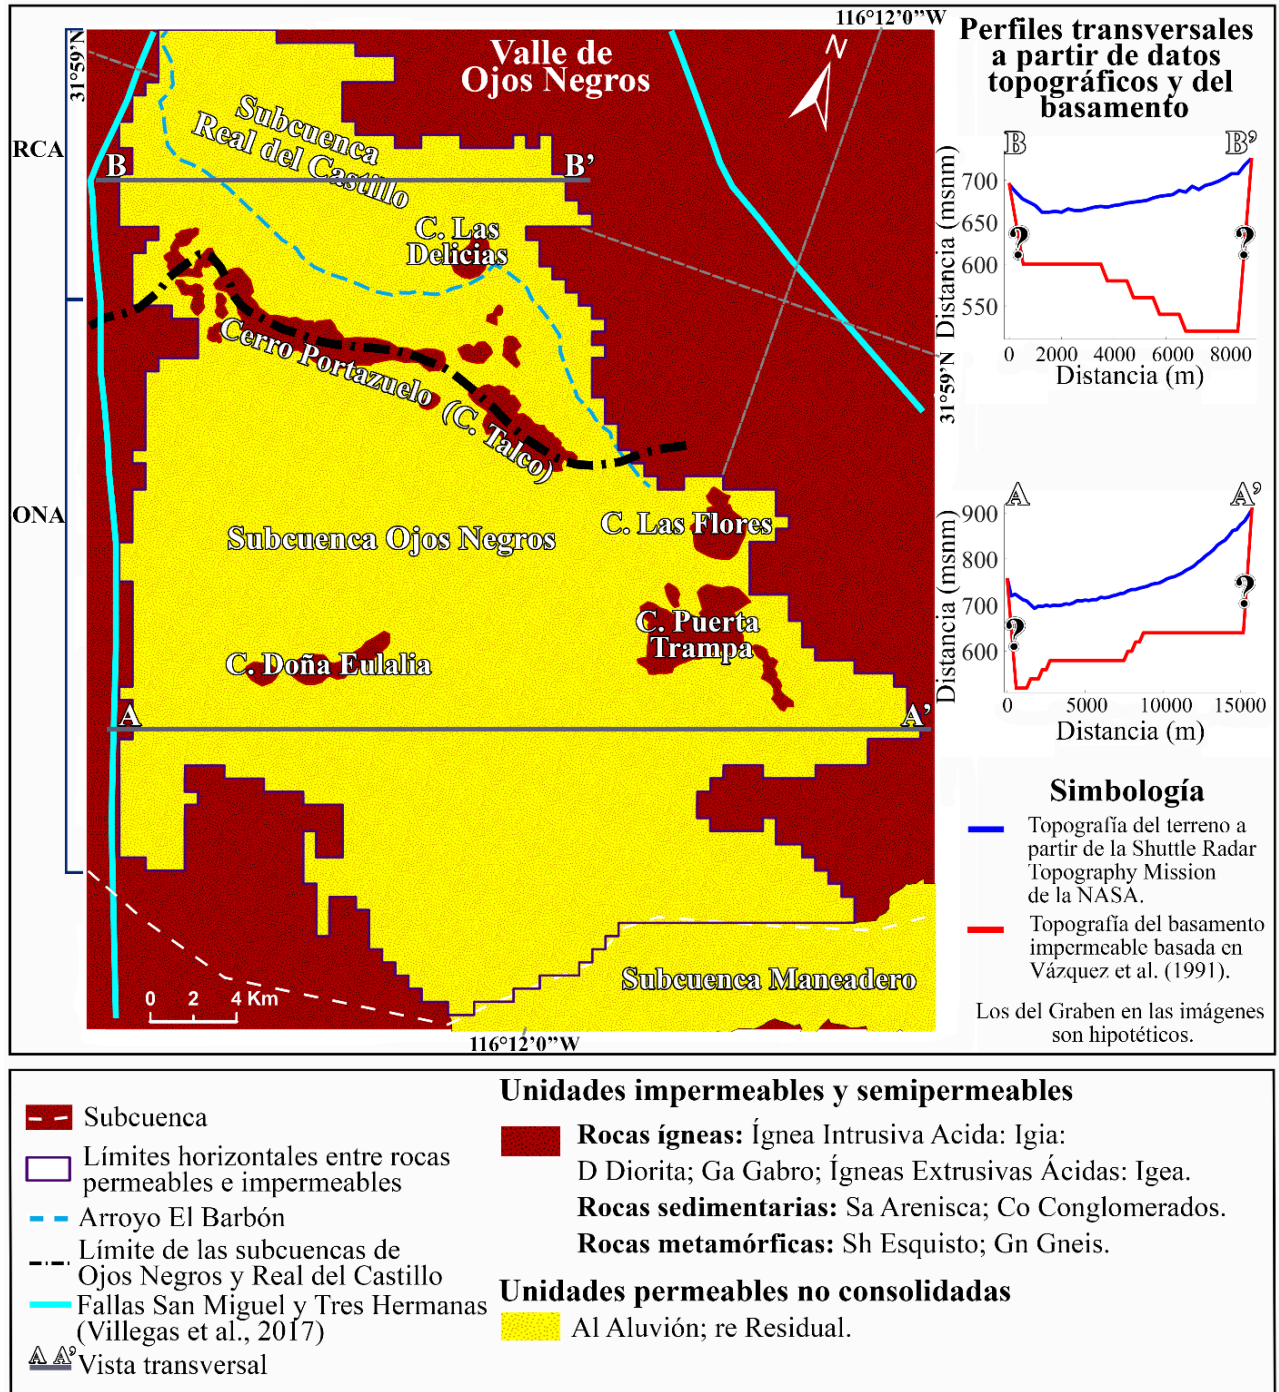
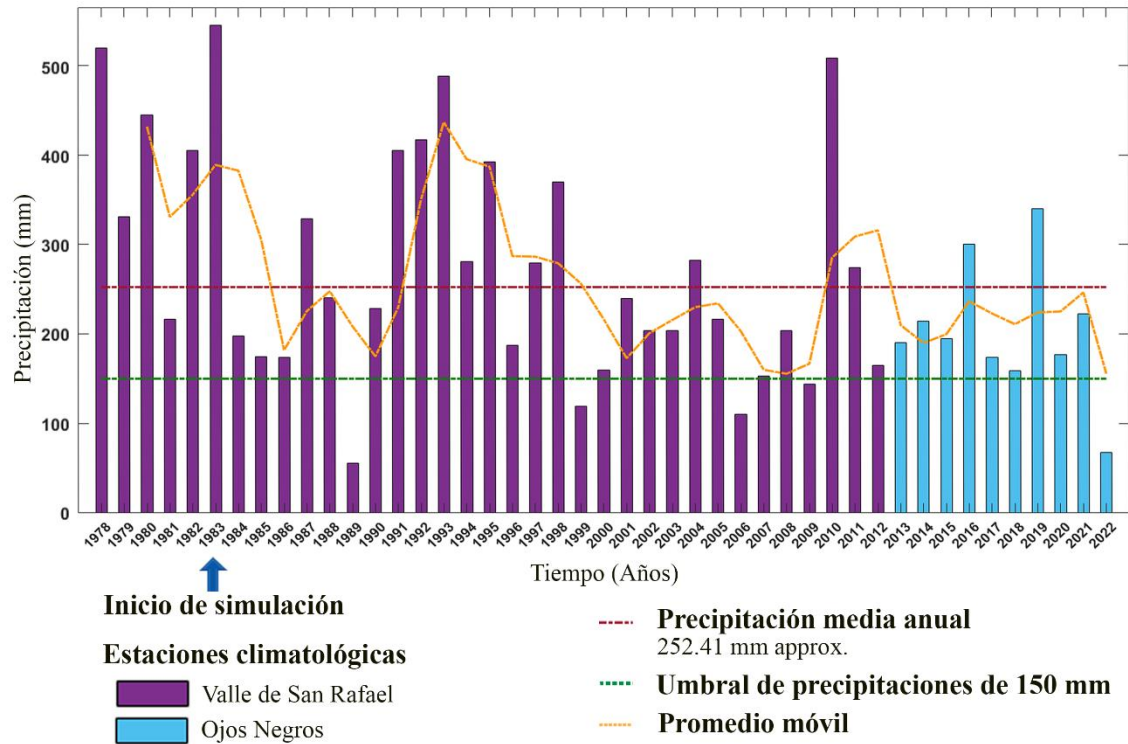


Figura 2. Geología del VON (INEGI, 1997)


I.3.3. Climatología

El VON cuenta con un clima árido, caracterizado por tener una única estación de lluvias durante el invierno, que abarca desde noviembre hasta abril, y experimenta una variación extrema de

temperaturas (INEGI, 2017). El clima se describe como frío y húmedo en invierno, y seco y caluroso en verano, según la clasificación climática de Köppen, modificada por García (1981), el clima de Ojos Negros se clasifica como BSh(s)(e'). Este tipo de clima está asociado con el ecosistema comúnmente conocido como "mediterráneo", que se encuentra en gran parte de la costa Oeste y Norte de Baja California, así como en la costa Sur de California, las temperaturas medias anuales varían entre 12 y 18 °C (Beltrán L., 1997; Escolero-Fuentes y Hernández-Rosas, 1992; INEGI, 2017). Las precipitaciones medias anuales oscilan entre 220 y 250 mm/año (Fig. 3a) en los últimos 30 años. La mayor parte de la lluvia anual ocurre durante los meses húmedos de invierno (de noviembre a abril) (Fig. 3b).



a)



b)

Figura 3. Precipitación media anual en el VON. A) Del período 1980-2022. B) Porcentaje del esquema de precipitación media mensual, con base en el registro histórico medido en las estaciones meteorológicas ubicadas dentro del VON y realizado por la CONAGUA

II. ANTECEDENTES

II.1. Trabajos académicos realizados en la zona de estudio

Los estudios previos realizados en los AVON corresponden a distintas instituciones; por ejemplo, Vázquez et al. (1991) realizó un modelo geohidrológico de los acuíferos ON y RC. En el cual, se definió la geometría de los acuíferos, la ubicación de las fronteras impermeables que limitan el dominio de flujo y los tipos de materiales que componen los acuíferos; además, estimó la profundidad del basamento impermeable a partir de estudios geofísicos. El modelo conceptual corresponde a un acuífero libre con medio heterogéneo de sedimentos no consolidados, sobre un basamento impermeable con topografía irregular, con recargas por infiltración vertical y horizontal, y en régimen transitorio. La descarga del modelo es producto de 38 pozos de extracción; mientras que, las condiciones iniciales se fijaron en 1983 con un periodo de simulación de 10 años y un intervalo de tiempo mensual.

Por otra parte, Beltrán (1997) evaluó el impacto en el AON debido a la explotación ocasionada por el incremento en los volúmenes de extracción de agua subterránea para uso agrícola. Mientras que, Ercan (1999) desarrolló un estudio geohidrológico del AON, considerando para su elaboración un modelo conceptual con características similares a las de Vázquez et al. (1991); sin embargo, el área de estudio fue menor, ya que solo se analizó el área correspondiente al AON. Además, las condiciones iniciales del modelo se fijaron en 1995 y la simulación consistió en un periodo de dos años. Para la simulación se consideraron 71 pozos de extracción en estado transitorio.

Posteriormente, se actualizó el modelo hidrogeológico de los AVON y las condiciones de explotación de los pozos de extracción. La evaluación del simulador, implementado con la información actualizada, reveló un descenso significativo del NF en el AON y un descenso menos pronunciado en el ARC, como resultado de las políticas históricas y actuales de explotación del agua subterránea (Campos-Gaytán, 2002).

Por otra parte, un modelo actualizado del AON reveló cambios en el espesor saturado y una mejora en la calidad de los datos de entrada. El descenso observado en los niveles freáticos (NF) de los pozos de seguimiento se atribuyó a la sobreexplotación agrícola. La ubicación y la magnitud de los pozos de extracción fueron fundamentales para calibrar y reproducir los NF registrados, lo que puso de relieve la importancia de medir las tasas de extracción por pozo para la sostenibilidad del acuífero. Sin embargo, el estudio se limitó a un pequeño número de pozos de monitoreo,

principalmente en el noroeste del valle, sin datos históricos disponibles para la zona sur (Padilla Morín, 2013).

II.2. Antecedentes sobre el empleo de los métodos para la estimación del bombeo

La revisión de documentos sobre el empleo de los métodos para estimar el bombeo, ha constituido una parte fundamental para el desarrollo de esta investigación y, como resultado de esa labor, se desarrolló el artículo *Review of Groundwater Withdrawal Estimation Methods* (Meza-Gastelum et al., 2022)(Apéndice A). A continuación, se presentan algunos de los trabajos considerados como más relevantes.

Ruud et al. (2003) y Parizi et al. (2019) utilizaron SIG en zonas semiáridas. Ruud et al. (2003) desarrollaron un modelo de balance hídrico basado en SIG para estimar el GWW en áreas agrícolas. Por su parte, Parizi et al. (2019) aplicaron entornos SIG para clasificar zonas con extracciones de agua subterránea, utilizando Las propiedades hidrogeológicas del acuífero y las propiedades de los pozos de bombeo.

Shao et al. (2014) y Moreo et al. (2003) utilizaron métodos basados en modelos de flujo, aplicando una metodología de inversión del principio de balance hídrico, para ajustar los NF simulados con los observados. Moreo et al. (2003) incluyó un modelo de flujo e imágenes satelitales para analizar y gestionar el agua subterránea. El modelo de flujo se utilizó para estimar las GWW anuales para diferentes usos con datos sobre las ubicaciones de los pozos y categorías de uso. Mientras que, las imágenes satelitales, se utilizaron para identificar y mapear áreas irrigadas. Shao et al. (2014) utilizó un método iterativo apoyado en un modelo de flujo de agua subterránea para estimar las GWW a través de la simulación de los NF, basándose en el principio del balance hídrico, que relaciona la recarga, descarga y extracción con los cambios en el NF. El proceso comienza con el cálculo de los NF simulados a partir de datos hidrogeológicos y tasas de extracción, los cuales se comparan con los NF observados. Si se encuentran discrepancias, las tasas de extracción se ajustan de manera iterativamente hasta lograr una coincidencia entre los NF simulados y observados.

Li et al. (2019) desarrollo un modelo de RNA basado en el algoritmo de retro-propagación para estimar la GWW, utilizando datos de NF, precipitación y descarga. Se compararon los resultados con datos oficiales y métodos de balance hídrico. Asimismo, Majumdar et al. (2020) desarrollo un enfoque de aprendizaje automático para predecir la GWW, para ello utilizo archivos raster y

vectoriales con una resolución espacial de 5 km utilizando información de varios satélites, como MODIS, PRISM y USDA-NASS.

Estos estudios, combinan modelos de flujo, SIG e inteligencia artificial, son algunas de las aplicaciones sobre los cuales se basa el desarrollo de este trabajo doctoral. La investigación y trabajo realizado, en la aplicación de los métodos para estimar la GWW, ha dado como resultado la clasificación y descripción de 34 estudios (Fig. 4).

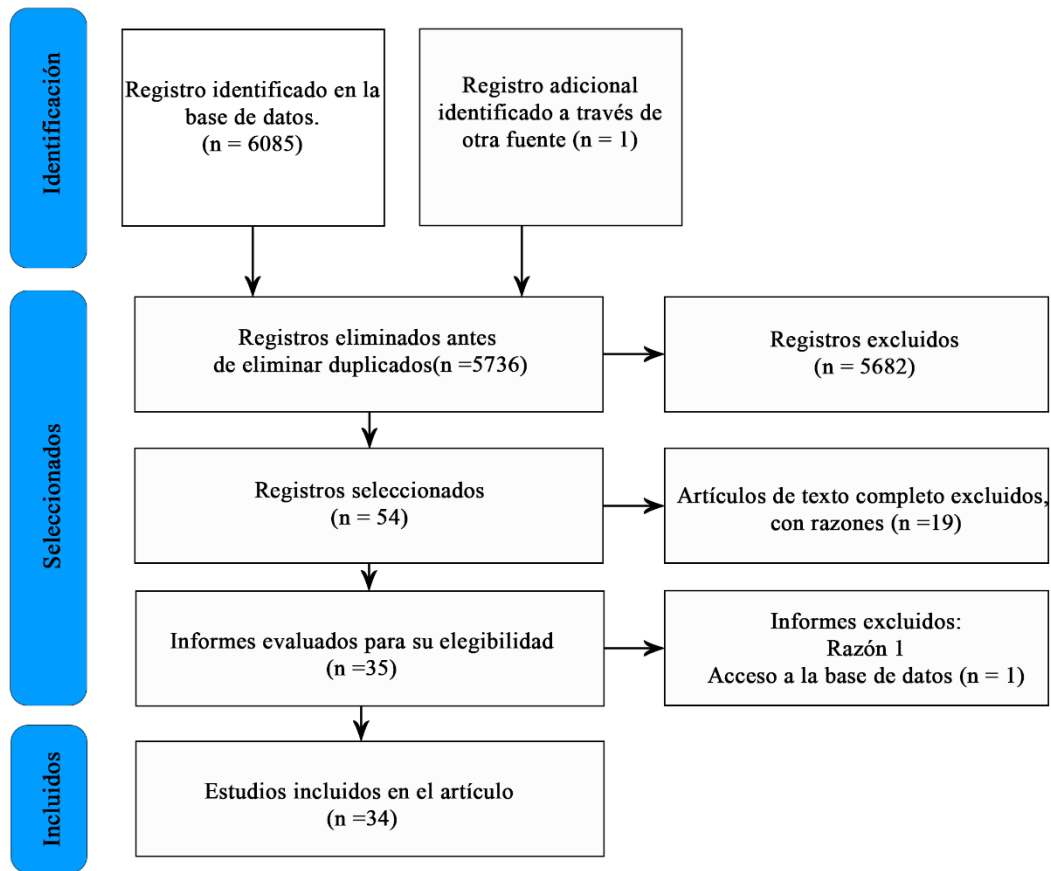


Figura 4. Proceso de búsqueda, selección e identificación de estudios de acuerdo con el diagrama de flujo PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) para nuevas revisiones sistemáticas, que incluyó búsquedas en bases de datos, registros y otra fuente (Page et al., 2021)

A continuación, se presentan las clasificaciones y metodologías aplicadas en la estimación de GWW. La estimación del GWW es una variable muy importante para la gestión de agua subterránea, ha sido una de las principales descargas de los acuíferos en las últimas décadas (Shao et al., 2014). Una gestión hidrológica adecuada de un acuífero depende del conocimiento sobre

GWW (Murkowski, 2014). Dado que, las estimaciones pueden subestimar las interacciones dentro de los sistemas acuíferos, pasando por alto las necesidades individuales de los usuarios y careciendo de datos para una gestión (Massuel et al., 2017).

Además, las GWW pueden intensificar riesgos geológicos como la intrusión salina y el hundimiento del terreno (Parizi et al., 2019). Investigaciones recientes indican que las actividades humanas alteran el ciclo hidrológico y la circulación del agua, lo que hace que la información sobre la GWW sea crítica para comprender la influencia humana (Kustu, Fan, y Robock, 2010). No obstante, cuantificarlas es complejo y conlleva incertidumbre, ya que puede variar espacial y temporalmente a lo largo del acuífero (Konikow y Neuzil, 2007).

Para estimar el bombeo de aguas subterráneas, se han empleado principalmente cuatro métodos: (1) análisis del consumo eléctrico de las bombas, (2) método del balance hídrico, (3) análisis del hidrograma de aguas subterráneas y (4) simulaciones con modelos numéricos (Liu, Hsu, y Yeh, 2015). Las investigaciones para estimar la GWW pueden dividirse en dos categorías, basadas en los criterios definidos para este estudio: Asociación con métodos directos o con métodos indirectos. Estas categorías permiten una clasificación sistemática y facilitan la comprensión de las metodologías empleadas. A continuación, se describen dichas categorías.

II.2.1. Enfoques directos para estimar la GWW

Se conocen como enfoques directos a los métodos en los que el volumen de extracción en cada estación de bombeo se mide (manual o automáticamente) o se calcula utilizando el método de tasa de tiempo multiplicando la velocidad promedio de la bomba por el tiempo de bombeo acumulado (Hurr y Litke, 1989). El método más preciso y fiable para hacer un seguimiento de la GWW es la instalación de caudalímetros en todos los pozos que bombean agua subterránea (Martindill, Good, y Loge, 2021). Sin embargo, los medidores de flujo generalmente no están aplicados en todas las regiones, además los propietarios de pozos de extracción generalmente se muestran poco dispuestos a instalar nuevos medidores de flujo, mismos que permitirían hacer un seguimiento preciso de las extracciones de agua subterránea en pozos agrícolas (Austin, 2014; Massuel et al., 2017). En la actualidad, la investigación de la explotación de agua subterránea sigue adoptando métodos directos para su estimación, no obstante, la aplicación de estos métodos puede resultar difícil, ya que las mediciones directas requieren datos que a menudo no se reportan, lo que podría

suponer un desafío para realizar estimaciones precisas (Richey et al., 2015; Su, Cui, Wang, y Li, 2012).

Pese a esto, la estimación de las tasas de bombeo puede llevarse a cabo mediante la transformación de los datos de consumo de energía eléctrica adquiridos de los pozos que realizan las GWW (Hurr y Litke, 1989). Dado que la relación entre el consumo de electricidad y el volumen de bombeo es una relación fiable, la precisión de estos métodos depende del censo de pozos de bombeo aunado a que los registros del consumo de electricidad de las bombas sean completos y precisos, datos más precisos conducen a una estimación más exacta del bombeo (Liu et al., 2015). Por ejemplo, Ogilbee y Mitten (1970) estimaron la GWW municipales y agrícolas para las principales cuencas de California en Estados Unidos. Elaboraron tablas con los datos del consumo total anual de electricidad y gas natural para el bombeo de agua subterránea, mismos que, se obtuvieron de las principales empresas de servicios públicos del centro de California. Los datos que se obtuvieron corresponden al volumen de agua subterránea bombeada para uso municipal de 27 comunidades cuya población oscilaba entre 1,000 y 145,000 habitantes. La metodología para determinar el factor de uso anual per cápita, mismo que, es utilizado para determinar el volumen de agua suministrado para uso municipal se realizó dividiendo la cantidad de agua por su población, de esta manera la cantidad de agua bombeada puede calcularse multiplicando la población de una comunidad por el factor de uso anual per cápita. Mientras que para estimar el bombeo de agua subterránea para uso agrícola se utilizó el bombeo en función de la superficie, utilizando el método del coeficiente de potencia (Ogilbee y Mitten, 1970).

II.2.2. Enfoques indirectos para estimar la GWW

Se conoce como enfoques indirectos a la estimación del volumen bombeado en función de los efectos que el agua extraída del acuífero produce en el acuífero mismo, o bien, por la aplicación del agua a un uso específico, podrían clasificarse en cinco grupos de acuerdo a las características y herramientas del enfoque: método de estimación basados en las demandas de agua de los cultivos; métodos de estimación basados en satélites; método de fluctuación del NF (WTF por sus siglas en inglés); enfoque de modelado de agua subterránea, y métodos basados en inteligencia artificial (Parizi et al, 2019).

Método de estimación basados en las demandas de agua para cultivos: Uno de los enfoques comúnmente utilizados es medir la superficie del cultivo regado y multiplicarla por las necesidades

hídricas de cada cultivo, este enfoque se utiliza en los acuíferos donde la principal actividad se basa en la agricultura (Belmonte et al., 2005; Zhang et al., 2014). Tal como Wray (1982), quien desarrolla un estudio para estimar el volumen de agua extraída empleando técnicas que combina datos multiespectrales con datos del bombeo de agua subterránea para las distintas temporadas de cultivos. En este método se definen la ubicación y la extensión de las tierras que poseen cultivos, algunas de ellas pudieran tener variaciones de tales cultivos. Para definir las características de cada uno se realiza un análisis por computadora de los datos obtenidos del satélite Landsat, de esta manera la cantidad de agua utilizada se calcula acumulando el producto de la superficie de cultivo por el bombeo promedio para las necesidades hídricas de cada tipo de cultivo (Wray, 1982).

Otro ejemplo de esta aplicación es Tillman et al. (2012), quienes estimaron las GWW basado en la vegetación natural para un área de más de 190,000 km² utilizando datos de teledetección mediante satélites para una cuenca en el estado de Arizona, ubicada al suroeste de Estados Unidos. Se emplearon datos del Índice de Vegetación Mejorado (EVI por sus siglas en inglés) de los sensores EOS-1 MODIS. Además, se estableció una relación entre la evapotranspiración, el EVI y la temperatura para calcular la GWW producto de la vegetación. El objetivo de este proyecto se enfocaba principalmente en el desarrollo de un método sencillo para determinar la GWW utilizando empleando la vegetación en una zona donde no se cuenta con información completa sobre la humedad del suelo así como la profundidad del NF (Tillman, Callegary, Nagler, y Glenn, 2012).

Método de estimación basado en satélites: Los métodos basados en teledetección y sistemas de información geográfica (SIG) pueden promover precisión al momento de estimar la explotación de un acuífero (Joodaki, Wahr, y Swenson, 2014). Por ejemplo, Ruud et al. (2004) desarrollaron un modelo del balance hídrico basado en SIG para estimar el bombeo anual de agua subterránea Implementando en una zona agrícola en un entorno semiárido al sur del Valle de San Joaquín, California, EE. UU. El modelado hidrológico basado en SIG reúne y procesa los datos de entrada disponibles, para calcular los componentes claves del modelo de balance hídrico a escala de cuenca, estimando y evaluando el bombeo de agua subterránea y los cambios en el almacenamiento (Ruud et al., 2004). Siguiendo este mismo enfoque, Ahmad et al. (2005) propone una técnica para estimar el uso neto del agua subterránea en grandes zonas de regadío, mediante la combinación de teledetección y de balance hídrico. Esta metodología se basa en el uso combinado de información obtenida por teledetección y técnicas de SIG para estimar las componentes del balance hídrico las

cuales son: la distribución de la tasa de riego, la tasa de precipitación neta, la tasa de evapotranspiración y el cambio en el almacenamiento de humedad del terreno en el área no saturada. Estimando uso neto del agua subterránea en la agricultura (Ahmad, Bastiaanssen, y Feddes, 2005).

Enfoque del modelado de agua subterránea: En este enfoque, el número de pozos de bombeo y el volumen de extracción se calibran mediante un modelo de flujo de agua subterránea (Parizi et al., 2019). Por ejemplo, Moreo et al. (2003) desarrollo el modelo numérico para estimar las GWW de Death Valley, Nevada y California, USA. Los sitios de extracción se estimaron mediante el modelo numérico (Moreo, 2003). Dicho enfoque también fue aplicado por Martos-Rosillo et al. (2009) en la provincia de Sevilla, España, mediante el análisis de series temporales y un modelo numérico de agua subterránea se cuantificó la explotación y se estimó la recarga promedio anual de dos acuíferos (Martos-Rosillo et al., 2009). Mientras tanto, Tsanis y Apostolaki (2009) presentan un método para cuantificar la explotación del recurso hídricos subterráneos fundamento del balance hídrico, considerando la descarga de una cuenca en combinación con las mediciones del volumen del agua subterránea extraído.

Método de fluctuación del nivel freático (WTF por sus siglas en inglés): Este enfoque utiliza la correlación del cambio de almacenamiento del agua subterránea y las fluctuaciones de los niveles freáticos (rendimiento específico en el caso de acuíferos no confinados) se basa en la suposición de que el aumento del NF en un punto de observación durante la temporada de recarga es causado por la recarga, dicho aumento se multiplica por el rendimiento específico para obtener una estimación directa de la recarga (Tsanis y Apostolaki, 2009).

Este enfoque utiliza la correlación entre el cambio en el almacenamiento de agua subterránea y las fluctuaciones de los niveles freáticos (rendimiento específico en acuíferos no confinados) y se basa en suponer que el aumento del NF en un punto de observación durante la temporada de recarga es causado por la recarga; este incremento se multiplica por el rendimiento específico para obtener una estimación directa de la recarga (Tsanis y Apostolaki, 2009).

Normalmente, el método WTF se combina con la ecuación de equilibrio del agua subterránea y un método geoestadístico para estimar el bombeo anual de la GWW. Por ejemplo, Martínez-Santos y Martínez-Alfaro (2010) desarrollan una adaptación del método WTF para estimar el bombeo de agua subterránea en zonas agrícolas del centro de España, acoplando el método de WTF con la ecuación de equilibrio del agua subterránea (Martínez-Santos y Martínez-Alfaro, 2010).

Asimismo, Yang et al. (2018) desarrollaron un método modificado de WTF para caracterizar cuantitativamente los patrones regionales de la GWW en acuíferos sometidos a estrés causado por el bombeo agrícola intensivo. El estudio desarrolla el método denominado regresión de la fluctuación del NF (WTFR por sus siglas en inglés) y está diseñado para caracterizar sistemas que son impulsados tanto por procesos de recarga por precipitación como por descarga neta. Como base del método WTF, en un punto de observación se definen dos parámetros: la eficiencia de infiltración y el módulo de descarga. Donde el primero es una relación entre la cantidad de precipitación y el incremento del NF, y el segundo es una matriz de 12 elementos que representa el patrón de la descarga neta. De tal manera que, se define el módulo de descarga como la reducción de altura neta debido al resultado colectivo de la descarga de bombeo y el retorno de riego (Yang et al., 2018).

Métodos basados en inteligencia artificial: Recientemente se han desarrollado modelos impulsados por inteligencia artificial, como las RNA y los sistemas de inferencia neuro-fuzzy adaptativo (ANFIS), mismos que, han demostrado su eficiencia en aplicaciones de sistemas hidrológicos (Emamgholizadeh, Moslemi, y Karami, 2014; Güldal y Tongal, 2010). Por consiguiente, la aplicación de los métodos basados en inteligencia artificial para la determinación de la GWW es una herramienta a la cual los autores recurren. Por ejemplo, Majumdar et al. (2020) enfoca las correlaciones entre varias mediciones del balance hídrico y las extracciones de agua subterránea en un marco de aprendizaje automático, mismos que aprende la relación entre los distintos conjuntos de datos y los utiliza de forma predictiva. El enfoque de aprendizaje automático para predecir las GWW a escala local utiliza archivos tipo ráster y vectoriales con resolución espacial de 5 km, tomando la información de distintos satélites, por ejemplo, la evapotranspiración (MODIS), la precipitación (PRISM) y los datos de uso del suelo (USDA-NASS), mismos que se relacionan de distintas maneras con las extracciones de agua subterránea (Majumdar, Smith, Butler, y Lakshmi, 2020). Por otro lado, Li et al. (2019) desarrollaron un modelo de RNA basados en el algoritmo “backpropagation” para estimar la descarga de agua subterránea. Para ello, se establecieron como entradas a las RNA: NF, precipitación y descarga de agua subterránea. Utilizando 5 capas ocultas y 144 datos para entrenar las RNA; los cuales fueron registros de descarga del agua subterránea. Los resultados se compararon con los datos oficiales y con el método de balance hídrico (Li, Hu, Zhang, y Liu, 2019).

II.3. Antecedentes sobre aplicaciones NDVI

El índice de vegetación de diferencia normalizada (NDVI) es una relación de la reflectancia en las bandas rojo y del infrarrojo cercano, utilizado comúnmente como un indicador del crecimiento de la vegetación terrestre, el cual está relacionado con el proceso radiación fotosintética activa (Myneni et al., 1995). El NDVI se ha utilizado para describir las variaciones de la vegetación en distintos estudios (W. Sun et al., 2015; Tao et al., 2019; Zhang et al., 2013). Además, para evaluar diferentes tipos de vegetación en relación con los cambios climáticos y la actividad humana, con el fin de desarrollar estrategias que aborden tales desafíos (Jiang et al., 2017).

Además, se ha analizado las relaciones entre el NDVI y los factores climáticos a diferentes escalas (Ichii et al., 2002). Por otro lado, el NDVI tiene mayor relación con la temperatura que con la precipitación, variando según la estación, además las actividades humanas han influido en las tendencias del NDVI en varias regiones (Sun et al., 2015).

Aguilar et al. (2012) compararon patrones de NDVI con la precipitación y la profundidad del NF. Sus resultados mostraron que los valores más altos de NDVI aunado a una mayor cobertura de vegetación se registraron en años húmedos. Además, se encontró relación entre el NDVI y la precipitación acumulada, así como con la profundidad del NF.

II.4. Conceptos básicos para la aplicación de modelos

Para la implementación de un modelo numérico se requiere: a) construir un modelo conceptual; b) definir el modelo matemático que describa el comportamiento del flujo de agua subterránea, y c) construir el modelo numérico que resuelva de manera aproximada la ecuación matemática que describe el comportamiento del flujo de agua subterránea (Anderson y Woessner, 1992).

II.4.1. Modelo Numérico

Un modelo numérico del flujo de agua subterránea representa computacionalmente el sistema de un acuífero, se basa en los parámetros físicos que rigen el flujo subterráneo y los procesos de entrada y salida correspondientes (López, 2014).

En la elaboración del modelado de agua subterránea, se utilizan diferentes técnicas de solución numérica, siendo las más comunes el método de diferencias finitas, el método de elementos finitos y el método de elementos analíticos. Cada una de estas técnicas tiene sus propias fortalezas y

limitaciones como, disponibilidad, costo, facilidad de uso, aplicabilidad y nivel de conocimiento requerido por el usuario (Al-Salamah et al., 2011).

La solución de dichos modelos matemáticos se logra, mediante las técnicas numéricas del elementos finitos o diferencias finitas centrales. Este último con incrementos espaciales en ambas direcciones horizontales, esto requiere la división de la zona de estudio en una malla, teniendo en cuenta las propiedades hidráulicas del acuífero (Trescott y Larson, 1977). Así mismo, el uso de diferencias finitas implica subdividir el área de interés en celdas o elementos y definir las condiciones de contorno (Bear, 2013). Entre las ventajas de este método se encuentra su facilidad de aplicación, su amplia documentación y la confiabilidad de los resultados (Mehl y Hill, 2004; Zhao, 2013). Sin embargo, presenta desventajas, como su adaptación inapropiada a las fronteras irregulares de un modelo (McDonald y Harbaugh, 1988).

II.4.2. Modelo Conceptual Hidrogeológico

La construcción del modelo conceptual constituye un paso fundamental de la modelación numérica (Anderson et al., 2015). Este es el primer paso de la modelación, y tal vez el más importante dado que el modelo deberá de refleje el funcionamiento del acuífero, basándose en la información disponible sobre los parámetros que determinan su comportamiento, los cuales influirán en el nivel de detalle y en el tipo de modelo a construir (Todd y Mays, 2004). Anderson y Woessner (1992), define un modelo hidrogeológico conceptual como una representación gráfica simplificada del sistema acuífero organizando datos recolectados en campo relacionados con el problema real. Para crear un modelo conceptual, se requiere reunir datos geológicos, geofísicos, geohidrológicos y climatológicos que estén directamente relacionados con el sistema de flujo de agua subterránea (Fetter, 2018). Entre los factores que deben definirse se encuentran: Geometría del acuífero, coeficiente de almacenamiento, permeabilidad, transmisividad, régimen hidráulico (es acuífero libre, confinado o semiconfinado) y enfoque del modelo (una dimensión (1D), dos dimensiones (2D) o tres dimensiones (3D)).

II.4.3. Modelo Matemático

Un modelo matemático simula indirectamente el flujo de agua subterránea, mediante una ecuación gobernante que representa los procesos físicos que ocurren dentro del sistema, la cual se

complementa con condiciones de frontera, que describen los niveles o flujos en los límites del modelo (Anderson y Woessner, 1992). Una vez que el modelo conceptual se traduce en un modelo matemático en forma de ecuaciones de gobierno, con condiciones iniciales y de contorno asociadas, se puede obtener una solución transformándola en un modelo numérico y escribiendo un programa (código) de computadora (Bear, 1992; Konikow, 2007). La modelación matemática es reconocida como un enfoque efectivo para prever el comportamiento de agua subterránea, que fundamenta su estructura en la discretización espacial del acuífero, esto permite incorporar de manera detallada su variabilidad y características específicas (Domenico y Schwartz, 1997).

II.5. Herramienta de simulación (modelización)

Para la simulación del flujo de agua subterránea se utilizó MODFLOW-2005, desarrollado por McDonald y Harbaugh (1988). MODFLOW-2005 es una herramienta de modelado ampliamente utilizada a nivel mundial, que permite simular procesos del flujo de agua subterránea en dominios bidimensionales y tridimensionales representados por una cuadrícula (Taie Semiromi y Koch, 2019). A pesar de haber sido desarrollado hace más de dos décadas, ha experimentado importantes actualizaciones y mejoras recientes debido a los esfuerzos de diversos grupos de trabajo en todo el mundo (Gossel, 2013). Integrando principios físicos como la ley de Darcy y el balance de masa para el flujo subsuperficial, MODFLOW puede modelar condiciones tanto en estado estacionario como transitorio en acuíferos con características variadas, como acuífero libre (o no confinados), confinados, y condiciones que varían entre ambos (Kim et al., 2008). Además, permite la simulación de diversas influencias externas, tales como el flujo de pozos, la recarga por área, la evapotranspiración, el drenaje y el flujo a través de ríos, teniendo en cuenta la variabilidad espacial de las conductividades hidráulicas y los coeficientes de almacenamiento, lo que permite modelar condiciones anisotrópicas (McDonald y Harbaugh, 1988).

MODFLOW se ha utilizado para determinar los cambios en el flujo y los niveles de agua subterránea causados por la recarga natural, la extracción artificial y eventos hidrológicos específicos (Jang, Liu y Chou, 2012; Jang et al., 2016). Su construcción se basó inicialmente en un acuífero de capa única, utilizando la ecuación de flujo de agua subterránea en dos dimensiones (Anderson y Woessner et al., 2015; Leake, 1997; Restrepo et al., 1998).

II.6. Modelos en Diferencias Finitas

MODFLOW, es un software que utiliza diferencias finitas y técnicas iterativas para conseguir la solución del sistema de ecuaciones para cada intervalo de tiempo (Harbaugh, 2005). El proceso iterativo comienza con la asignación de valores iniciales en cada nodo y, una vez la resolución numérica del sistema de ecuaciones es completada por el software, se generan nuevos valores. Estos nuevos valores introducen nuevamente en el sistema, reemplazando a los anteriores y repitiendo el procedimiento de manera cíclica hasta que cada iteración sean iguales menores que error de convergencia (el registro histórico del NF) o hasta alcanzar el número máximo de iteraciones (Fetter, 2001).

II.7. Modelos en Redes Neuronales Artificiales

Las RNA son modelos computacionales inspirados en los procesos del sistema nervioso biológico, tienen la capacidad de aprender basados en la experiencia además de generalizar y abstraer características de los datos que son utilizados en la capa de entrada (Izaurieta y Saavedra, 2000; Kohonen, 1988). Dichos modelos a menudo requieren menos datos y esfuerzo que aquellos basados en leyes físicas, dado que aprenden de manera autónoma (Coppola et al., 2003; Goodfellow, Bengio y Courville, 2016; Maren, 1990). Se han establecido como aproximadores universales, mapeando son capaces de mapear relaciones complejas y no lineales, con aplicaciones satisfactorias en diversos campos (Hornik et al., 1989). Además, las RNA son especialmente útiles cuando se procesan señales como imágenes o sonidos que han sido convertidos en datos digitales, imitando la forma en que el cerebro humano toma decisiones (Lee y Kim, 2022; Yamashita, Nishio, Do y Togashi, 2018).

En la aplicación de los recursos hídricos, los modelos de RNA han demostrado su aplicación en la gestión de dichos recursos, como estudios de campo que se utilizan para reproducir el flujos y niveles de agua (Aichouri et al., 2015; Lee y Kim, 2022; Park y Chung, 2020; Schulze et al., 2005). El desarrollo de las RNA se puede desglosar en al menos dos generaciones (Gao, Shi, Fukuda, Li y Huang, 2019). La primera generación de RNA incluye modelos muy simples, como el perceptrón multicapa (Javed et al., 2021) y la red neuronal Hopfield, que se componen de neuronas umbral (Mohd Jamaludin et al., 2020). En la segunda generación de RNA, las neuronas ya no emplean la función de umbral para calcular sus salidas, en cambio, utilizan funciones de activación no lineales para aproximarse a funciones arbitrarias (Tian et al., 2022). Esta última generación de RNA

también ha mejorado los algoritmos de aprendizaje, permitiendo que el modelo aprenda de manera autónoma las características a partir de los datos como la red “back-propagation” (BP por sus siglas en inglés) (Lv, 2021) y la red neuronal convolucional (Shafiq y Azim, 2021).

Esta investigación se centra en las RNA de segunda generación. Las cuales, están diseñadas para emular las funciones neuronales comunes y su organización estructural se inspira en la complejidad del cerebro humano (Tian et al., 2022; López y Fernández, 2008).

II.7.1. La neurona artificial

La neurona artificial está diseñada para replicar las funciones esenciales de una neurona biológica (Goodfellow et al., 2016). Recibe múltiples señales de entrada, cada una ponderada por un coeficiente que simula la fuerza de una conexión sináptica. La suma ponderada de estas señales determina el grado de activación de la neurona (López y Fernández, 2008). En la Figura 5 se ilustran los elementos que constituyen una neurona.




Figura 5. Representación gráfica de una neurona artificial. Las X_i dentro de los círculos en color verde representan las entradas de la red. La sumatoria dentro del círculo color azul representa la operación que realiza la neurona; la y_j dentro del círculo en color azul claro representa la salida de la red. La f dentro del recuadro negro representa una función de activación, y b_i es el bias. Modificada de Hagan et al. (2014)

II.7.2. Arquitectura de una RNA

Como se muestra en la Figura 6, una RNA está compuesta por tres principales capas: la capa de entrada, que recibe señales del exterior a través de sus unidades; las capas ocultas, que la cual pueden ser una red monocapa compuesta por una única capa oculta (Fig. 6a) o varias capas ocultas (red multicapa, Fig. 6b) que procesan la información sin conexión directa con el exterior; y por

último la capa de salida, donde se produce la respuesta final de la red (Valderrama-Purizaca et al., 2020).

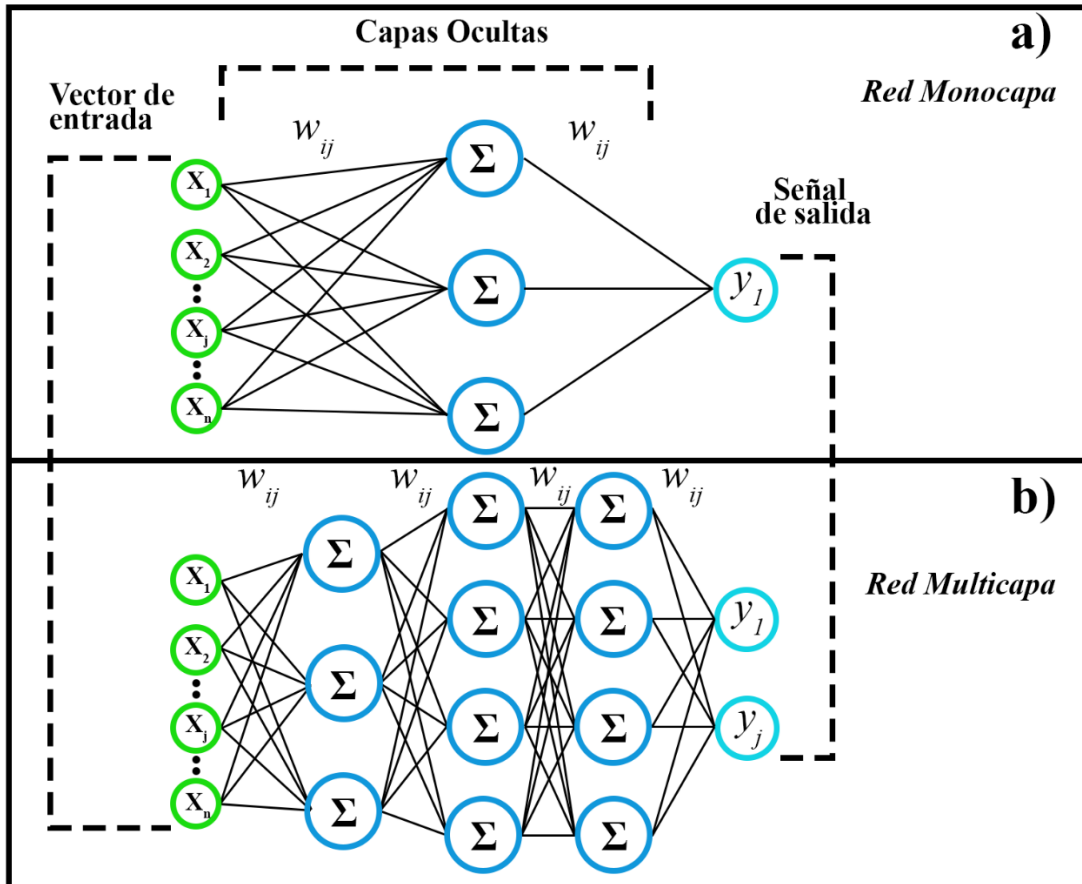


Figura 6. Estructura general de las Redes Neuronales Artificiales. Las x_i dentro de los círculos verdes representan las entradas de la red. Las sumatorias dentro de los círculos de color azul representan la operación que realizan las neuronas, las y_j dentro de los círculos azul claro representan la salida de la red. Modificada de Hagan et al. (2014)

II.7.3. Pesos sinápticos

Los pesos sinápticos (w_{ij}) actúan como canales de comunicación, conectando cada unidad de la capa de entrada con las neuronas de las capas siguientes. En las redes multicapa, estos pesos conectan la salida de cada neurona con las neuronas de la capa siguiente (Fig. 6b). Las redes que transmiten señales en una sola dirección, desde la entrada hasta la salida de la RNA, se conocen como redes “feedforward” o también conocidas como propagación hacia adelante. Por otro lado, las redes recurrentes permiten que las señales fluyan en ambas direcciones, hacia adelante y hacia

atrás. Los pesos sinápticos juegan un papel importante, ya que representan el aprendizaje de la red sobre un problema específico (Kang y Banerjee, 2017).

II.7.4. Función de activación

La función de activación (f) se selecciona en función de las necesidades del problema a resolver por la neurona. Comúnmente, esta función es de tipo binario y decide si la neurona se activará para transmitir información o si permanecerá inactiva, lo que generaría como resultando en una salida nula (Goyal et al., 2020). Las funciones de activación más utilizadas se presentan en la Figura 7.

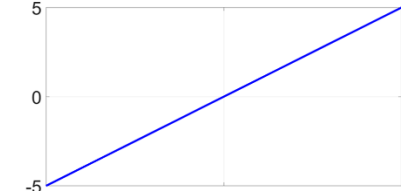
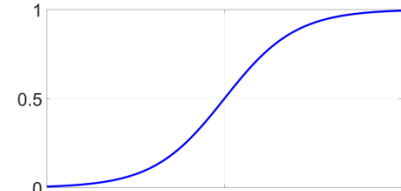
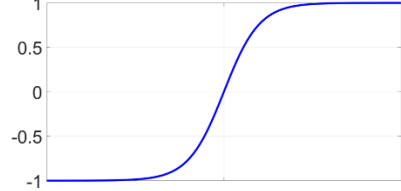
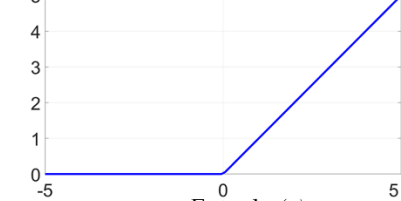
Tipos de Función	$f(x)=$	Gráfica
Lineal	x	
Sigmoidea	$\frac{1}{(1+e^x)}$	
Tangente Hiperbólica	$\frac{(e^x - e^{-x})}{(e^x + e^{-x})}$	
ReLU	$\begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases}$	

Figura 7. Funciones de activación utilizadas en una RNA

II.7.5. El bias o parámetro umbral

El bias es un componente de suma importancia en las RNA, dado que permite aprender y representar funciones complejas, por ejemplo, desplazamientos y transformaciones no lineales de los datos (Wei et al., 2018; Wang et al., 2023). Durante el proceso de entrenamiento de una RNA, el bias se ajusta iterativamente con los pesos de las conexiones (Jia et al., 2021). Esto se hace mediante el algoritmo de entrenamiento (descenso de gradiente, o el algoritmo de Hebb) con el objetivo de minimizar la función de pérdida y permitir que la red se adapte mejor a los datos de entrenamiento.

II.7.6. Aprendizaje de una RNA

Las RNA tiene la capacidad de aprender. El cual ocurre a través de un proceso iterativo en el que se ajustan continuamente los pesos sinápticos (w_{ij}) y el bias. Durante cada iteración, la red ajusta estos parámetros para mejorar su rendimiento y predicciones, de tal manera, que adquiere experiencia y conocimiento del problema que está resolviendo (Aggarwal, 2018; Fausett, 1994).

II.7.7. Aprendizaje supervisado

El aprendizaje supervisado inicia con un conjunto de datos conocidos, compuesto por entradas (x_i) y sus correspondientes valores de salida, también denominados salidas deseadas o etiquetas (y_j) (Berry, Mohamed, y Yap, 2019), este tipo de entrenamiento se puede aplicar para ajustar los parámetros (sesgos y ponderaciones) con el fin de obtener la salida de red deseada (Vásconez et al., 2023). De forma iterativa, la RNA modifica sus parámetros para reducir la diferencia entre las salidas producidas y las esperadas (Ciaburro y Venkateswaran, 2017). El objetivo del aprendizaje supervisado es afinar la RNA mediante el conjunto de valores que se pueden entrenar (Wei et al., 2018). Una de las características de este tipo de aprendizaje radica en su confiabilidad y precisión (Venkatesan y Kulkarni, 2016).

II.7.8. Perceptrón simple

El perceptrón simple es un modelo de RNA de una sola capa (Rosenblat, 1958), es un modelo simple que puede utilizar un algoritmo de aprendizaje supervisado para ajustar los pesos sinápticos

en tareas de clasificación binaria. Rosenblatt utilizó un perceptrón de una sola capa para la clasificación de patrones linealmente separables (Du y Swamy, 2013). En la Figura 6 se muestra un diagrama de la estructura de un modelo neuronal. El cual, se integra por una serie de elementos de entrada, denotados como x_i , que pueden ser producto de la capa de entrada o como de conexiones con otras neuronas. Cada neurona procesa estas entradas realizando una suma ponderada; es decir, cada entrada x_i se multiplica por un peso específico w_{ij} asociado a esa conexión. El resultado de dicha operación se ingresa en una función de activación, la cual es la encargada determina si la neurona se activará o se inhibirá. Así, basándose en las entradas x_i , la RNA es capaz de generar una salida y_j . Este proceso puede ser representado formalmente de la siguiente manera:

$$y_j = f\left(\sum_{i=1}^n w_{ij}x_i + b_i\right) \quad (1)$$

donde f representa la función de activación, generalmente se utiliza la misma función de activación para cada neurona, y el parámetro b_i representa el bias.

Posteriormente, el aprendizaje supervisado compara la salida de la red y la salida deseada. Es un sistema de ciclo, con el error como señal de retroalimentación, para hacer que el error se aproxime a cero. Generalmente, se aplica un procedimiento de descenso de gradiente con el algoritmo de retropropagación de errores (BP por sus siglas en ingles). (Du et al., 2022; Del Brío y Molina, 2001).

II.7.9. La estructura de la red neuronal “Backpropagation” (retropropagación de errores, BP)

La estructura de BP ha ganado una gran popularidad como modelo de redes neuronales debido a su sencillez, sólida capacidad de generalización y facilidad de comprensión e implementación, entre otros beneficios (Tian et al., 2022). En términos generales, la red consta de tres componentes fundamentales: la capa de entrada, que recibe los datos iniciales; la capa intermedia o capa oculta, que procesa los datos, y la capa de salida la encargada de mostrar los resultados o predicciones de la RNA (Figura 8). Por lo general, la capa oculta de BP consta de 1 o 2 capas, y sus neuronas están interconectadas con las neuronas en las capas previas y subsecuentes. El proceso de cálculo de las neuronas se basa en la multiplicación y suma de las entradas de cada capa junto con sus respectivos

pesos sinápticos. La ecuación 1 describe el proceso que se realiza en las neuronas.




Figura 8. Diagrama de topología de una red BP. Modificada de Tian et al. (2022)

Las neuronas o nodos en cada capa se interconectan en una disposición de alimentación hacia adelante (feedforward), estas conexiones entre las distintas capas de nodos tienen pesos asociados que inciden en las salidas de la primera capa de nodos antes de su procesamiento subsiguiente (Aggarwal et al., 2007). Mientras que, la BP consiste en propagar el error desde la capa de salida hacia las capas ocultas de la red para ajustar los pesos sinápticos y mejorar el rendimiento del modelo (Fig. 8). La red neuronal BP tiene la ventaja de contar con un entrenamiento efectivo y un buen entendimiento del sistema neuronal (Sinha et al., 2007).

II.7.10. Función de pérdida (Loss Function)

Para que un algoritmo de aprendizaje automático sea capaz de ajustar un modelo a los datos de entrenamiento, es muy importante contar con una función que evalúe cuán cercanos están los valores predichos (salidas del modelo) en comparación con los valores verdaderos (objetivos o valores de entrenamiento) (Salar y Ahmadi, 2023). Esta función se le conoce como función de pérdida o costo y la elección de ella va depender de la tarea o problema a resolver, por lo cual puede variar (Yuan, Xiong, y Huai, 2003; Zhang y Wu, 2008). Durante el desarrollo de este trabajo, se utilizó el error cuadrático medio, ya que, demostró un buen desempeño con el modelo neuronal. Se define mediante la siguiente expresión:

$$\text{Error Cuadrático Medio (E)} \quad \sqrt{\frac{1}{P * S} \sum_{p=1}^P \sum_{i=1}^S (y_i^p - d_i^p)^2} \quad (2)$$

donde: P representa el número total de datos o patrones de entrenamiento; S número total de datos de salida; y_i^p salida actual de la neurona, y d_i^p la salida objetivo.

II.7.11. Algoritmo de entrenamiento de un perceptrón

El principio fundamental del entrenamiento es muy simple, se calcula un error de entrenamiento basado en una función de pérdida que refleja la diferencia entre la salida de la red y el valor objetivo o ejemplo de entrenamiento, posteriormente, los pesos y sesgos de la red se actualizan de una manera que reduce el error de entrenamiento (Pérez González, 2021).

El algoritmo de BP es parte esencial del entrenamiento para la mayoría de las RNA; este se basa en la regla de la cadena del cálculo diferencial, que permite calcular los gradientes de error en función de las sumas de productos de gradientes locales a lo largo de los distintos caminos desde un nodo hasta la salida, el cual puede ser descrito por dos fases (Aggarwal, 2018). Fase hacia adelante, se utiliza la ecuación 1 y se adapta para cada capa oculta de la RNA de la siguiente manera:

$$y_j^{(l)} = \sum_{i=1}^n w_{ij}^{(l)} \cdot x_i^{(l-1)} + b_i^{(l)} \quad (3)$$

$$a_j^{(l)} = f(y_j^{(l)}) \quad (4)$$

para cada capa $l = 1, 2, \dots, L$; donde $y_j^{(l)}$ es la entrada a la neurona j de la capa l , $w_{ij}^{(l)}$ es el peso de la conexión en la capa l , $x_i^{(l-1)}$ es la activación de la neurona anterior en la capa $l - 1$ (salida de la neurona anterior), $b_i^{(l)}$ bias de la neurona i en la capa l , f representa la función de activación, $a_j^{(l)}$ es la activación de la neurona en la capa l . La fase hacia atrás (retropropagación), se calcula el gradiente del error con respecto a los pesos en la última capa. Para ello, se utiliza la regla de la cadena del cálculo diferencial; la cual, descompone el gradiente del error total con respecto a la

salida de la red (la función de pérdida) en una serie de gradientes parciales con respecto a las activaciones de la última capa (Rodríguez-Sánchez, 2023). Por practicidad y para simplificar las fórmulas, se considerará una RNA compuesta por una sola capa y una neurona. En este caso, el cálculo del gradiente de la función de pérdida se puede expresar de la siguiente manera:

$$\frac{\partial E}{\partial w^l} = \frac{\partial y^l}{\partial w^l} \cdot \frac{\partial a^l}{\partial z^l} \cdot \frac{\partial E}{\partial a^l} \quad (5)$$

$$\frac{\partial E}{\partial b^l} = \frac{\partial y^l}{\partial b^l} \cdot \frac{\partial a^l}{\partial z^l} \cdot \frac{\partial E}{\partial a^l} \quad (6)$$

para cada capa $l = 1, 2, \dots, L$, donde E es la función de pérdida. La ecuación 5 representa el gradiente de la función de pérdida respecto a los pesos sinápticos. Mientras que la ecuación 6 representa el gradiente de la función de pérdida respecto al bias. Posteriormente, se actualizan los pesos sinápticos y el bias utilizando algún algoritmo de optimización, como el descenso del gradiente estocástico (SGD, por sus siglas en inglés):

$$w^l = w^l - \eta \frac{\partial E}{\partial w^l} \quad (7)$$

$$b^l = b^l - \eta \frac{\partial E}{\partial b^l} \quad (8)$$

donde η es la razón de aprendizaje. Por otro lado, la regla de Hebb es el método más común para determinar los pesos. El algoritmo consiste en realizar correcciones a los pesos, con base en el error cometido. Es decir, cada entrada x_i está asociada a un peso w_{ij} , el cual se ajustará con base en la diferencia entre la salida y_j calculada por la RNA y el valor esperado d_j , de este modo la RNA se auto corrige (Isasi y Galván, 2004). A continuación, se muestra este algoritmo de aprendizaje:

$$w_{ij}^{k+1} = w_{ij}^k + \Delta w_{ij}^k \quad (9)$$

$$\Delta w_{ij}^k = \eta (d_j^k - y_j^k) x_i^k$$

$$b_i^{k+1} = b_i^k + \eta (d_j^k - y_j^k)_i^k \quad (10)$$

donde η es la razón de aprendizaje, d_j el valor deseado, y_j el valor obtenido y x_i la entrada aplicada al perceptrón; este proceso de entrenamiento también se aplica al bias.

II.7.12. Algoritmo de optimización ADAM

ADAM (Adaptive Moment Estimation) es un algoritmo de optimización popular que combina las ideas de Propagación media cuadrática (RMSprop por sus siglas en inglés) (Kingma y Ba, 2014), adapta las tasas de aprendizaje para cada parámetro, y momentum. Este ultimo acelera el entrenamiento al considerar el gradiente pasado, para ajustar los pesos de manera más eficiente durante el entrenamiento de una RNA (Aguilar et al., 2021; Goodfellow, Bengio y Courville, 2016). A continuación, se explica de manera general cómo funciona ADAM:

- Promedio ponderado de los cuadrados de los gradientes anteriores (v_t): ADAM calcula un promedio ponderado de los cuadrados de los gradientes anteriores similar a RMSprop. Utiliza (β_1) como un hiperparámetro que controla el decaimiento de los gradientes anteriores, generalmente igual a 0.9. Este proceso se realiza con la siguiente expresión:

$$v_t = \beta_1 v_{t-1} + (1 - \beta_1) \left(\frac{\partial E}{\partial w_{t-1}^l} \right)^2 \quad (11)$$

donde v_{t-1} es el promedio de los cuadrados de los gradientes anteriores en el paso de tiempo anterior ($t - 1$). Mientras que, ∂w_{t-1}^l es el gradiente de la función de pérdida con respecto a $t - 1$.

- El promedio ponderado de los gradientes anteriores (m_t) es similar al concepto de momento, pero en lugar de calcular el promedio ponderado de los gradientes directamente, considera el promedio ponderado de los cuadrados de los gradientes. Esto implica utilizar una tasa de decaimiento (β_2) para determinar qué tan fuerte deben ser los gradientes anteriores en la influencia del cálculo general. Por lo general, se establece en 0.999. La fórmula para actualizar (m_t) es la siguiente:

$$m_t = \beta_2 m_{t-1} + (1 - \beta_2) \left(\frac{\partial E}{\partial w_{t-1}^l} \right) \quad (12)$$

- Actualización de los pesos. Finalmente, ADAM utiliza los promedios v_t y m_t corregidos y actualiza los parámetros de la RNA de la siguiente manera:

$$w_t = w_{t-1} - \frac{\eta}{\sqrt{v_t + \epsilon}} * m_t \quad (13)$$

donde η es el factor de aprendizaje, ϵ es valor generalmente mínimo entre el rango de 10^{-9} y 10^{-8} .

.II.7.13. Fases de entrenamiento y validación

La fase de entrenamiento como pone uno de los aspectos más importantes de las RNA es el periodo en el que la RNA lleva a cabo el aprendizaje. Durante esta etapa, la red ajusta gradualmente sus pesos sinápticos para acercarse a la respuesta deseada (salida deseada). Una vez que se completa este proceso de entrenamiento, sigue la fase de validación, en la cual la red se considera operativa o en funcionamiento y es durante esta fase que sus pesos sinápticos ya no son modificados. El modelo perceptrón multicapa puede ajustarse de manera continua y tras completar el entrenamiento, el modelo puede cumplir su objetivo de clasificar o reconocer patrones específicos (Wu y Feng, 2018).

II.7.14. Número de épocas

La cantidad de veces que todo el conjunto de datos de entrenamiento se ha pasado hacia adelante y hacia atrás a través de la RNA durante el proceso de entrenamiento se denomina una "época". En términos generales, puede haber múltiples épocas, y el proceso de aprendizaje concluye cuando la red responde de manera correcta a todos los pares de entrenamiento (Izaurieta y Saavedra, 2000). Usualmente, se necesitan numerosas épocas, en ocasiones alcanzando cifras de decenas de miles, para llevar a cabo un entrenamiento eficaz de una red neuronal (Ciaburro y Venkateswaran, 2017).

II.7.15. Sobreajustar los datos de entrenamiento

El problema del sobreajuste se refiere al hecho de que ajustar un modelo a un conjunto de datos de entrenamiento particular no garantiza que proporcionará un buen rendimiento de predicción en datos de prueba no vistos, incluso si el modelo predice los objetivos en los datos de entrenamiento perfectamente (Aggarwal, 2018). Esto quiere decir que el modelo funciona bien con los datos de entrenamiento, pero no logra generaliza bien (Géron, 2022). Dado que, una gran mejora en el conjunto de entrenamiento y una menor en el conjunto de pruebas (Validación) muestra que se ha especializado de forma excesiva con los datos de entrenamiento, esto podría sugerir un proceso frecuentemente llamado sobreentrenamiento o sobreajuste (Moroney, 2020).

II.8. Error cuadrático medio

Para evaluar el desempeño de los modelos desarrollados en este estudio, se calculará el error cuadrático medio (RMSE, por sus siglas en inglés), también denominado desviación cuadrática media, un parámetro estadístico comúnmente utilizado que mide la diferencia cuadrada promedio entre los valores predichos por un modelo y los valores observados (Vélez y Nieto, 2016). Este se calcula mediante la siguiente expresión:

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N [hm^i - hc^i]^2 \right]^{0.5} \quad (14)$$

donde N corresponde a número de pozos analizados, hc^i es la elevación del NF calculada, hm^i es la elevación del NF, e i el orden de incremento.

III. METODOLOGIA

En este capítulo se describen los fundamentos de la ecuación que rige el flujo de agua subterránea y se presenta la estructura propuesta para la implementación de la RNA desarrollada en este trabajo de tesis para la estimación de la GWW, así como los criterios empleados para la evaluación y el desempeño del modelo neuronal.

III.1. Ecuaciones del flujo de agua subterránea en un acuífero

El flujo en los acuíferos se rige por los principios de la Ley de Darcy, la cual nos indica la velocidad con la que fluye un volumen de agua debido a relaciones de energía de mayor a menor altura piezométrica, por lo que se expresa como la proporcionalidad del área y la diferencia de alturas inversamente proporcional a la longitud recorrida (Darcy, 1856):

$$Q = -KA \times \left(\frac{h_1 - h_2}{L} \right) = -KA \times \frac{dh}{dl} \quad (15)$$

donde: Q = Volumen de agua por unidad de tiempo; dh = Diferencia entre los niveles de agua; h_1, h_2 = Niveles de agua; L = Longitud del recorrido del flujo; K = Conductividad hidráulica, y A = Sección transversal.

El signo negativo es debido a que el gradiente tiende a moverse en direcciones desde un punto de mayor altura hasta un punto de menor altura (pérdida de la altura). Despejando A de la ecuación 15 como el cociente Q/A , podemos obtener $q = \frac{Q}{A}$, que se define como la descarga específica o velocidad de Darcy, e indica que la velocidad del flujo es directamente proporcional a un área de paso y al gradiente hidráulico afectado por la conductividad hidráulica, esta ley se puede expresar de la siguiente manera:

$$q = -K \times \frac{\partial h}{\partial x} \quad (16)$$

donde: q = Descarga específica o velocidad de Darcy; ∂h = Diferencia entre los niveles de agua; ∂x = Diferencial de longitud, y K = Conductividad hidráulica.

Asimismo, para obtener el modelo matemático para un medio elástico, poroso y completamente saturado, se considera un cubo como el mostrado en la Figura 9, donde se supone un flujo en las tres direcciones (q_x, q_y, q_z).




Figura 9. Cubo representativo del flujo en tres direcciones

Utilizando la nomenclatura de la ecuación 16 podemos expresar el caudal en términos de las tres direcciones:

$$q_x = -K \times \frac{\partial h}{\partial x} \Delta y \Delta z ; q_y = -K \times \frac{\partial h}{\partial y} \Delta x \Delta z ; q_z = -K \times \frac{\partial h}{\partial z} \Delta x \Delta y \quad (17)$$

La herramienta MODFLOW se basa en resolver la ecuación de flujo de agua subterránea basando se en las propiedades hidrogeológicas del medio y estableciendo conexiones con otros compartimentos hidrológicos, como la zona vadosa y los fenómenos de transporte, por medio de la implementación de "paquetes" que permiten una representación de los procesos hidrogeológicos en el subsuelo (Taie Semiromi y Koch, 2019). Por lo tanto, la ecuación la podemos representar de la siguiente manera:

$$\frac{\partial}{\partial x} \left\{ k_x (h - d) \frac{\partial h}{\partial x} \right\} + \frac{\partial}{\partial y} \left\{ k_y (h - d) \frac{\partial h}{\partial y} \right\} = s \frac{\partial h}{\partial t} - \omega \quad (18)$$

donde h representa la carga hidráulica, k_x y k_y son las conductividades hidráulicas en las direcciones x e y , respectivamente. Además, d corresponde a la elevación del fondo impermeable con respecto a un nivel de referencia, s es el coeficiente de almacenamiento del acuífero, ω denota una fuente o sumidero, y t representa el tiempo. Esta ecuación es no lineal. Sin embargo, es posible linealizarla y resolverla utilizando el método de diferencias finitas, tal como se hace en MODFLOW (Anderson y Woessner, 1992; Wen-Hsing y Wolfgang, 1999).

III.2. Datos espectrales

En este estudio se utilizaron conjuntos de datos de teledetección compuestos por imágenes aéreas y multiespectrales de los años 2005 a 2018. Para cubrir este período, se procesaron imágenes de tres programas: Landsat 8 OLI/TIRS C2 Nivel-1, Landsat 7 ETM+ C2 Nivel-1, y Landsat 4-5 TM C2 Nivel-1, adquiridas del sitio web del USGS el 13 de diciembre de 2023. El área de estudio corresponde a una escena con la fila 038 y trayectoria 039. Además, Mediante Earth Explorer las imágenes fueron analizadas visualmente para seleccionar aquellas escenas libres de nubes, con el fin de reducir la incertidumbre asociada con condiciones atmosféricas. Así mismo, las imágenes de Landsat 7 ETM+ y 8 OLI/TIRS ofrecen una resolución global de 15 m en modo pancromático y 30 m en modo multiespectral (6 bandas) (Ngako et al., 2021). Mientras que Landsat 4-5 TM proporciona seis bandas espectrales con una resolución de 30 m (es decir, bandas 1 a 5 y 7) (Gasmi et al., 2021).

III.2.1. Procesamiento de datos espectrales

Los conjuntos de datos de las misiones Landsat se procesaron utilizando el software ArcGIS Pro 2.6 para calcular el Índice de Vegetación de Diferencia Normalizada (NDVI por sus siglas en inglés) y clasificar la salud de la vegetación. El NDVI propuesto por Rouse et al. (1974) se puede calcular utilizando la ecuación 19 (Rouse et al., 1974):

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (19)$$

donde NIR representa el valor de reflectancia de la banda del infrarrojo cercano y Red corresponde al valor de reflectancia de la banda roja. Los valores de NDVI varían de -1 a 1, donde 1 indica una

probable alta densidad de vegetación verde, mientras que valores de 0 o negativos indican la ausencia de vegetación (Fan et al., 2022). Para calcular el NDVI utilizando datos de Landsat, se utilizaron las bandas 4 y 5 para Landsat 8 OLI/TIRS, y las bandas 3 y 4 para Landsat 7 ETM y Landsat 4-5 TM (Kuzevic et al., 2022).

III.2.2. Análisis de variaciones interanuales

Se definieron regiones en un área de 250 x 250 m alrededor de cada pozo (área de una celda en el modelo de flujo), ya que dicho tamaño podría reflejar un valor de NDVI homogéneo alrededor del pozo. Se consideró que las fluctuaciones en la profundidad del NF están asociadas con el consumo natural de agua subterránea por parte de plantas y cultivos. Asimismo, se consideró que el valor promedio del NDVI reflejaba esta relación. Además, se utilizó un umbral de NDVI de 0.2 y 0.8 como límite entre vegetación, suelos desnudos y otras clases.

III.3. Selección de arquitecturas o modelos para las RNA

En esta sección, se muestran las características del modelo de RNA propuestos en este estudio con el fin de determinar las extracciones de agua subterránea.

Después de seleccionar los parámetros o variables de entrada de la red, es necesario identificar una estructura óptima para la red que le permita realizar estimaciones de la descarga de agua subterránea. Sin embargo, en cuanto a la cantidad de capas y neuronas, no hay una fórmula o regla específica para establecer el número ideal de neuronas ocultas para abordar un problema, normalmente, se determinan mediante un proceso de prueba y error, esto implica que partir de una arquitectura previamente entrenada realizar ajustes aumentando o disminuyendo el número de neuronas ocultas y capas hasta encontrar la configuración que mejor se adapte a la resolución del problema (Villada, Muñoz, y García, 2012).

El procedimiento común y recomendado es iniciar con una capa oculta de neuronas y aumentar el número de neuronas y el número de capas de forma gradual hasta encontrar la arquitectura conveniente (Hagan et al., 2014). En este estudio, se experimentaron con diversas configuraciones de RNA. Inicialmente, se comenzó con un número de neuronas igual a la cantidad de entradas. Posteriormente, se aumentó el número de neuronas de forma gradual en cada capa hasta encontrar la estructura que mostrara mejores ajustes. Sin embargo, se limitó el número de neuronas por capa

a 15, puesto que el poder computacional tendía a aumentar con mejoras mínimas. La elección de la mejor arquitectura de red se basó en la consideración del menor error con respecto al RMSE utilizado en la ecuación 14. Por lo cual, se probaron alrededor de 47 diferentes arquitecturas de RNA. Las arquitecturas exploradas parten desde aquellas que constan de 4 elementos en su capa de entrada, 4 neuronas y un elemento de salida, hasta aquellas que incluyeron 6 elementos en su capa de entrada, 4 capas ocultas con 15 neuronas y un elemento de salida. Al incrementar el número de neuronas y de capas ocultas se incrementa la capacidad de procesamiento de una RNA y se espera un mejor desempeño de la misma, sin embargo, al incrementar el número de neuronas también aumentó la cantidad de épocas requeridas para entrenar todos los parámetros de la RNA con unas mejoras mínimas en la precisión del modelo. En el apéndice B (Tabla B1) se presenta una síntesis de los resultados de las arquitecturas exploradas; donde se puede observar que la arquitectura de 6 entradas y 3 capas con 15 neuronas realizaron los mejores ajustes, manteniendo un equilibrio entre el número de épocas y el RMSE, mientras que, el resto de ellas, especialmente aquellas con una sola capa oculta presentan mayores errores durante el entrenamiento.

Utilizando como criterio los valores de RMSE observados, se seleccionó la configuración de redes neuronales tipo perceptrón, las cuales presentaron los mejores resultados. La diferencia principal entre los demás modelos que se fueron descartando radica en las diversas combinaciones de los parámetros que influyen en la estimación del bombeo de agua subterránea y el tipo de función de activación. El modelo seleccionado cuenta con 3 capas ocultas, 15 neuronas en cada capa, emplea una función de activación de tipo ReLu en sus primeras dos capas ocultas y en la capa de salida la función de activación lineal (Fig. 10).




Figura 10. Arquitectura o modelo de RNA seleccionada: donde x_1 = Precipitación; x_2 = Registro de nivel freático; x_3 = Conductividad hidráulica; x_4 = Topografía superficial; x_5 = Basamento impermeable, y x_6 = Evapotranspiración

III.3.1. Entradas y salidas

Durante el desarrollo de una RNA es muy importante realizar un análisis de los datos basado en la problemática a modelar con el fin de seleccionar la arquitectura adecuada de la RNA. Este proceso implica la definición de las variables de entrada y salida, el diseño de las capas de la red, así como la determinación del número de neuronas, por ello, es necesario tomar decisiones óptimas en relación con estas variables para obtener un modelo que mejor ajuste a la realidad (Wang et al., 2023).

Por lo tanto, las *variables de entrada*: Son los factores o parámetros que impactan con los procesos que podrían afectar la explotación o descarga del acuífero. Además, de la ubicación de los pozos dentro del modelo de flujo, propiedades del acuífero, características del medio o los procesos relevantes que influyen en la descarga, mismas que se describen a continuación:

- x_1 = Precipitación, esta corresponde al volumen de agua que se infiltra verticalmente y llega hasta el NF y se convierte en parte del sistema de agua subterránea (Cruz-Falcón et al., 2011). Se considera como recarga por infiltración vertical un 10% de la precipitación.
- x_2 = Registro del NF, proporciona información sobre la cantidad de agua presente en el acuífero en un momento dado. Esta información útil para determinar la disponibilidad de agua y si el acuífero puede soportar tasas de extracción.
- x_3 = Conductividad hidráulica, se refiere a la capacidad de un medio para transmitir agua a través de él. La cual afecta significativamente la capacidad del acuífero para el flujo de agua (Hernández-Juárez et al., 2020).
- x_4 = Topografía superficial, puede influir en la ubicación de pozos de extracción. Además, es un parámetro que permite caracterizar el límite superior del acuífero, de tal manera que el modelo pueda identificar sus distintas zonas.
- x_5 = Basamento impermeable, al igual que la topografía superficial es un parámetro que permite caracterizar el límite del acuífero, en este caso, siendo el límite inferior.
- x_6 = Evapotranspiración, afecta en la gestión de los sistemas de riego agrícola. La cantidad de agua necesaria para reemplazar la pérdida de agua debido a la evapotranspiración puede afectar la cantidad de agua que se extrae de un acuífero (Monterroso-Rivas y Gómez-Díaz, 2021).

Variable de salida: representa el valor objetivo o salida deseada, que en este caso es la descarga. Es fundamental definir y medir con precisión esta variable para garantizar predicciones aceptables (Wei et al., 2018).

III.3.2 Tratamiento previo de los datos

La normalización puede ser un proceso primordial en el análisis para comparar datos que tienen valores en dominios diferentes, por lo que, la normalización transfiere datos desde su dominio a un rango específico, como entre (0, 1) (Eesa y Arabo, 2017).

Como parte de la normalización por “standard score” (más comúnmente conocida como z-score), se utilizan la media y la desviación estándar para normalizar los valores de los atributos de entrada (Wang y Chen, 2012). La normalización de dicho proceso se presenta en la Ecuación (20):

$$X_i = \frac{x_i - \mu}{\sigma} \quad (20)$$

donde X_i es el valor normalizado, x_i representa valor actual sin normalizar, μ es la media del conjunto de valores de entrada y σ es desviación estandar del conjunto de valores de entrada. Este tipo de normalización ha demostrado un buen desempeño con el uso de RNA (Al-Faiz, Ibrahim, y Hadi, 2019). Además, de presentar una buena convergencia con los datos (Eesa y Arabo, 2017).

Por lo cual, con el propósito de mejorar el desempeño del modelo neuronal, en este trabajo, los datos de entrada que fueron normalizados son: registro de NF, conductividad hidráulica, topografía superficial, basamento impermeable y evapotranspiración. No fue necesario normalizar los valores de la precipitación, ya que, sus registros se encuentran en rangos de cero y uno [0,1].

III.3.3 Evaluación del modelo de RNA usando un modelo de acuífero sintético

Con el fin de evaluar el desempeño de la RNA, se construyó un modelo sintético de un acuífero libre en MODFLOW, el cual corresponde a una adaptación del modelo sintético presentado por Figueroa-Núñez (2018). El modelo está representado con un mallado compuesto por 6 renglones y 10 columnas, con celdas cuadradas de 400 m por lado, un espesor de 248 m, con una topografía superficial de 258 m, y un basamento impermeable 10 m, NF inicial de 250 m, y conductividad hidráulica (K) de 50 m/día (Tabla 1).

Tabla 1. Características del modelo sintético adaptado de Figueroa (2018)

Descripción	Cantidad	Unidad
Largo y ancho de la celda (Cuadrada)	100	m
Columnas	10	
Renglones	6	
Cota del terreno natural	258	m
Cota del basamento impermeable	10	m
NF inicial	250	m
Extracción del Pozo 1	10,250	m ³ /día
Extracción del Pozo 2	9,360	m ³ /día

No obstante, se introdujeron ajustes en las conductividades hidráulicas para analizar la respuesta de la RNA frente a esta variación. En este sentido, la Figura 11 refleja la configuración de

conductividad hidráulica que se implementó. Concretamente, se incrementó la K original del modelo desarrollado por Figueroa-Núñez (2018) por un factor de 4, a fin de considerar de manera más amplia las posibles variaciones en este parámetro. Por otra parte, en la adaptación de este caso sintético se considera un aumento en los días de ejecución del modelo hasta un total de 30 días.




Figura 11. Modelo sintético adaptado de Figueroa-Núñez (2018)

III.4 Descripción de los Datos Usados para La Implementación de los Modelos Neuronales y del Modelo Sintético

En esta sección, se presenta una descripción de los parámetros que se emplearon para construir la capa de entrada al modelo neuronal.

III.4.1. Registros del nivel freático

Los datos relacionados con el NF utilizados en este estudio provienen de los registros proporcionados por la CONAGUA. Estos datos muestran una periodicidad mensual y abarcan el período de 1989 a 2018, aunque no todos los meses presentan registros. En la Tabla 2, se muestra un resumen de la cantidad de mediciones del NF que se tiene como registro y que fueron utilizadas en este trabajo. Estos registros se representan gráficamente en la Figuras 12; también se puede encontrar información adicional en el Apéndice C.

Tabla 2. Datos del nivel freático empleados para la calibración del modelo de flujo. El símbolo "-" indica la falta de información disponible. AON hace referencia al acuífero de ON y ARC representa al acuífero de RC

#	Periodo analizado	Meses de Operación	Puntos de Observación disponibles		#	Periodo analizado	Meses de Operación	Puntos de Observación disponibles	
			AON	ARC				AON	ARC
1	Julio de 1989	79	19	5	15	Noviembre del 2012	359	50	-
2	Noviembre de 1995	155	17	-	16	Abril del 2013	364	34	-
3	Febrero de 1997	170	19	-	17	Agosto del 2013	368	-	39
4	Febrero de 1999	194	-	5	18	Noviembre del 2013	371	46	-
5	Abril del 2005	268	-	10	19	Abril del 2014	376	47	-
6	Diciembre del 2007	300	-	23	20	Noviembre del 2014	383	43	-
7	Noviembre de 2008	311	45	-	21	Abril del 2015	388	46	-
8	Mayo del 2009	317	46	-	22	Noviembre del 2015	395	42	-
9	Noviembre del 2009	323	48	18	23	Abril del 2016	400	45	-
10	Abril del 2010	328	45	-	24	Noviembre del 2016	407	30	-
11	Noviembre del 2010	335	53	-	25	Mayo del 2017	413	42	-
12	Abril del 2011	340	52	-	26	Noviembre del 2017	419	31	-
13	Noviembre del 2011	347	51	-	27	Abril del 2018	424	39	-
14	Abril del 2012	352	50	-					




Figura 12. Registro de elevaciones del nivel freático en aprovechamientos de agua subterránea situados en el VON

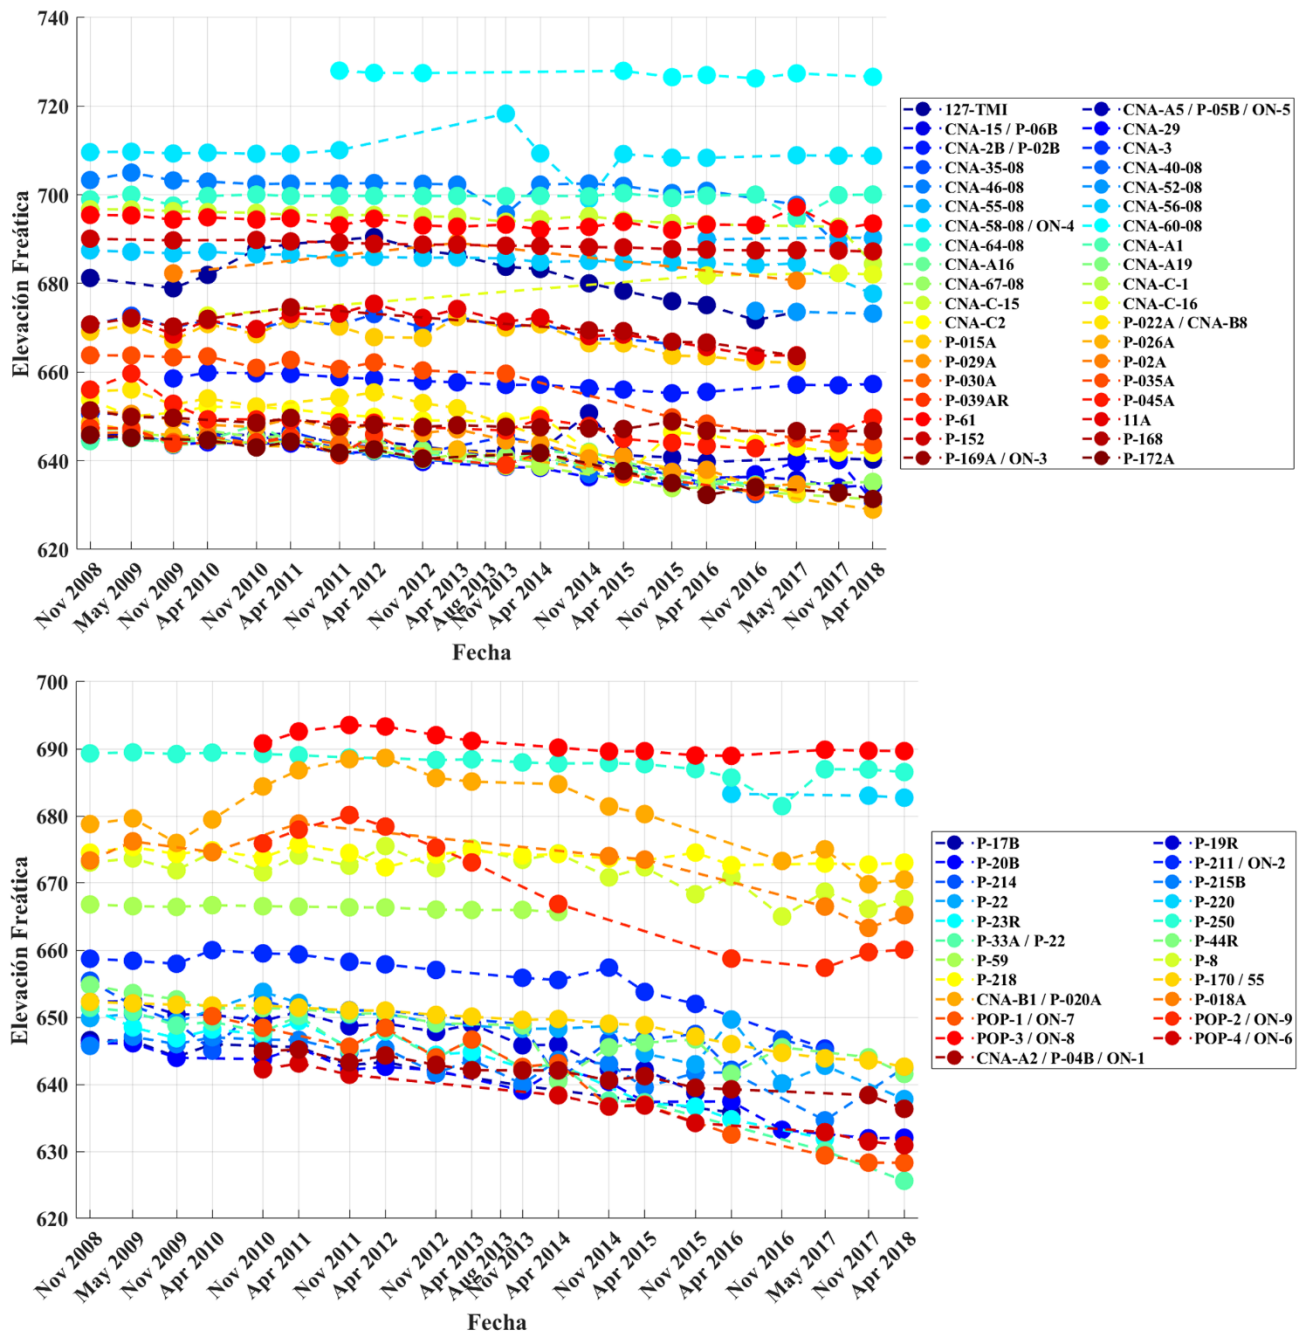
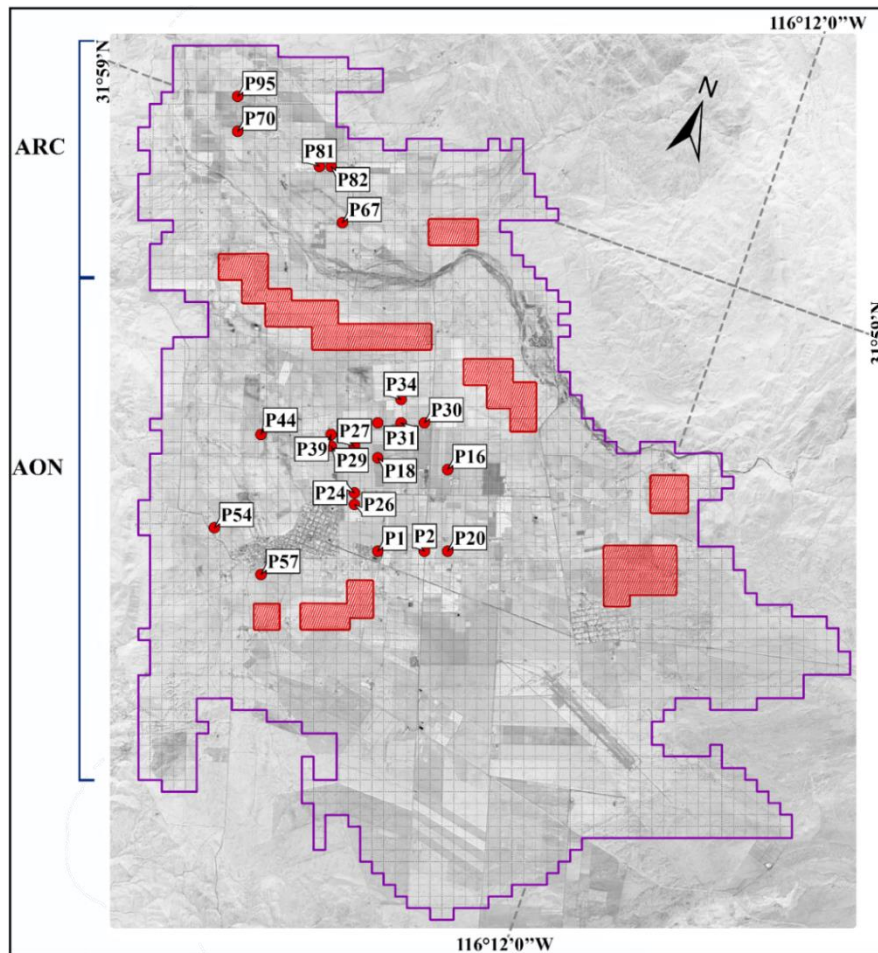


Figura 12. CONTINUACIÓN. Registro de elevaciones del nivel freático en aprovechamientos de agua subterránea situados en el VON

III.4.2. Ubicación de los puntos de observación

En las Figuras 13 y 14 se presenta la ubicación de los pozos de observación en el VON. Estos pozos registraron los NF y se utilizaron para estimar la descarga de agua subterránea. Los datos se

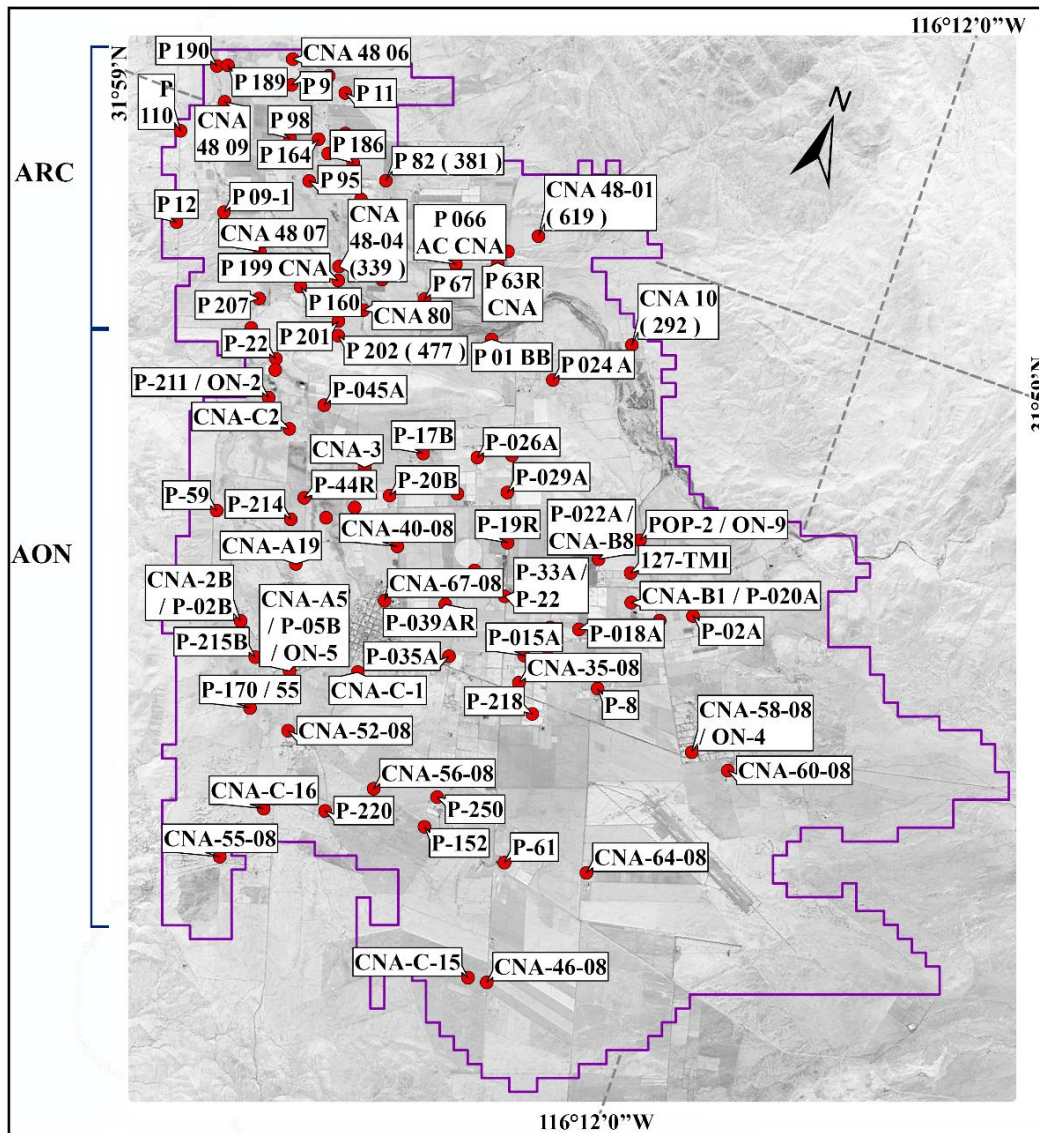
dividen en dos períodos: el primero, de 1983 a 1999, comprende 22 pozos distribuidos en el VON, de los cuales 5 están en RC y 17 en ON (Fig. 14). El segundo período, de 2005 a 2018, incluye 101 puntos de observación, con 64 pozos en ON y 37 en RC (Fig. 15).



Aproximación del Dominio de Flujo

- ARC: Acuífero de Real del Castillo
- AON: Acuífero de Ojos Negros
- Área Activa
- Puntos de observación registros 1989-1999

Figura 13. Distribución de pozos de observación situados en el VON, periodo de observación 1989-1999, cuyo registro del NF fue empleado para reproducirse con la RNA



Aproximación del Dominio de Flujo

- ARC: Acuífero de Real del Castillo □ Área Activa
AON: Acuífero de Ojos Negros ● Puntos de observación registros 2005-2018

Figura 14. Distribución de pozos de observación situados en el VON, periodo de observación 2005-2018, cuyo registro del NF fue empleado para reproducirse con la RNA

III.4.3. Asignación de los registros de nivel freático

Las mediciones del NF a lo largo del período analizado han cambiado, es decir, las mediciones no han sido realizadas todo el tiempo en los mismos pozos, ni ha sido el mismo número de pozos (Tabla 2). Por lo que, los pozos incluidos en la modelación fueron cambiando, dependiendo de las mediciones consideradas en cada fecha simulada. Estos cambios de pozos en los que se ha medido

el NF provoca que en algunas fechas las celdas donde se ubica un pozo de descarga y, por ende, donde se estima un volumen de descarga, no coincida con las celdas del modelo consideradas en periodos anteriores. Por consiguiente, en la elaboración de este trabajo se definieron los dos casos siguientes. En el primer caso, se refiere a las fechas en las cuales los registros del NF coinciden con las celdas donde se encuentra un pozo de descarga en el cual se estimó la descarga. En esta situación, no se requieren procesos adicionales para asignar el registro de NF.

El segundo caso es, cuando los puntos de observación no coinciden con las celdas donde se encuentran los pozos en los que se estimó la descarga. Por ello, se procedió a la elaboración de mapas de elevación del NF utilizando los registros de campo y mediante el empleo del proceso de interpolación Kriging. Con base en la interpolación realizada, se asignó un NF a la celda correspondiente para la estimación de la descarga. El método de interpolación Kriging ha sido seleccionado para el propósito de este trabajo, porque durante su proceso de cálculo considera que para un punto dado en el espacio cuyo valor necesita ser estimado, la herramienta de interpolación establecerá cuál de los valores conocidos puede asumirse que afecta al punto desconocido y puede utilizarse para estimar su valor, mientras que los puntos restantes se dejan fuera (Martínez-Santos y Martínez-Alfaro, 2010). Además, con este proceso de interpolación se restringe el área donde están ubicados los pozos en los que se estima la descarga y la disponibilidad de registros del NF. Para la asignación de los registros del NF, el caso 1 se aplicó a las fechas comprendidas entre 1989 y 2005, mientras que el caso 2 se utilizó para las fechas que abarcan desde 2007 hasta 2018 (Tabla 3).

Tabla 3. Distribución de cada caso utilizado para la asignación del registro de nivel freático a la RNA. Los valores marcados con "-" indican fechas que no fueron modeladas por la RNA.

Número	Período analizado	Caso	Número	Período analizado	Caso
1	Julio de 1989	1	16	Abril del 2013	-
2	Noviembre de 1995	1	17	Agosto del 2013	2
3	Febrero de 1997	1	18	Noviembre del 2013	2
4	Febrero de 1999	1	19	Abril del 2014	-
5	Abril del 2005	-	20	Noviembre del 2014	2
6	Diciembre del 2007	1	21	Abril del 2015	-
7	Noviembre de 2008	2	22	Noviembre del 2015	2
8	Mayo del 2009	2	23	Abril del 2016	-
9	Noviembre del 2009	2	24	Noviembre del 2016	2
10	Abril del 2010	-	25	Mayo del 2017	2
11	Noviembre del 2010	2	26	Noviembre del 2017	2
12	Abril del 2011	-	27	Abril del 2018	-
13	Noviembre del 2011	2			
14	Abril del 2012	-			
15	Noviembre del 2012	2			

III.4.4. Registros de precipitación

En este trabajo, se utiliza la variable climatológica de precipitación, cuyos registros han sido recopilados por la CONAGUA y el Sistema de Información para el Manejo del Agua de Riego en el Estado de Baja California (SIMARBC). Estos registros pertenecen a dos estaciones climatológicas, Ojos Negros y Valle de San Rafael (Fig. 3). En la Tabla 4, se muestran los valores mensuales de precipitación utilizados durante el período de modelación de la RNA.

Tabla 4. Registro de precipitación mensual (en mm) llevado a cabo durante el periodo 1983-2020 en las estaciones climatológicas del Valle de San Rafael (celda sombreada con un Color Morado) y Ojos Negros (celda sombreada con un Color azul), operadas por la CONAGUA y SIMARBC, respectivamente

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Total anual
1983	35	84	141	46	1	0	0	102	45	10	38	43	545
1984	17	1	1	12	0	0	39	12	3	0	17	97	198
1985	17	28	15	4	0	0	4	0	10	23	57	17	175
1986	8	41	79	3	0	0	3	6	8	6	0	21	174
1987	29	77	25	11	10	0	0	19	6	75	29	50	329
1988	63	15	15	66	2	0	30	22	0	0	8	20	241
1989	24	14	8	7	3	0	0	0	0	0	0	0	56
1990	51	29	15	40	2	0	32	26	0	0	8	26	228
1991	37	89	147	2	0	0	40	4	18	20	0	49	405
1992	40	80	140	3	13	0	0	19	0	18	3	101	417
1993	238	145	34	0	0	6	0	17	0	8	27	14	488
1994	23	98	54	20	0	0	3	4	0	0	42	37	281
1995	150	26	83	33	26	11	0	5	50	0	0	9	392
1996	52	44	41	0	0	0	2	18	0	13	8	10	188
1997	62	22	7	21	0	8	0	1	38	0	28	93	280
1998	22	159	102	42	9	0	0	7	1	0	10	18	370
1999	24	22	23	0	0	0	47	0	0	0	0	4	120
2000	12	59	36	4	0	15	0	6	0	16	9	3	160
2001	73	90	35	31	0	0	11	0	0	0	0	0	239
2002	5	0	16	4	157	0	10	0	0	2	11	0	204
2003	4	82	44	18	1	0	0	37	0	0	16	3	204
2004	8	70	9	10	0	0	0	0	0	118	25	42	282
2005	77	65	25	2	5	0	8	29	0	7	0	0	217
2006	3	3	56	11	13	0	8	0	0	0	0	15	110
2007	15	21	2	0	4	0	0	9	23	0	56	23	153
2008	90	46	23	1	5	0	0	15	0	1	25	0	204
2009	1	71	0	7	0	0	0	0	0	0	14	51	144
2010	199	81	37	40	0	0	0	0	8	73	9	62	508
2011	9	104	21	21	7	0	14	0	0	9	48	43	274
2012	8	43	35	26	0	0	0	42	10	3	0	0	165
2013	53	22	29	1	2	0	7	37	7	12	8	14	190
2014	18	42	37	4	0	0	5	21	20	10	5	54	215
2015	37	29	35	6	16	5	14	3	6	9	19	17	195
2016	80	2	64	33	3	0	0	0	21	0	10	86	300
2017	99	52	8	0	8	2	0	0	0	0	6	0	174
2018	0	17	15	25	2	0	3	13	5	6	11	62	159

III.4.5. Conductividad hidráulica

Las estimaciones de la conductividad hidráulica se basan en una adaptación de los modelos previamente presentados por Campos-Gaytán (2002) y Padilla Morin (2013). Además, de los valores característicos para el tipo de material, los cuales, fueron publicados por Anderson y Woessner (1992) (Tabla 5). De esta adaptación se puede concluir lo siguiente:

- a) Se considera que las rocas ígneas y metamórficas que constituyen tanto las fronteras Este como Oeste, así como los afloramientos en el interior de los acuíferos, son impermeables y se tratan como celdas inactivas.
- b) Las zonas con una conductividad hidráulica de 125 m/mes sugieren la presencia de sedimentos con la posible existencia de lentes arcillosos de baja conductividad hidráulica.
- c) Los depósitos de talud y pie de monte, así como los depósitos aluviales y fluviales compuestos por limos, arcillas y arenas, en los valles RC y ON, se estiman con conductividades hidráulicas de 166.67 m/mes y 250 m/mes, respectivamente.
- d) Los depósitos aluviales y fluviales, compuestos por arenas tanto finas como gruesas, que conforman el lecho del Arroyo El Barbón se establecieron con una conductividad hidráulica de 1,500 m/mes.
- e) Los depósitos aluviales y fluviales compuestos por arenas gruesas y gravas que conforman ambos acuíferos (ON y RC) se han considerado con conductividades hidráulicas de 7,833 m/mes y 8,333 m/mes, respectivamente.

Tabla 5. Valores estimados de la conductividad hidráulica (k) (en m/mes), Anderson y Woessner (1992)

Material	Conductividad hidráulica (m/mes)		
	Límite inferior	Media	Límite superior
Arcillas	0.0000183	0.00761	0.015201
Sedimentos, Suelo, Lodo (Silt loess)	0.2129167	60.939	121.667
Arena con sedimentos, Arenas finas	2.1291667	305.231	608.333
Arena limpia /Arena gruesa	15.2083333	3049.271	6083.333
Grava	3041.6666667	92770.833	182500
Roca ígnea no fracturada / Roca metamórfica no fracturada	0.0000003	106.458	212.920

El análisis de dicha información da como resultado un código de conductividades hidráulicas cuya capa única del sistema mostró una gama de variación desde 125 a 8,333 m/mes (Fig. 15). Tales valores fueron implementados tanto en el modelo neuronal como en el modelo de flujo. La asignación de la K en la RNA se llevó a cabo con base en la ubicación espacial del pozo analizado dentro del modelo de flujo. Dicha distribución se presenta en las Tablas 6 y 7 siguiendo la discretización temporal de los pozos de bombeo.

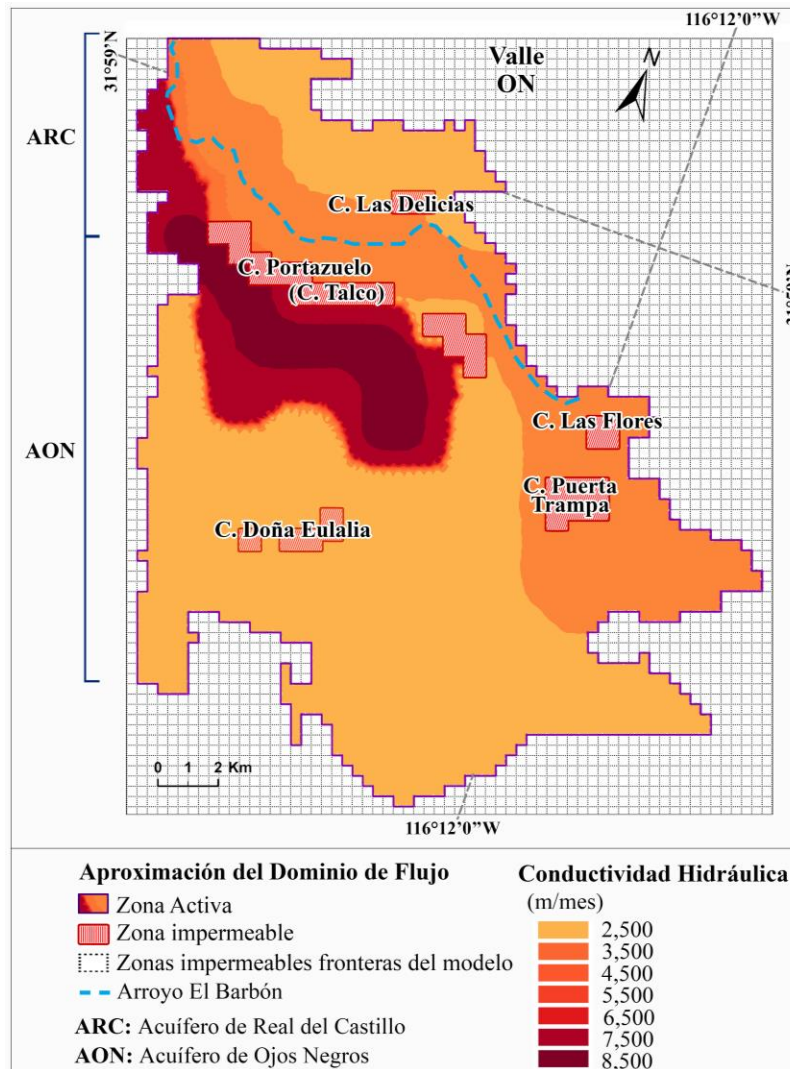


Figura 15. Código de Conductividad Hidráulica (K en m/mes) para los Acuíferos de Ojos Negros y Real del Castillo

III.4.6. Topografía Superficial y Basamento Impermeable

La Topografía Superficial se obtuvo del Radar del Transbordador Espacial de la NASA (SRTM) (van Zyl, 2001) y el Basamento Impermeable de registros e información de Vázquez et al. (1991). La topografía del terreno cuenta con pendientes suaves y, en general, con una superficie plana, con pocas irregularidades significativas (Figura 16a). Sin embargo, se aprecian montículos que separan los dos valles. Estas características topográficas del valle se encuentran a una altitud promedio de aproximadamente 700 msnm.

La determinación de la elevación topográfica del basamento impermeable (en msnm) se basó en los valores proporcionados por Vázquez et al. (1991), quienes llevaron a cabo estudios de gravimetría, polarización inducida y resistividad en el VON. La elevación promedio de la topografía del basamento impermeable se estima en aproximadamente 590 msnm, lo que indica una diferencia de alrededor de 110 m en relación con la topografía del terreno (Fig.16 b).

La totalidad de los datos previamente comentados sobre la topografía superficial y el basamento impermeable fueron utilizados para el modelo numérico del flujo de agua subterránea. Mientras que, en el modelo de RNA la topografía y basamento se asignaron únicamente a los pozos (o celdas) en los cuales se determinó la descarga, de acuerdo con su ubicación espacial dentro del modelo y con la cantidad de pozos que se utilizaron en cada periodo. El primer período abarca los años entre 1983 y 1991, como se muestra en la Tabla 6, donde se presentan los valores de topografía superficial (T), basamento (B) y conductividades hidráulicas (K), junto con las coordenadas dentro del modelo de MODFLOW (columna (C) y renglón (R)). El segundo grupo de pozos corresponde al período entre 1992 y 2018, y se encuentra en la Tabla 7. Al igual que en el primer grupo, se proporciona información sobre la ubicación espacial en el modelo y los parámetros asociados de basamento, Topografía y conductividad hidráulica.

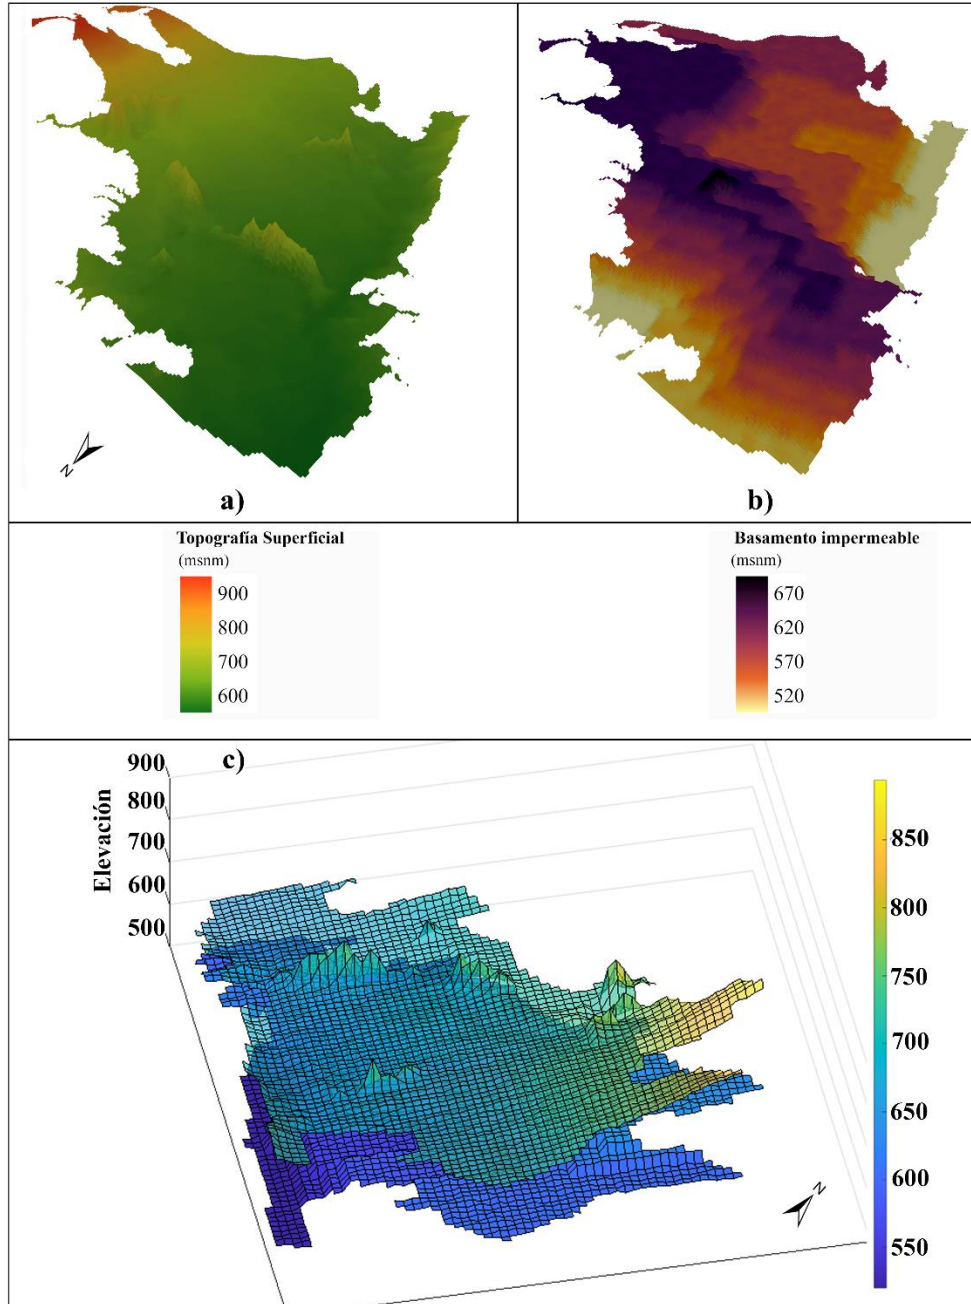


Figura 16. Elevaciones topográficas en el VON. a) Topografía superficial. b) Topografía del basamento impermeable. c) Isométrico elaborado con información de las topografías superficial y del basamento impermeable en el VON

Para el análisis con los modelos neuronales, los datos de la topografía superficial, basamento impermeable y conductividad hidráulica se normalizaron utilizando la ecuación 20. La determinación del valor para cada pozo se basó nuevamente en su posición espacial dentro del modelo.

Tabla 6. Parámetros de topografía superficial, basamento impermeable y conductividad hidráulica para los pozos, periodo 1983 a 1991. Simbología: Topografía superficial en msnm (T); Basamento impermeable en msnm (B); Conductividad hidráulica en m/mes (K) y Coordenadas dentro del modelo en MODFLOW: columna (C) y renglón (R)

Pozo	T	B	K	C	R
1	723	598	292	32	48
2	700	578	292	22	44
7	716	578	292	28	46
8	714	578	292	32	45
12	710	578	292	26	44
13	697	578	125	20	40
16	690	578	125	18	35
18	686	558	6667	12	34
20	720	598	292	28	44
24	692	598	6667	22	33
26	694	618	1250	42	39
27	721	638	8333	26	33
29	701	578	6667	22	40
30	705	578	8333	26	40
31	687	578	6667	18	33
33	694	638	6667	28	29
34	692	598	125	20	35
37	715	598	125	34	39
39	704	578	8333	28	37

Pozo	T	B	K	C	R
42	695	618	8333	24	33
44	691	638	8333	24	31
54	698	558	292	10	46
55	685	520	292	6	44
56	691	558	292	12	46
57	688	558	292	8	42
62	693	578	125	16	38
63	686	578	6667	14	33
66	677	618	1250	16	21
67	681	598	1250	20	19
70	686	598	1250	24	19
71	684	558	167	26	16
80	672	578	167	18	11
81	668	598	167	28	14
82	686	538	1250	12	9
95	676	558	167	20	11
97	660	578	167	10	5
98	662	578	167	10	7
123	673	598	167	18	15

Tabla 7. Parámetros de topografía superficial, basamento impermeable y conductividad hidráulica para los pozos, periodo 1991 a 2018. Simbología: Topografía superficial en msnm (T); Basamento impermeable en msnm (B); Conductividad hidráulica en m/mes (K); y Coordenadas dentro del modelo en MODFLOW: columna (C) y renglón (R)

Pozo	T	B	K	C	R
1	700	578	292	22	44
2	710	578	292	26	44
7	718	578	292	28	48
8	728	618	292	35	48
9	724	618	292	34	45
12	719	598	292	32	46
16	704	578	8333	28	37
18	704	578	8333	26	39
19	702	578	8333	26	37
20	714	578	292	29	44
22	708	578	6667	26	42
23	704	578	8333	24	40
24	701	578	6667	22	40
26	697	578	125	20	40
27	694	578	125	20	36
30	695	618	8333	26	33
31	694	618	8333	24	33
37	692	598	6667	22	33
39	690	598	6667	18	34
41	687	578	125	14	36
42	687	578	6667	14	34
44	686	558	6667	12	34
46	678	558	8333	12	27
48	677	598	8333	14	27
55	685	520	292	6	44
56	690	558	292	10	44
57	698	558	292	10	46
60	698	578	125	16	42
62	686	538	167	28	14
63	684	558	167	25	16
64	656	578	1250	6	7
66	686	598	1250	24	19
67	681	598	1250	20	19
70	673	598	167	18	15
74	725	638	1250	44	37
80	677	618	1250	16	21
81	676	558	167	20	11
82	672	578	167	18	11
95	668	598	1250	12	9
97	657	558	167	9	3
98	661	578	167	11	5
111	697	558	292	10	54
115	719	598	292	30	48
122	701	578	6667	22	42
123	693	578	125	16	38
124	684	598	8333	16	31
126	724	618	292	39	39
142	663	598	1250	10	11
144	686	538	292	8	46
150	662	638	1250	10	15
153	715	578	292	25	60
155	669	598	167	16	13
157	660	578	1250	8	7
158	661	618	1250	8	13
164	665	578	167	12	7
165	665	598	1250	14	9
166	662	578	167	10	7
168	715	578	292	30	43
169	695	638	6667	28	31
170	691	520	292	6	46
174	662	598	1250	8	11
176	712	578	292	26	46
177	689	618	8333	20	31
185	665	598	1250	12	11
199	673	618	1250	14	17
200	675	638	1250	14	19
203	686	618	1250	26	23
204	683	618	1250	22	23
214	685	538	6667	10	36
216	691	638	8333	24	31
217	725	598	292	33	48
218	722	578	292	28	50
219	701	578	125	20	44
221	718	598	292	32	43
222	721	618	292	34	43
223	715	598	125	34	39
226	716	578	292	28	46
233	689	578	125	14	40
234	688	558	6667	12	38
235	690	578	125	14	45
236	701	558	125	16	46
237	702	558	125	19	46
238	678	618	8333	12	25
239	731	638	1250	41	41
240	726	618	125	37	39
242	706	578	6667	30	37
244	697	578	125	20	42
245	727	578	292	31	60
247	694	558	292	10	50
248	680	538	292	8	40
249	674	618	8333	10	23
250	706	578	292	20	56

III.4.7. Evapotranspiración

El modelo neuronal incorpora la evapotranspiración como una pérdida de agua subterránea, la cual se considera asociada con el proceso de evaporación de los cuerpos superficiales de agua y con la transpiración de las plantas. Se ha establecido una tasa de pérdida basada en la información proporcionada en las Tablas 8 y 9; la cual, corresponde a los registros obtenidos del Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP). Tales registros contienen datos para los diversos cultivos en el VON. Existen al menos dos temporadas de cultivos en el valle, la primera de ellas es primavera-verano (P-V), en la cual se pueden encontrar cultivos como: Tomatillo, Alfalfa, Tomate, Chile, Cebolla, Cebollín, Calabacita, VID, Sandía, Esparrago y Varios (Tabla 8). La segunda temporada corresponde a otoño-invierno (O-I), en esta se pueden encontrar cultivos como: Chile, Tomatillo, Tomate, Alfalfa, Cebolla, Calabacita, Cebollín, Sandía, VID, Mixtura, Espárragos y Varios (Tabla 9).

Tabla 8. Valores estimados por pérdidas de evapotranspiración para el periodo Primavera- Verano (P-V). Tomado de INIFAP (2016)

Cultivo	mm/mes						Total anual (mm/año)
	P-V						
	Ene	Feb	Mar	Abr	May	Jun	P-V
Vid	1.60	2.10	2.60	3.20	3.90	4.60	22.6
Cebollín	9.5	53.1	68.5	25.25	-	-	156.35
Cebolla	-	-	24.70	90.80	14.2	172.20	301.9
Alfalfa	75.05	91.22	137.67	168.47	224.27	246.35	1194.85
Tomate	-	-	29.00	86.00	159.7	15.80	290.50
Esparrago	22.21	34.49	107.17	168.47	224.27	243.35	1051.78
Tomatillo	-	-	35.47	150.12	168.67	135.08	489.34
Chile	-	-	94.58	136.47	153.34	176.65	561.04
Calabacita	-	-	61.48	122.82	138.01	145.47	467.78
Sandía	45.25	103.67	118.23	136.47	153.34	155.87	913.21

Tabla 9. Valores estimados por pérdidas de evapotranspiración para el periodo Otoño- Invierno (O-I). Tomado de INIFAP (2016)

Cultivo	mm/mes						Total anual (mm/año)
	O-I						
	Jul	Ago	Sep	Oct	Nov	Dic	O-I
Vid	4.60	4.70	7.40	2.70	2.00	1.50	13.6
Cebollín	-	-	10.5	49	75.1	16.3	150.9
Cebolla	166.20	76.80	-	-	-	-	243
Alfalfa	251.82	225.33	194.13	134.05	83.14	64.36	475.68
Tomate	-	34.80	111.40	112.23	41.50	-	265.13
Esparrago	251.82	225.33	194.13	134.05	83.14	49.72	461.04
Tomatillo	-	56.12	146.04	123.94	49.80		319.78
Chile	-	-	106.21	112.67	76.62	45.40	340.90
Calabacita	-	-	69.035	101.40	68.96	37.39	276.78
Sandía	200.39	149.66	132.76	112.67	76.62	40.06	511.76

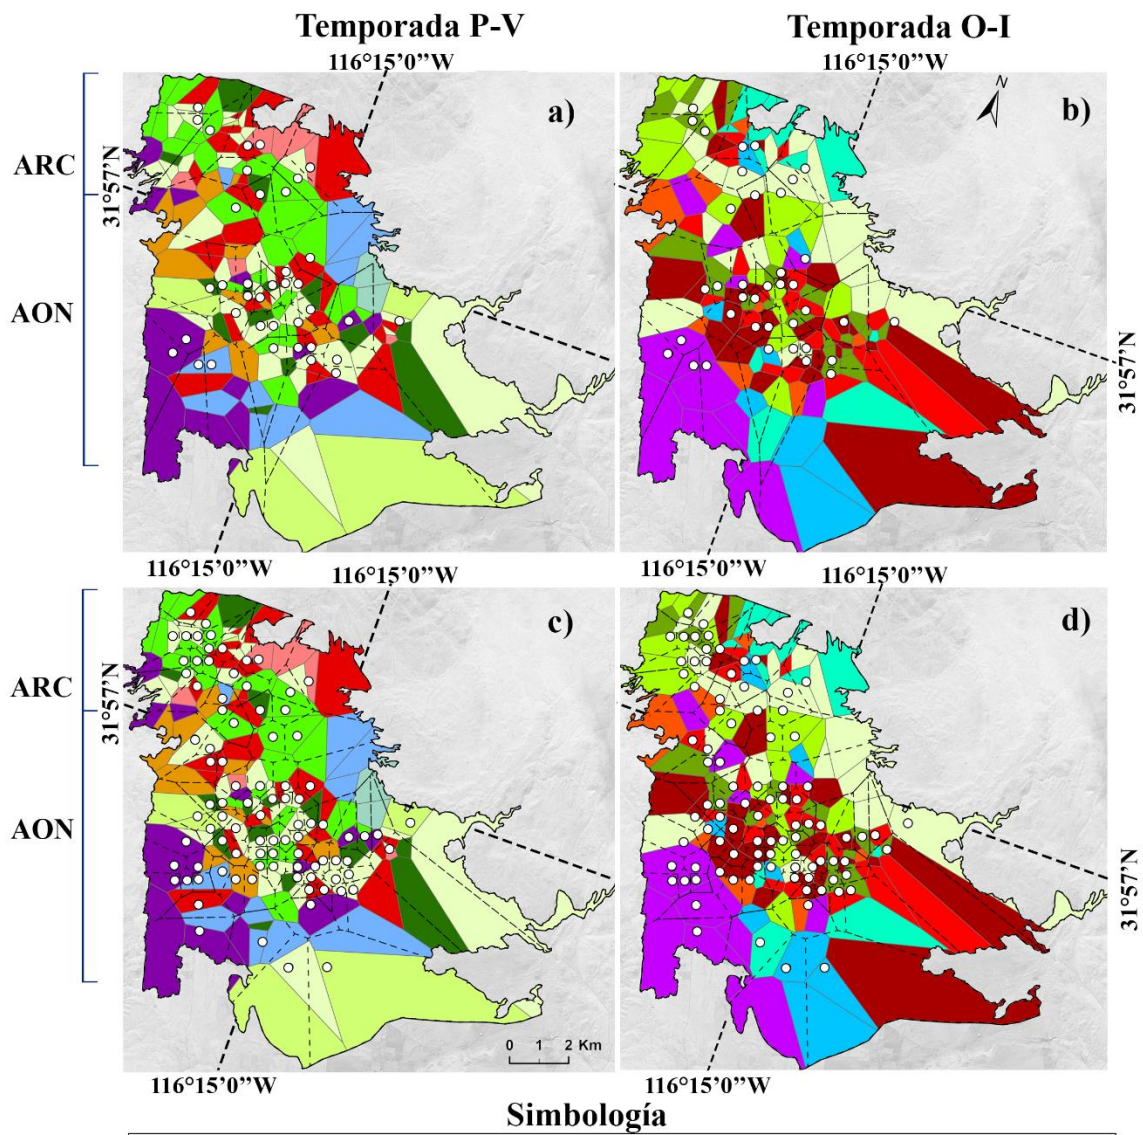
Con la finalidad de definir una tasa de bombeo para cada pozo situado en el VON, fue necesario generalizar algunos factores, puesto que, actualmente no existe algún registro oficial que indique la cantidad de aportación de cada pozo con respecto al tipo o área del cultivo. Por lo tanto, en la elaboración de este trabajo se consideraron los siguientes criterios:

- Se elaboraron Polígonos de Thiessen para los pozos de bombeo que fueron utilizados en este trabajo. Lo anterior, con el fin de establecer un área estimada de participación con los tipos de cultivos.
- Posteriormente, se elaboraron Polígonos de Thiessen de los cultivos. Esto con el fin de extender las áreas en las que se presentan tales tipos de cultivos en el VON.
- Se determinó la participación de cada pozo de bombeo utilizando como criterio el área del pozo de bombeo y el área de los cultivos, ambos obtenidos de los Polígonos de Thiessen.
- La participación de cada pozo en los procesos de evapotranspiración se estimó dividiendo el volumen de riego (Tabla 10) entre el número de pozos que podrían participar en algún determinado cultivo basado en los Polígonos de Thiessen del cultivo y bombeo.

Por lo tanto, la evapotranspiración de los cultivos se calculó considerando un área asignada a cada cultivo delimitada por los Polígonos de Thiessen, en concordancia con el área de bombeo establecida para cada pozo (Fig. 17). A partir de estos criterios fue posible establecer un porcentaje de la evapotranspiración en cada pozo. Cabe destacar que solo se tuvo acceso a la información de los cultivos y su área respectiva para la temporada 2015 y 2016.

Tabla 10. Áreas de cultivos de acuerdo con el INIFAP para las temporadas 2015-2016

Temporada	Cultivo	Superficie (m²)	Volumen de riego (m³/año)
P-V	Alfalfa	4,972,300	5,941,153
	Calabacita	1,492,300	698,072
	Cebolla	2,214,700	1,036,701
	Cebollín	5,304,400	829,343
	Chile	2,996,400	1,681,103
	Esparrago	705,000	741,505
	Sandía	970,700	886,456
	Tomate	3,237,800	940,581
	Tomatillo	6,147,700	3,008,334
	VID	1,013,200	22,898
	Varios	2,648,700	0
O-I	Alfalfa	3,427,400	1,630,346
	Cebollín	1,343,200	202,689
	Cebolla	2,255,800	548,159
	Calabacita	1,641,600	454,367
	Chile	5,304,400	1,808,251
	Esparrago	792,900	365,559
	Sandía	1,272,400	651,168
	Tomate	3,661,100	970,667
	Tomatillo	3,929,500	1,256,560
	VID	1,204,600	16,383
	Varios	1,548,400	0



Evapotranspiración de cultivos				
	P-V	(mm/año)	O-I	(mm/año)
○	Pozos de extracción			
□	Dominio de flujo			
⌈ ⌋	Polígonos de Thiessen			
ARC:	Acuífero de Real del Castillo			
AON:	Acuífero de Ojos Negros			
	Tomatillo	489	Chile	341
	Alfalfa	1195	Tomatillo Verde	320
	Tomate	290	Tomate	265
	Chile	561	Alfalfa	476
	Cebolla	302	Sandía	512
	Cebollín	156	Calabacita	277
	Calabacita	468	Cebollín	151
	Vid	23	Cebolla Bola	243
	Sandía	913	Vid	14
	Esparrago	1052	Mitura	0
	Varios	0		

Figura 17. Evapotranspiración de los cultivos y un área atribuida a cada cultivo de acuerdo con los Polígonos de Thiessen, en relación a la temporada y periodo de bombeo

III.4.8. Segmentación de Pozos de Descarga para la RNA: Dos Rangos de Entrenamiento

Durante la fase de entrenamiento de la RNA, se implementaron dos rangos para abordar la variabilidad de los datos. La razón principal de esta estrategia radica en que la observación de valores dentro del intervalo de 0 a 100,000 m³/mes podrían introducir desafíos en el proceso de aprendizaje de la RNA, cuando el siguiente valor establecido como parámetro de entrenamiento se encuentra dentro del rango de 100,000 a 250,000 m³/mes, generando posibles pérdidas de aprendizaje. Por lo tanto, la segmentación en dos rangos distintos se propuso como una solución para mitigar este problema, permitiendo que la red se especialice y ajuste de manera más precisa a patrones específicos dentro de cada intervalo. Las distribuciones de rangos, está basada en los registros de descargas de Campos-Gaytán (2002) y Padilla Morin (2013). De los cuales podemos encontrar rangos entre 0 a 100,000 y 100,000 a 250,000 m³/mes para las temporadas 1983-1991 y 1992–2018, respectivamente (Tabla 11 y 12).

Tabla 11. Distribución de pozos de descarga para el periodo 1983 a 1991, segmentados en rangos entre 0 a 100,000 m³/mes (celda sombreada con Color Naranja) y 100,000 a 250,000 m³(celda sombreada con Color azul)

#	Pozo	Descarga (m ³ /mes)
1	31	-22,519
2	33	-46,182
3	27	-56,022
4	123	-248,529
5	18	-57,817
6	81	-59,075
7	26	-70,617
8	39	-75,327
9	29	-77,799
10	42	-78,427
11	24	-80,681
12	30	-82,524
13	34	-83,623
14	63	-88,176
15	37	-90,339
16	1	-96,975
17	44	-105,125
18	95	-113,768
19	71	-113,768

#	Pozo	Descarga (m ³ /mes)
20	27	-113,768
21	70	-113,768
22	81	-113,768
23	1	-122,137
24	66	-124,568
25	80	-132,823
26	82	-152,428
27	123	-161,846
28	39	-167,819
29	97	-175,408
30	54	-177,068
31	55	-187,068
32	57	-193,313
33	18	-219,925
34	67	-228,025
35	12	-248,400
36	7	-250,396
37	20	-249,948
38	8	-249,113

Tabla 12. Distribución de pozos de descarga para el periodo 1992 a 2018, segmentados en rangos entre 0 a -100,000 m³/día (celda sombreada con Color Naranja) y -100,000 a 250,000 m³ día (celda sombreada con Color azul)

#	Pozo	Descarga m ³ /mes
1	153	-38
2	18	-540
3	8	-972
4	239	-1728
5	245	-2129
6	221	-2172
7	250	-2595
8	126	-3942
9	248	-7919
10	74	-8388
11	23	-10983
12	22	-15230
13	218	-16213
14	176	-19217
15	203	-20391
16	64	-20391
17	97	-20391
18	142	-20391
19	150	-20391
20	155	-20391
21	157	-20391
22	158	-20391
23	164	-20391
24	165	-20391
25	174	-20391
26	185	-20391
27	199	-20391
28	200	-20391
29	204	-20391
30	240	-20747
31	168	-20832
32	16	-22144
33	2	-22826
34	115	-22983
35	19	-23300
36	12	-26150
37	81	-30208
38	223	-31662
39	20	-32936
40	169	-35854
41	7	-43983
42	222	-47040
43	63	-49667
44	242	-63661
45	9	-66260
46	226	-80021

#	Pozo	Descarga m ³ /día
47	56	-83333
48	111	-83333
49	166	-86725
50	1	-87660
51	217	-90180
52	219	-99944
53	170	-250000
54	27	-250000
55	41	-250000
56	124	-250000
57	144	-208333
58	233	-208333
59	234	-208333
60	244	-208333
61	57	-208333
62	60	-208333
63	123	-208333
64	238	-166667
65	247	-166667
66	249	-166667
67	46	-166667
68	55	-166667
69	67	-157675
70	216	-146347
71	122	-132703
72	177	-125000
73	214	-125000
74	235	-125000
75	236	-125000
76	237	-125000
77	24	-125000
78	26	-125000
79	30	-125000
80	31	-125000
81	37	-125000
82	39	-125000
83	42	-125000
84	44	-125000
85	48	-125000
86	98	-115625
87	62	-105125
88	66	-105125
89	70	-105125
90	80	-105125
91	82	-105125
92	95	-105125

III.4.9. Entrenamiento de la RNA

El proceso de entrenamiento se basa en la generación de registros del NF en el modelo de flujo. Estos registros son el resultado de la ejecución de MODFLOW, el cual parte de la suposición de que dicho modelo se encuentra calibrado. Posteriormente, MODFLOW se ejecuta con cambios en el ingreso de la descarga mensual que se utiliza en los pozos de descarga, la cual tendrá variaciones y se utilizará como valor objetivo para el modelo neuronal. En otras palabras, se generan los registros del NF en el modelo de flujo variando los parámetros de descarga en los pozos de extracción. Dichos registros del NF se utilizan como parámetros de entrada para la RNA. Mientras tanto, los valores de descarga que dieron lugar a estos registros del NF se utilizan como parámetros de entrenamiento (Fig. 18).

Para que la RNA comprenda el comportamiento de MODFLOW, se propusieron diferentes valores de descarga para los pozos durante cada período de entrenamiento. Inicialmente, estos valores derivan de los registros de las Tabla 11 y 12. Los cuales, se aumentaron aleatoriamente en incrementos del 5% hasta llegar al 200%. Durante el período de entrenamiento, el valor inicial de descarga registrado para un pozo se incrementó de manera aleatoria en intervalos del 5% durante las ejecuciones de MODFLOW. De esta manera, se obtiene un registro simulado del NF con variaciones mensuales en la descarga.

El objetivo de este proceso es evitar valores constantes en la descarga. Si se utilizan valores de descarga constantes durante cada mes en toda la simulación, se producirá una disminución del NF debido a ese valor constante. Esto podría llevar a que el modelo neuronal no aprenda correctamente, ya que, se verá forzado a intentar predecir el valor mensual constante de la descarga con el que fue entrenado. A pesar de que los parámetros de entrada muestran variaciones con respecto a cada pozo, el modelo neuronal interpretará esas características como una descarga constante en ese pozo en específico. Por lo cual, si se descarga el mismo valor en un pozo cada mes, la RNA aprenderá a generar una descarga igual al valor con el que fue entrenada. Esto introduce errores en el modelo neuronal, ya que, se espera que, al ingresar los parámetros de entrada, la RNA genere una descarga que cumpla con las características que se ingresa.

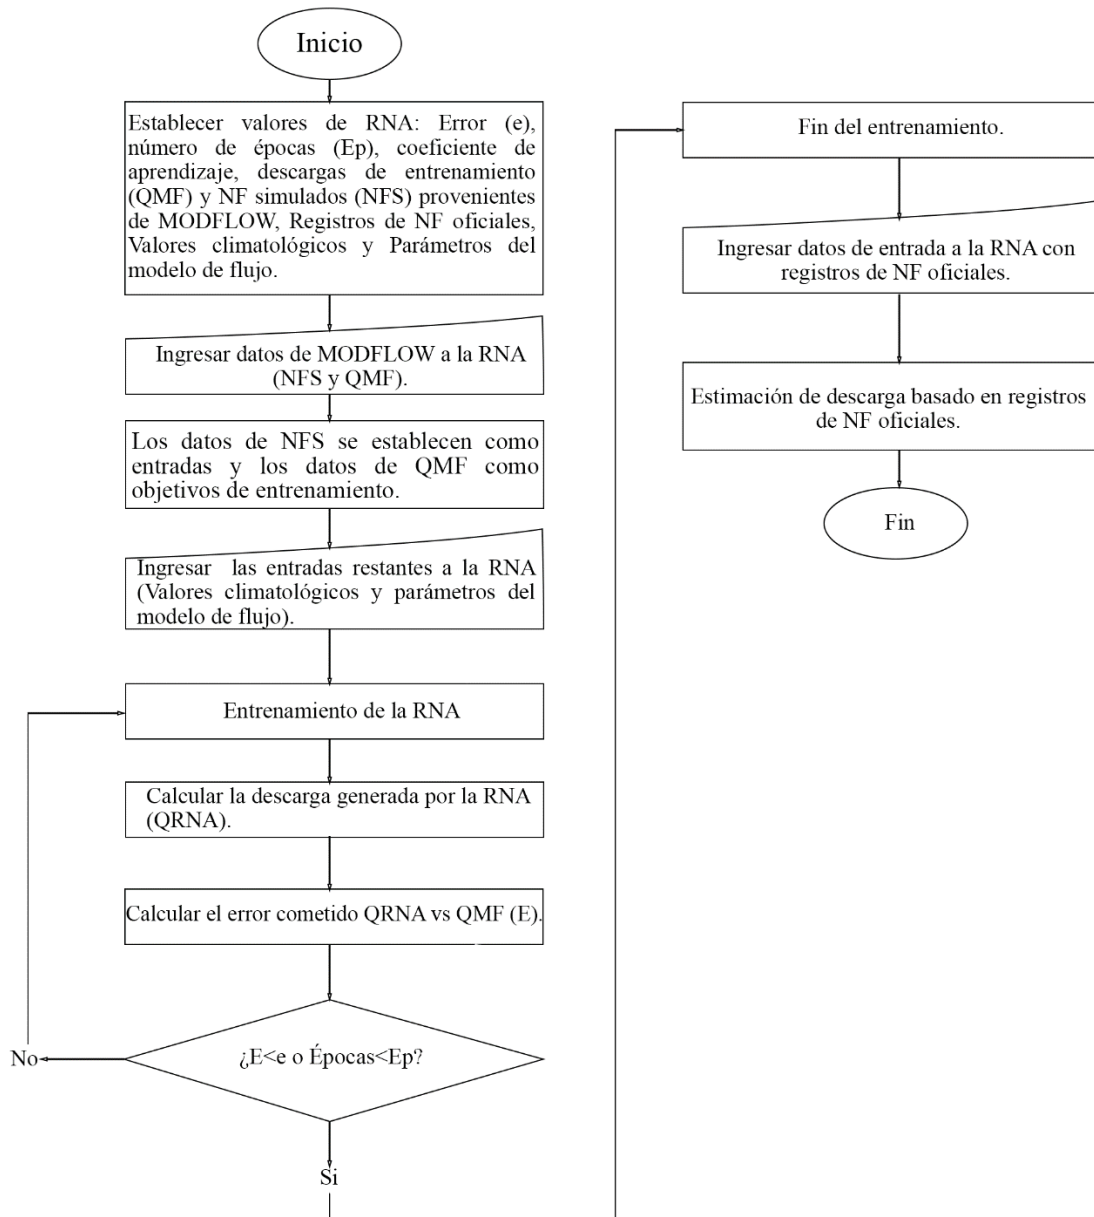


Figura 18. Diagrama de flujo para el entrenamiento de la RNA

III.4.10. Proceso de análisis de los datos

Se estimó la descarga para 19 fechas, excluyendo las fechas de abril (2010, 2011, 2012, 2013, 2014, 2016, 2016 y 2018), debido a que los pozos de descarga se encuentran inactivados en el modelo de flujo durante estos meses. Con excepción de abril de 2005, debido a la falta de registros NF entre 1999 y 2004, se utilizó una estimación para cubrir este vacío. En abril de 2005, se contó con datos de NF que fueron utilizados para estimar la descarga mensual correspondiente al año 2004. Para realizar esta estimación, se introdujeron los datos de abril de 2005 en la RNA. Posteriormente, la descarga estimada por la RNA se utilizó en el modelo de flujo para los meses de operación de los pozos durante el año 2004 (de mayo a octubre). De este modo, se logró cubrir el periodo sin datos previos basado en los valores del año 2005. Para el resto de los registros comprendidos en abril, los ajustes y mejoras que se obtuvieron al acercamiento que se pudiera haber obtenido con las estimaciones en la descarga antes de dicho mes, generalmente los registros de noviembre.

Las descargas estimadas fueron ingresadas al modelo durante los meses de operación de los pozos, lo que genera un registro constante de la descarga para los meses de mayo a octubre, con excepción de los años con los que se contó con más de dos registros (2009, 2013 y 2017), en dichas fechas fue posible estimar la descarga comprendida antes o durante el registro de NF. Es decir, las descargas se estimaron con la información del mes de registro y fueron ingresadas al modelo de flujo en los meses de operación de los pozos.

III.4.11. Datos utilizados en el modelo sintético

Con el objetivo de evaluar la aplicabilidad del modelo neuronal en un espectro más amplio de variabilidad climática y características geohidrológicas (tal como se expuso en la sección III.6), se procedió a utilizar un modelo sintético considerando un registro de precipitación para un periodo de 30 días.

En este modelo sintético se utilizaron los datos de la estacione climatológica Olivares Mexicanos, de la base de datos de CLICOM para establecer la variable climatológica (Precipitación), siendo el único criterio de selección, el tipo de clima, específicamente, un clima semiárido.

La elección de las fechas de la Tabla 13 se basó en la necesidad de abordar un periodo que involucrara la recarga por precipitación, tanto en la simulación del modelo en MDOFLOW como

en la fase de entrenamiento de la RNA. Por lo tanto, en el entrenamiento se utilizó un conjunto de datos que abarca 30 días y para la validación los 12 días consecutivos al periodo de entrenamiento. Como resultado, las salidas generadas por la RNA representan valores de descarga diaria.

Asimismo, los valores de descarga y NF fueron establecidos de acuerdo con los resultados de la ejecución del modelo sintético en MODFLOW. Recordando que dichos valores serán reconocidos por la RNA como parámetro de entrada (NF) y valores de entrenamiento (descarga). Por lo tanto, en MODFLOW el modelo ajusta el NF en las celdas de acuerdo con las variaciones inducidas en los valores de descarga de un determinado pozo. Por lo tanto, la RNA debe aprender de las características del modelo sintético basado en los parámetros de entrada para predecir un valor cercano a la descarga fijada durante cada día de la simulación (Tabla 13).

Tabla 13. Registro climatológico ingresado a MODFLOW y la RNA. Tomados de la base de datos CLICOM, estación meteorológica Olivares Mexicanos. Los datos de descarga y registros de NF corresponden al pozo_1 que se utilizó en el modelo de MODFLOW. Datos utilizados durante la validación (Color azul)

Fecha	Precipitación	NF	Descargas (Valores de entrenamiento)	Fecha	Precipitación	NF	Descargas (Valores de entrenamiento)
	mm	(msnm)	(m ³ /día)		mm	(msnm)	(m ³ /día)
12/01/2001	0.93	249.937	-2128.333	12/22/2001	1.28	249.856	-11218.333
12/02/2001	0.58	249.928	-2818.333	12/23/2001	0.48	249.859	-11638.333
12/03/2001	0.58	249.928	-3238.333	12/24/2001	1.74	249.850	-12058.333
12/04/2001	1.27	249.926	-3658.333	12/25/2001	0.73	249.846	-12478.333
12/05/2001	1.48	249.921	-4078.333	12/26/2001	0.54	249.849	-12898.333
12/06/2001	1.22	249.914	-4498.333	12/27/2001	1.98	249.849	-13318.333
12/07/2001	0.61	249.913	-4918.333	12/28/2001	2.63	249.840	-13738.333
12/08/2001	1.1	249.910	-5338.333	12/29/2001	1.6	249.831	-14158.333
12/09/2001	1.18	249.905	-5758.333	12/30/2001	0.49	249.833	-14578.333
12/10/2001	0.98	249.899	-6178.333	01/01/2002	1.01	249.935	-29854.55
12/11/2001	0.35	249.898	-6598.333	02/01/2002	1.33	249.934	-29274.85
12/12/2001	0.95	249.893	-7018.333	03/01/2002	0.3	249.926	-4637.6
12/13/2001	0.67	249.890	-7438.333	04/01/2002	3.66	249.940	-13912.8
12/14/2001	0.76	249.887	-7858.333	05/01/2002	2.92	249.934	-30434.25
12/15/2001	0.95	249.890	-8278.333	06/01/2002	1.62	249.925	-5507.15
12/16/2001	2.26	249.881	-8698.333	07/01/2002	3.79	249.933	-25796.65
12/17/2001	1.22	249.883	-9118.333	08/01/2002	2.1	249.922	-4927.45
12/18/2001	2.23	249.879	-9118.333	09/01/2002	2.01	249.919	-11304.15
12/19/2001	1.2	249.869	-9958.333	10/01/2002	2.01	249.916	-24927.1
12/20/2001	0.84	249.867	-10378.333	11/01/2002	0.79	249.907	-5217.3
12/21/2001	1.16	249.864	-10798.333	12/01/2002	1.28	249.907	-15651.9

En el modelo sintético, se ha tenido en cuenta la inclusión del relieve topográfico. Esto se hace con el fin de mantener variaciones entre cada columna que forma la estructura del modelo; añadiendo así variaciones en la representación del terreno. La Figura 19 muestra los resultados obtenidos a partir de esta consideración, la cual propone un incremento de 1 m entre cada columna, visto de izquierda a derecha.




Figura 19. Topografía ingresada al modelo sintético en MODFLOW

IV. RESULTADOS Y DISCUSIONES

En esta sección se presentan los resultados de la configuración y simulación numérica del flujo de agua subterránea, realizados con MODFLOW. El objetivo del modelo es obtener una versión calibrada que se utilizará posteriormente para entrenar la red neuronal artificial (RNA). A continuación, se exponen los resultados y hallazgos derivados del análisis de los registros de NDVI, seguidos de los resultados obtenidos para las 27 fechas de modelación con la implementación del modelo de flujo. Posteriormente, se presentan los resultados de la aplicación de la RNA en el caso sintético descrito en el capítulo III.3.3 de este trabajo. Finalmente, se muestran los resultados de las estimaciones de bombeo obtenidas a partir del modelo neuronal implementado en MATLAB.

IV.1 Configuración Del Modelo De Flujo Del Agua Subterránea

En esta sección se presenta una descripción de los aspectos relacionados con la construcción del modelo de flujo, la discretización espacial y temporal, la calibración de condiciones estacionarias y transitorias, así como el comportamiento del modelo en respuesta a la demanda de los recursos hídricos subterráneos. La elaboración y desarrollo de este modelo de flujo tiene como propósito obtener un modelo lo más preciso posible. Dado que, será utilizado para entrenar y validar las descargas estimadas por la RNA.

El enfoque del modelo conceptual empleado en este estudio para simular los AVON se basa en el propuesto por Vázquez et al. (1991) y Campos Gaytán (2002). Su modelo conceptual describe a los acuíferos como sistemas heterogéneos, con un flujo horizontal en régimen transitorio, sobre un basamento impermeable de topografía irregular.

IV.1.1 Condiciones iniciales

Durante un período de análisis de 35 años (1983-2018), se llevó a cabo la simulación en condiciones estacionaria y transitoria del modelo de flujo. Por lo tanto, la elección de la condición inicial en el tiempo es de gran importancia para iniciar la simulación. Después de analizar y considerar los registros de CONAGUA sobre la precipitación histórica (Fig. 3) y las elevaciones del NF (Fig. 20), el año 1983 destaca como un punto importante en el comportamiento del AON. Debido a que se evidencia el final de un período de cuatro años con precipitaciones iguales o

superiores al promedio anual (Beltrán, 1997); adicionalmente, se registró la menor profundidad promedio del NF. Teniendo en cuenta estos datos y considerando que el efecto de los pozos en operación en la elevación del NF es mínimo en esa fecha, es posible interpretar que el acuífero se encontraba en su capacidad de almacenamiento máxima o en un estado estacionario. A causa de ello, para la simulación de las condiciones en estado estacionario se optó enero de 1983 como condición inicial; ya que, se supone que el sistema de agua subterránea se encontraba en o cerca de un equilibrio.

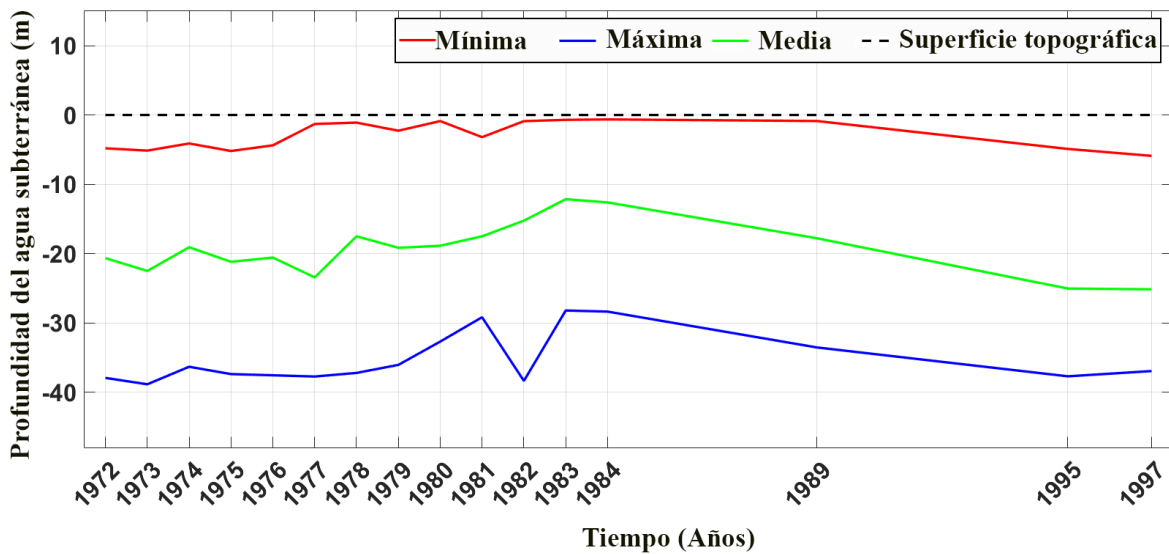


Figura 20. Datos del NF en el AON durante el periodo 1972-1997 (extraídos de Beltrán, 1997)

IV.1.2. Dominio del modelo y discretización

Después de haber revisado las delimitaciones físicas que restringen el sistema acuífero y haber analizado la información correspondiente a sus propiedades hidráulicas, se decidió construir una cuadrícula en diferencias finitas compuesta por celdas cuadradas con dimensiones de 0.25 km por lado. Cuya geometría propuesta se superpone al área de estudio y consiste en 76 filas y 63 columnas, dando un total de 4,788 celdas (Fig. 21), que cubren un área de 299.25 km².

La información hidrogeológica recopilada se utilizó para delimitar el área del sistema de flujo de agua subterránea y definir los límites este y oeste; cuyos límites corresponden a contactos litológicos entre rocas permeables e impermeables (Fig. 2).

Por otro lado, el límite sur, que delimita aproximadamente la subcuenca ON de la subcuenca de Maneadero (Fig. 1), presenta una elevación en la topografía del basamento impermeable en la parte sur del área de estudio. Por lo tanto, el límite sur de la subcuenca de ON se puede considerar como un límite de flujo nulo, es decir el flujo de agua no cruza la frontera.

Asimismo, según la información proporcionada por CONAGUA, en el límite norte, que corresponde a la salida aguas abajo del acuífero RC, se ha observado una notable estabilidad en las elevaciones del NF con el tiempo (aproximadamente 2.5 m en 10 años) (Campos-Gaytán, 2002). Por lo tanto, se considera como una frontera de NF constante.

El número de celdas que componen el dominio de flujo se basa en la información de las propiedades físicas de los materiales presentes en el área de estudio. Se identificaron un total de 2,099 celdas (131.19 km²) como celdas impermeables externas, que representan rocas ígneas y metamórficas y corresponden a los límites este y oeste. Además, se identificaron 127 celdas (7.94 km²) como celdas impermeables internas, que representan afloramientos intermedios de rocas metamórficas e ígneas. Por otro lado, la zona en los acuíferos ON y RC abarcó 2,562 celdas (160.12 km²), lo que es ligeramente menor que el área reportada previamente de aproximadamente 172.5 km². Estas celdas consisten en depósitos aluviales y fluviales, incluyendo gravas, arenas, limos y arcillas, así como depósitos de laderas y estribaciones, y se denominan celdas activas donde se resuelven las ecuaciones de flujo. Esta refinación en el proceso de mallado permite una delimitación de los límites del acuífero. Además, dicha reducción en el mallado se espera tenga mejoras en las estimaciones de los NF.

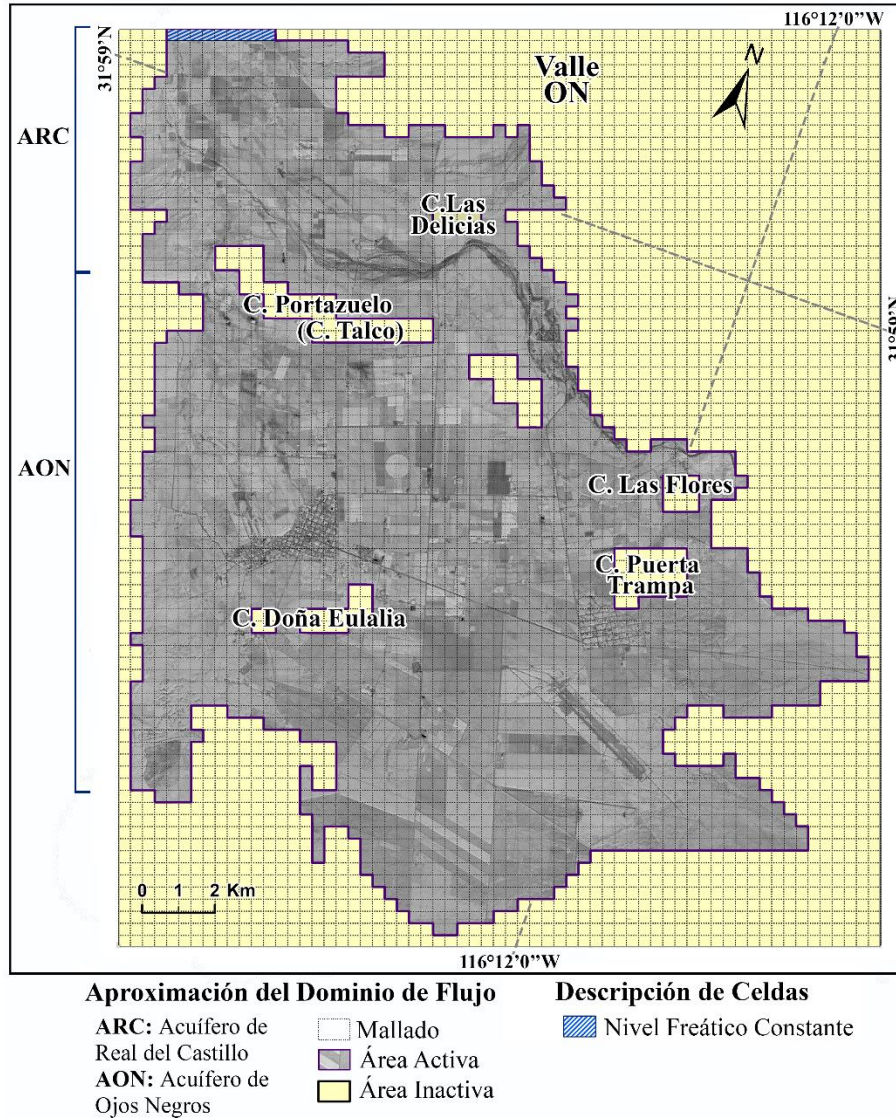


Figura 21. Características hidrológicas y aproximación del dominio de flujo del agua subterránea. Los límites irregulares de los acuíferos de estudio se reemplazaron con una configuración de líneas rectas

IV.1.3. Discretización temporal

Para replicar todo el período de simulación desde 1983 hasta 2018, se utilizaron períodos de estrés mensuales, básicamente, debido a la disponibilidad de datos mensuales de precipitación y registros del NF. En total, se utilizaron 423 períodos de estrés en estado transitorio. Dado que los períodos de estrés muestran consistencia con los valores registrados en el campo, se considera que la resolución temporal es adecuada para capturar las variaciones de cada mes.

IV.1.4. Recarga y Descarga

La información climatológica necesaria para llevar a cabo la evaluación hidrogeológica en los AVON, se compiló de las estaciones climatológicas del Valle de San Rafael y Ojos Negros (Figs. 1 y 3). La primera, operada por CONAGUA, incluye información suficiente para abarcar los años 1980-2012. En contraste, la segunda estación climatológica es operada por el Sistema de Información para el Manejo del Agua de Riego en el Estado de Baja California (SIMARBC), y su información engloba el período de registro 2013-2022. Esta última estación cuenta con registro actualizado de datos para el período 2012-2018. A partir de la recopilación de datos climatológicos disponibles, se calcularon los valores promedio de precipitación anual (Fig. 3). Dichos valores se emplearon para calcular la recarga mensual total correspondiente al periodo de simulación.

La recarga del acuífero está predominantemente influenciada por la infiltración de las lluvias. En trabajos previos realizados en cuencas con características similares al VON en relación a clima, vegetación y fisiografía, han determinado que aproximadamente el 10% de la precipitación se infiltra en el acuífero (Ponce et al., 1999; Vázquez et al., 1991). Por consiguiente, en este trabajo se considera que el 10% de la precipitación media anual se infiltra en el subsuelo de los acuíferos ON y RC

Con respecto a la recarga horizontal (frente de montaña) en el área de estudio, se han identificado las fronteras este y oeste como barreras impermeables, con la excepción de los sitios donde el escurrimiento de las serranías entra en el valle. En estos puntos, el volumen de recarga se calcula considerando un porcentaje de la precipitación media anual ocurrida en la subcuenca de ON, que fluye desde las serranías y llega al valle como recarga horizontal; luego, el volumen de recarga se distribuye proporcionalmente al tamaño de los arroyos y barrancos que descienden de las montañas (Campos-Gaytán, 2002). Basándose en la investigación realizada por Campos-Gaytán (2002), la recarga se asigna y distribuye en celdas (Fig. 22). En consecuencia, estos puntos aportan un flujo adicional que contribuye a la recarga de los AVON.

Además, en el interior de los acuíferos se pueden identificar zonas impermeables, como las serranías internas, tales como los cerros: Del Talco, Las Delicias, Las Flores, Puerta Trampa y Doña Eulalia, donde también ocurre recarga horizontal debido a la precipitación dentro del área de estudio. Sin embargo, el impacto de esta recarga es menor en comparación con la recarga horizontal que ocurre como resultado del escurrimiento de las serranías externas. En la Tabla 14

se muestra el número de celdas que comprenden estas zonas y los puntos de recarga correspondientes a cada zona (Fig. 22).

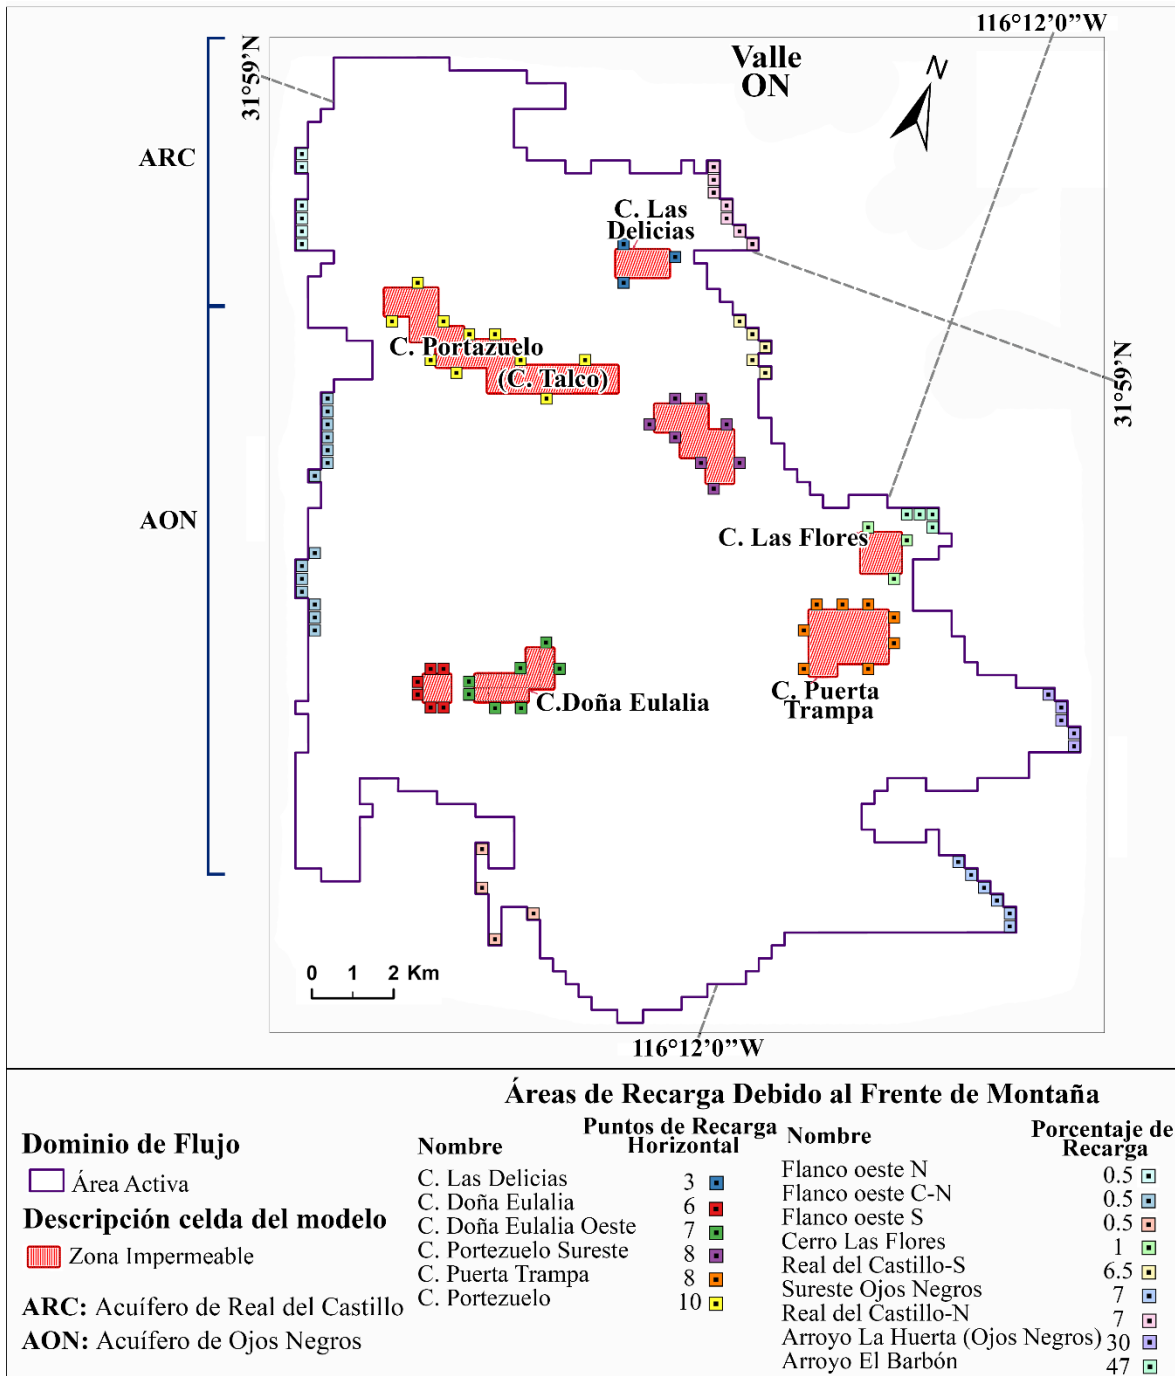


Figura 22. Recarga de agua subterránea, celdas con recarga de agua subterránea por infiltración directa de la precipitación media anual y recarga del frente de montaña

Tabla 14. Puntos de recarga horizontal por escurrimiento de las serranías interiores al dominio de flujo

Ubicación de la zona en relación con el acuífero	Número de celdas que conforman la zona analizada	Puntos de recarga horizontal
C. Doña Eulalia	4	6
C. Las Delicias	8	3
C. Doña Eulalia Oeste	14	7
C. Portezuelo Sureste	20	8
C. Puerta Trampa	26	8
C. Portezuelo	46	10

Por lo tanto, los escurrimientos horizontales por frente de montaña se consideraron como recarga puntual (recarga horizontal), ubicada tanto en los bordes Este y Oeste del VON, así como en cada una de las direcciones principales con respecto a los afloramientos rocosos presentes en el interior del valle (zonas impermeables interiores) (Fig. 22).

Un análisis del régimen hidrológico del VON revela que esta recarga horizontal no se limita exclusivamente a los períodos de lluvia, que generalmente ocurren entre los meses de noviembre y marzo, sino que se ha observado que ocurre constantemente a lo largo del año, gracias a la presencia de áreas agrícolas cercanas que aportan una cierta cantidad de agua a través de los retornos de riego (SARH, 1974). En consecuencia, se ha considerado que la recarga natural debida a los escurrimientos horizontales de montaña permanece constante durante todos los meses del año en los AVON.

Por otro lado, la descarga de los AVON se lleva a cabo mediante el bombeo. Sin embargo, debido a que la información sobre los períodos de operación de los pozos es limitada, la CONAGUA ha estimado que los pozos están operativos solo durante el 50% del año (de mayo a octubre). Además, la CONAGUA (2009) ha estimado que el volumen de extracción de agua subterránea a través de los pozos en el AON es de aproximadamente 25.5 Mm³/año y de aproximadamente 10 Mm³/año para el ARC (CONAGUA, 2013). Sin embargo, es importante señalar que el cálculo de la descarga anual es una estimación aproximada debido a la falta de medidores de flujo volumétrico en cada pozo. En consecuencia, durante el proceso de validación del modelo, se realizaron ajustes a las tasas de bombeo de algunos pozos, basado en los trabajos realizados por Campos-Gaytán (2002) y Padilla Morín (2013), con el propósito de lograr reproducir NF más precisos. Aunado a esto, la ubicación de los pozos de bombeo, así como su volumen estimado de extracción y su período de operación, toman como base los informes proporcionados por la CONAGUA (2009) y (2013),

tales datos concuerdan en gran medida con los trabajos presentados por Campos-Gaytán (2002) y Padilla Morín (2013).

Derivado a esto, durante la simulación, se consideró que los pozos operaban de mayo a octubre, con un volumen de extracción establecido en dos períodos. El primero ocurre en los años 1983-1991, donde se estima un volumen de extracción de $30 \text{ Mm}^3/\text{año}$, distribuido en 38 pozos; mientras que el segundo tiene lugar durante los años 1992-2018, para el cual se estima un volumen de extracción de $45 \text{ Mm}^3/\text{año}$, distribuido en 92 pozos de extracción (Tablas 11 y 12). Cada período incluye los volúmenes de extracción para los AVON. Los pozos se consideran como puntos de descarga con una tasa de flujo constante durante la modelación (sin incluir los valores de descarga estimados por la RNA, los cuales presentan variaciones entre cada periodo modelado). La ubicación de dichos se muestra en la Figura 23.

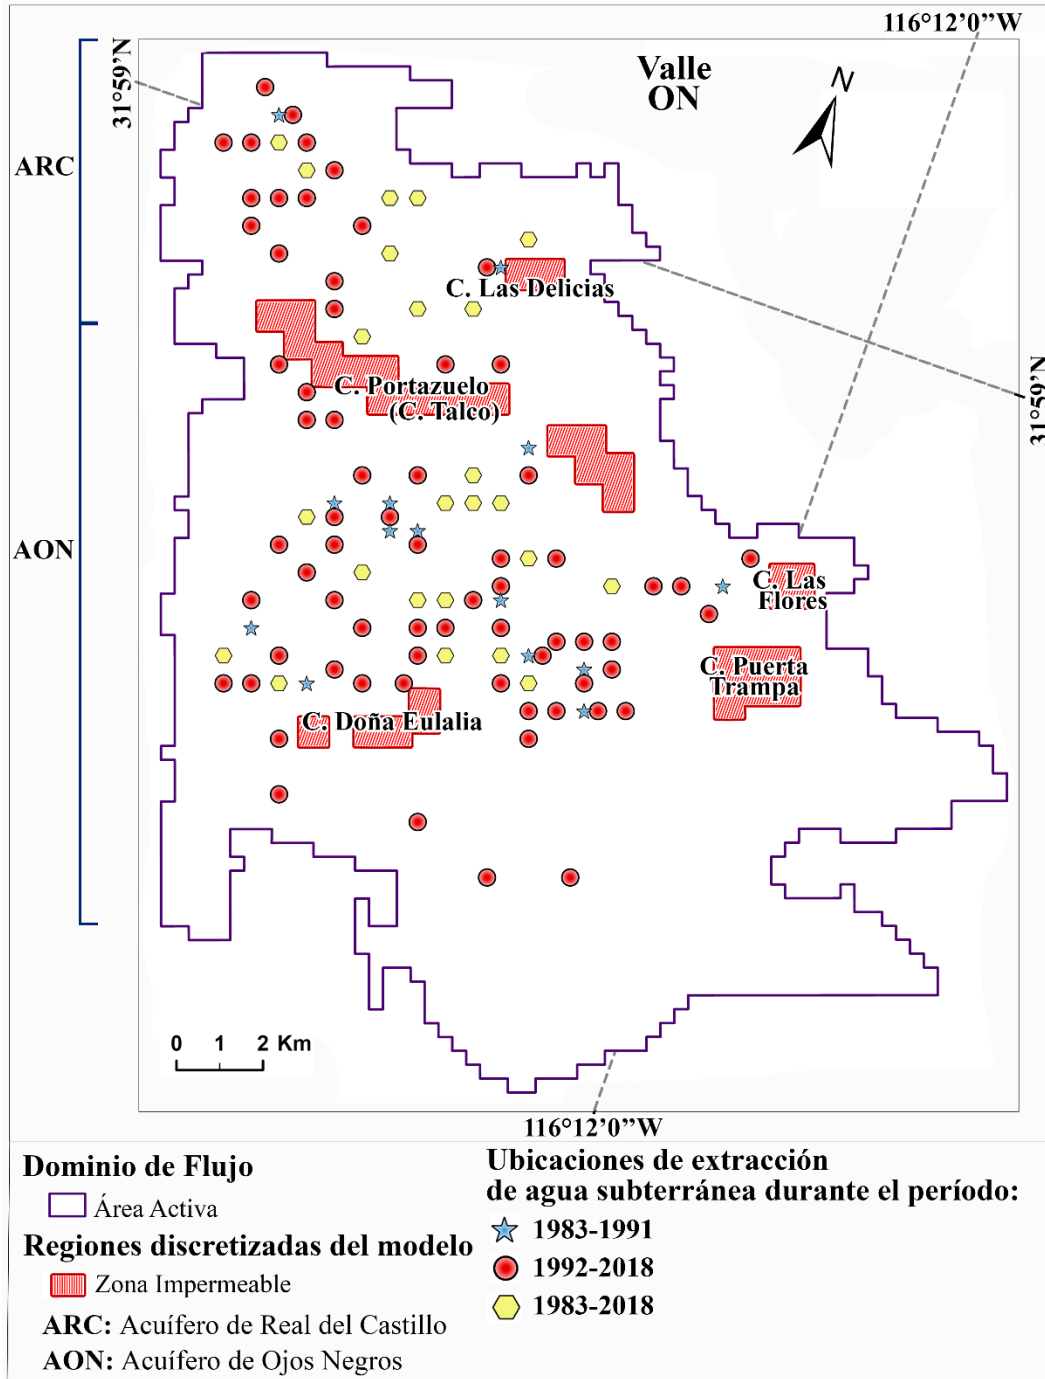


Figura 23. Descarga de aguas subterráneas: Ubicación de los pozos de bombeo considerados durante todo el período de simulación

IV.1.5. Coeficiente de almacenamiento

Con base en la información recopilada, Fetter (1994) propone un rango de coeficiente de almacenamiento de 0.02 a 0.30 para acuíferos tipo libre (o no confinado), independientemente del tipo de material permeable. Sin embargo, cuando el acuífero libre consiste principalmente de material poroso intergranular, Villanueva e Iglesias (1984) reducen ese rango de 0.05 a 0.15. Dado que los acuíferos ON y RC consisten en depósitos aluviales y fluviales que incluyen arenas, gravas, limos y arcillas, aludiendo a una composición heterogénea, se pueden considerar como pertenecientes a este último intervalo (0.15).

Estudios previos empleando diversas técnicas han estimado valores en el rango de 0.09 a 0.14 para los acuíferos ON y RC (SARH, 1974; Vázquez et al., 1991; Beltrán, 1997; Ercan, 1999). Por lo tanto, se determinó que un coeficiente de almacenamiento de 0.14 para ambos acuíferos se ajustaba a las condiciones hidrogeológicas. Se opta por este valor como una estimación intermedia entre los valores previos.

IV.2. Calibración del Modelo de Flujo

La calibración del modelo de flujo se realizó empleando el registro histórico de elevaciones del NF durante el período 1983-2018 (Fig. 24). Este proceso de ajuste abordo tanto condiciones estacionarias como transitorias. Los valores de conductividad hidráulica se ajustaron progresivamente, utilizando el método de prueba y error. El propósito era maximizar la correspondencia entre los NF calculados y observados.

Adicionalmente, se estima la recarga natural mensual, considerando los datos de precipitación media anual (Tabla 15). El cálculo mostró un valor promedio de $25.8 \text{ Mm}^3/\text{año}$, aproximadamente el 10% de la precipitación media anual.

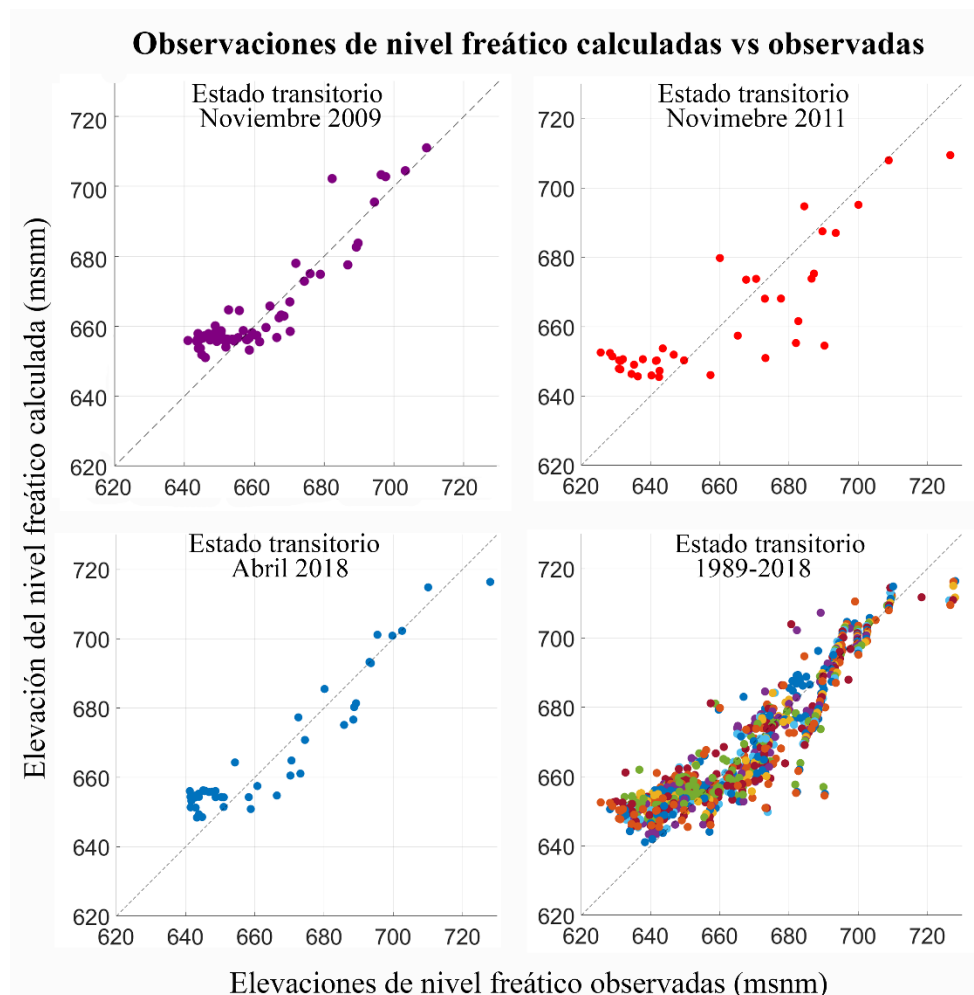


Figura 24. Comparación de registros de las elevaciones del NF, calculadas vs observadas, para los AVON

Tabla 15. Precipitación media anual (mm) para el periodo 1983-2021. Datos obtenidos de las estaciones climatológicas de Ojos Negros y Valle de San Rafael. Nota: El símbolo '-' indica que no hay información o datos disponibles

Estación / Coordenadas	Ojos Negros (mm) / 31°54'44'' 116°15'53''	Valle de San Rafael (mm) / 31°55'08'' 116°14'13''	Volumen de infiltración (m ³)
Año			La superficie de la subcuenca de Ojos Negros es de 1,094.5 km²
1983	539.80	-	58,081,110
1984	186.4	-	20,401,480
1985	187.4	-	20,510,930
1986	189.65	-	20,757,193
1987	241.8	-	26,465,010
1988	177.3	-	19,405,485
1989	59.45	-	6,506,803
1990	217.5	-	23,805,375
1991	377	-	41,262,650
1992	291.25	-	31,877,313
1993	316.75	-	34,668,288
1994	258.65	-	28,309,243
1995	392.1	-	42,915,345
1996	187.6	-	20,532,820
1997	250.1	-	27,373,445
1998	369.8	-	40,474,610
1999	119.5	-	13,079,275
2000	160	-	17,501,055
2001	239	-	26,202,330
2002	204	-	22,294,965
2003	204	-	22,316,855
2004	282	-	30,875,845
2005	217	-	23,739,705
2006	110	-	12,072,335
2007	153	-	16,702,070
2008	204	-	22,305,910
2009	144	-	15,749,855
2010	508	-	55,622,490
2011	274	-	30,033,080
2012	165	-	18,059,250
2013	-	190	20,839,280
2014	-	215	23,477,025
2015	-	195	21,298,970
2016	-	300	32,878,780
2017	-	174	19,022,410
2018	-	159	17,380,660
2019	-	340	37,191,110
2020	-	177	19,383,595
2021	-	218	23,892,935
		Promedio	25,776,074

Así mismo, en las circunstancias actuales, la extracción de agua subterránea con fines domésticos y agrícolas constituye el principal volumen de explotación de los AVON. Dicha explotación se estima de aproximadamente de 37.5 Mm³/año durante el periodo 1983-2018.

En contraste, la tasa de evapotranspiración se considera como nula debido a que desde 1997, los AVON han estado sujetos a un régimen de sobreexplotación que ha modificado sus condiciones naturales. En la actualidad, no se presentan salidas por flujo subterránea ni evapotranspiración, ya que la elevación del agua subterránea se ha profundizado drásticamente (Secretaría de Gobernación, 2017).

Como parte del objetivo de este estudio se ha obtenido un conjunto de parámetros para la simulación del flujo de agua subterránea que ayudará a mejorar el ajuste vertical entre las elevaciones del NF calculadas y observadas. Consecuentemente, el código de conductividad hidráulica (Fig. 15) ha permitido que más agua entrara y fluyera a través de los AVON.

IV.2.1 Condición Inicial del Modelo de Flujo

Las elevaciones del NF estimadas en Enero de 1983 correspondientes a la simulación en estado estacionario, no pudieron ser comparadas con datos observados, debido a la escasez de la información piezométrica para en dicha fecha. Aun así, la superficie piezométrica fue comparada con los datos de elevaciones de la topografía del terreno, exclusivamente en la zona del AON, obtenidos de la Carta Topográfica H11B13 Real de Castillo Nuevo (INEGI, 1974). Los resultados de esta comparación sugieren que dicha superficie piezométrica se encuentra en promedio 8.43 m por debajo de la topografía del terreno, lo cual concuerda con la información de Beltrán (1997) (Fig. 25a).

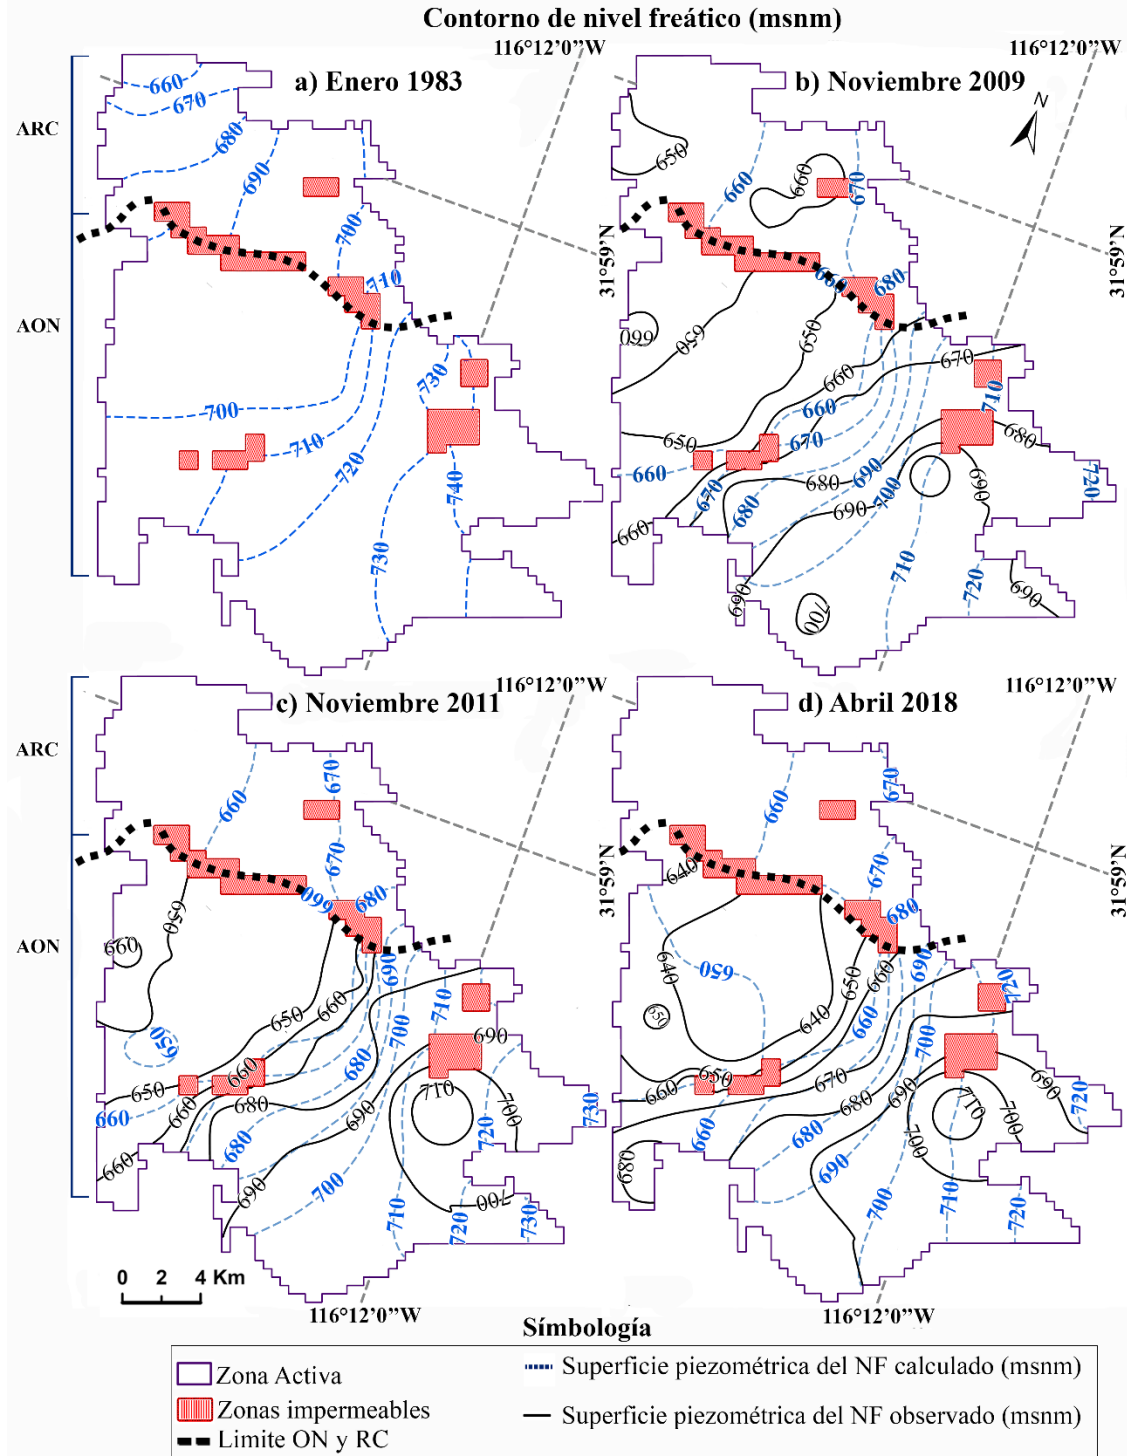


Figura 25. Superficies piezométricas del NF calculados y observados. a) Estado estacionario para los AVON, enero de 1983. b) Estado transitorio para los AVON, noviembre de 2009 (después de 322 meses de simulación), 1983-2009. c) Estado transitorio para el AON, noviembre de 2011 (después de 346 meses de simulación), 1983-2011. d) Estado transitorio para el AON, abril de 2018 (después de 423 meses de simulación), 1983-2018

IV.2.2 Condiciones Transitorias del Modelo de Flujo

Se utilizaron los registros del NF desde 1989 hasta 2018 para validar el modelo de flujo de agua subterránea en condiciones transitorias. En el AON, los niveles calculados del NF en noviembre de 2009 mostraron fluctuaciones que iban desde aproximadamente 651 msnm hasta más de 730 msnm. En cambio, en el ARC, estos niveles variaron de 655 a 680 msnm (Fig. 25b). De manera similar, durante la simulación de noviembre de 2011, los NF fluctuaron entre 648 y más de 730 msnm en el AON, mientras que en el ARC oscilaron entre 654 y 678 msnm (Fig. 25c). Para la simulación de abril de 2018, las elevaciones del NF variaron de 640 a más de 720 msnm en el AON, mientras que en el ARC variaron entre 653 y 676 msnm (Fig. 25d).

Los resultados obtenidos entre 1989 y 2018, mostraron diferencias en el ajuste vertical entre los NF simulados y observados con RMSE promedio de 9.48m en el AON y 5.58m en el ARC. Así mismo, los resultados de la condición transitoria indicaron una disminución de aproximadamente 1 m al año en los NF.

En general, la simulación numérica de agua subterránea fue consistente con las observaciones. La mayoría de los pozos mostraron disminuciones en los NF durante los 35 años de simulación de debido a la sobreexplotación de los recursos hídricos subterráneos. Particularmente, se destacaron resultados excelentes para los pozos P-199 CNA (ARC, sección central) y P-170/55 (AON, sección suroeste) cuyos valores del RMSE son de 2.35 y 3.16 m, respectivamente (Fig. 26).

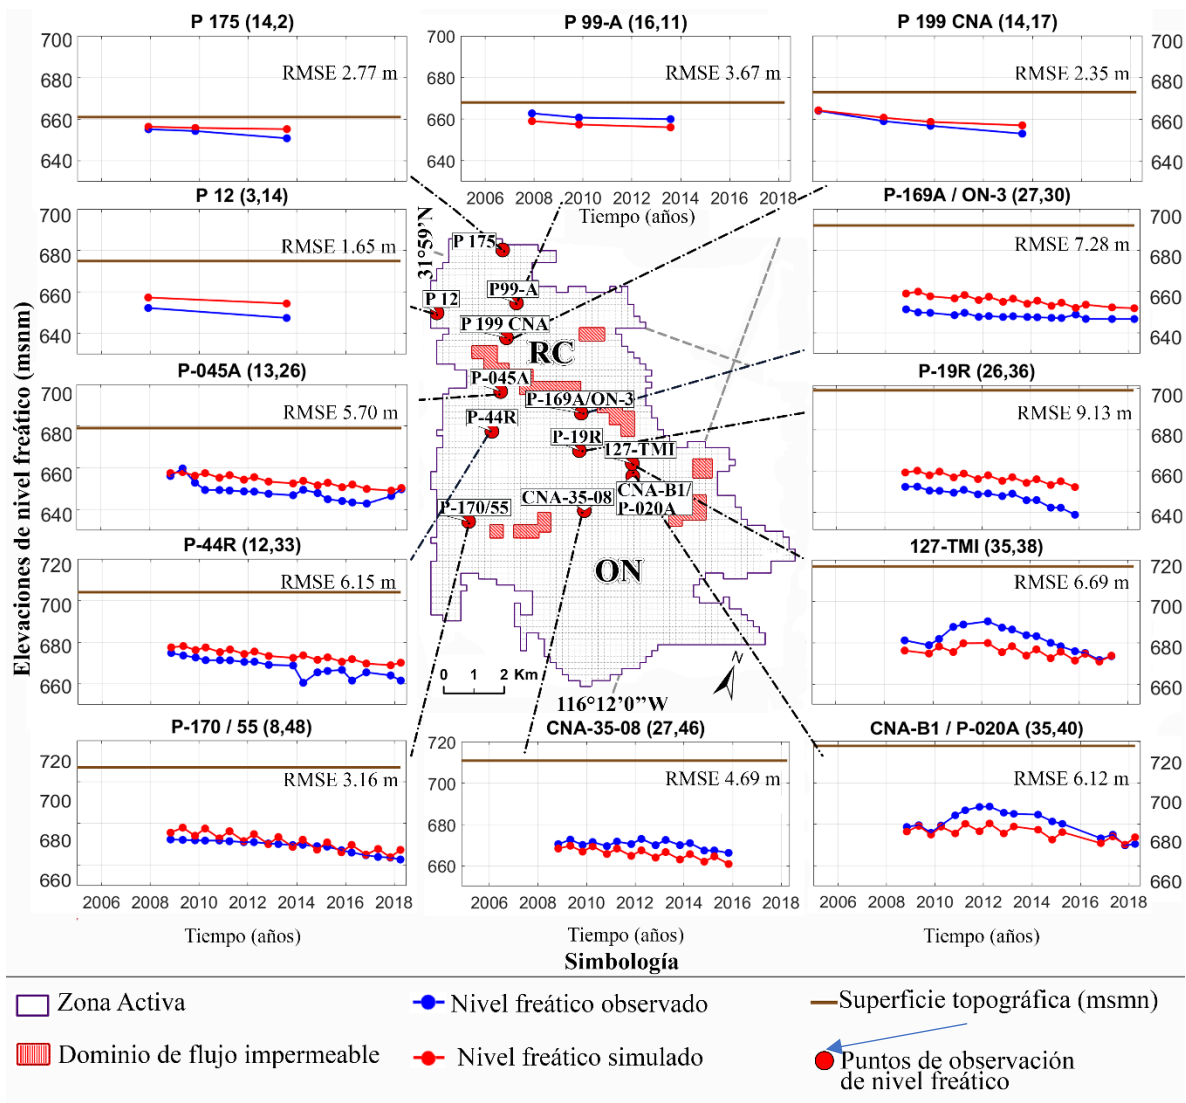


Figura 26. Hidrogramas de los pozos ubicados en los Acuíferos de Ojos Negros y Real del Castillo

Algunos pozos, tal como CNA-B1/P-020A y 127-TMI (ambos pozos en el AON, sección central este), mostraron fluctuaciones en las elevaciones del NF observado que no se lograron reflejar con precisión en el modelo. La a la respuesta del acuífero a eventos de precipitación podría estar relacionada con dicho comportamiento, dado que, durante esos años se registraron niveles de precipitación por encima de la media (Fig. 3a). Lo que pudo reflejarse como un porcentaje de recarga superior al 10% que se considera en la modelación.

Además, los pozos P-19R y P 169/ON-3 (ambos pozos en el AON, sección noreste) presentan variaciones en los NF con respecto a los registros observados, lo cual puede deberse principalmente al hecho de que no todos los pozos cumplen con los estándares de observación.

Aun así, los NF calculados para los pozos mencionados a continuación sugieren que las distribuciones de conductividad hidráulica utilizadas en el modelo de flujo son coherentes (Fig. 26). Los pozos 127-TMI y CNA-B1/P-020A (ambos pozos en el AON, sección central este) se encuentran en una región establecida por una conductividad hidráulica de 125 m/mes, y presentan un RMSE de 6.12 y 6.49 m, respectivamente. En un contexto similar, los pozos P-175 (ARC, sección central norte) y P-99-A (ARC, sección central) se encuentran en una zona donde la conductividad hidráulica es de 166.67 m/mes, y muestran un RMSE de 2.77 y 3.67 m, respectivamente. Asimismo, el pozo P-199 CNA (ARC, sección central sur), con un RMSE de 2.35 m, se encuentra en una región con una conductividad hidráulica de 1,250 m/mes. Además, los pozos P-12 (ARC, sección central oeste), P-44R (AON, sección noroeste) y P-169/ON-3 (AON, sección norte), cuyas conductividades hidráulicas son de 6,666.67 m/mes, registran RMSE de 1.65, 6.15 y 7.28 m, respectivamente. Finalmente, los pozos P-045A (AON, sección noroeste) y P-19R (AON, sección central), con RMSE de 6.15 y 9.13 m, respectivamente, ambos se encuentran en una zona con conductividad hidráulica de 8,333.33 m/mes.

IV.3. Registros de NDVI

Con la finalidad de estudiar el NDVI, se consideró un área de 250x250 m alrededor de cada uno de nueve (9). Dicha área corresponde al tamaño de una celda en el modelo de flujo. Los pozos se encuentran localizados a lo largo y ancho de los AVON (P-175, P-99-A, P-199 CNA, P-19R, P-045A, P-44R, 127-TMI, P-170/55, P-045A y CNA-35-08) y abastecen una parte de la demanda de agua que requiere la vegetación y los cultivos en ambos acuíferos; cuyo criterio de selección ha sido que los distintos pozos abarquen varias zonas de conductividad hidráulica. La discretización de los valores de NDVI se fijó en un rango de entre 0.2 y 1, siendo los valores más cercanos a 1 aquellos con mayor vigor vegetativo y los valores entre 0 y 0.2 corresponde a suelos desnudos. El total de los promedios correspondientes a cada valor de NDVI se muestra en la Tabla 16. Como se puede observar los valores de NDVI por debajo de 0.3, predominantes en la mayor parte de la ONVA durante los meses de mayo a noviembre, los cuales son consistentes con lo esperado en zonas áridas (Salinas-Zavala et al., 2017).

En esta investigación se han definido los 150 mm de precipitación media anual como un umbral de precipitación, enfocándose en eventos con una precipitación mayor que el umbral, ya que, son estos valores los que influyen para la obtención de valores más altos del NDVI (Fig. 3a). Los años con valores de NDVI más altos fueron durante abril de 2005 y 2013, donde la mayoría de los pozos mostraron un NDVI promedio superior a 0.7, coincidiendo con precipitaciones superiores a 150 mm. Entre 2010 y 2016, abril presentó un NDVI mayor o igual a 0.5 en la mayoría de los pozos, acompañado por precipitaciones superiores al promedio en 2010, 2011 y 2016. Los valores de NDVI más bajos se observaron en noviembre de 2009 y abril de 2018, con precipitaciones inferiores a 150 mm y superiores a 150 mm en 2014 y 2018 (Tabla 16).

Tabla 16. Valores promedio del NDVI en un área de 250x250 m alrededor de cada pozo seleccionado y registros del nivel freático (msnm). *Nota: NF indica nivel freático. El símbolo '-' indica que no hay información o datos disponibles. Las celdas marcadas en verde representan fechas en las que la precipitación media anual fue mayor o igual a 150 mm*

Pozo	P 99-A		P-170/55		P-175/56		P199 CNA		P-19R		P-045A		P-44R		CNA-35-08		127-TMI	
	NDVI	NF	NDVI	NF	NDVI	NF	NDVI	NF	NDVI	NF	NDVI	NF	NDVI	NF	NDVI	NF	NDVI	NF
Fecha	Prom	(msnm)	Prom	(msnm)	Prom	(msnm)	Prom	(msnm)	Prom	(msnm)	Prom	(msnm)	Prom	(msnm)	Prom	(msnm)	Prom	(msnm)
Abr 2005	0.46	-	0.70	-	0.61	-	0.78	664.06	0.24	-	0.79	-	0.77	-	0.25	-	0.77	-
Dic 2007	-	662.75	-	-	-	655.12	-	659.06	-	-	-	-	-	-	-	-	-	-
Nov 2008	0.30	-	0.38	652.29	0.28	-	0.67	-	0.34	-	0.52	656.06	0.33	654.80	0.41	670.55	0.37	681.24
May 2009	0.23	-	0.49	652.08	0.32	-	0.36	-	0.23	-	0.49	659.67	0.55	653.60	0.42	672.73	0.49	-
Nov 2009	0.26	660.71	0.28	651.86	0.23	654.27	0.32	656.84	0.38	-	0.39	652.87	0.31	652.66	0.39	670.17	0.65	678.92
Abr 2010	0.30	-	0.79	651.75	0.54	-	0.41	-	0.39	-	0.56	649.36	0.63	651.34	0.30	671.58	0.51	681.94
Nov 2010	0.26	-	0.48	651.76	0.30	-	0.32	-	0.43	652.30	0.58	649.34	0.46	651.35	0.36	669.58	0.72	687.75
Abr 2011	0.26	-	0.53	651.45	0.55	-	0.51	-	0.24	652.38	0.48	649.09	0.55	651.26	0.31	671.80	0.60	688.89
Nov 2011	0.28	-	0.27	651.01	0.25	-	0.36	-	0.45	650.44	0.48	648.68	0.35	650.51	0.46	670.60	0.63	-
Abr 2012	0.21	-	0.35	651.00	0.37	-	0.65	-	0.58	650.36	0.36	648.59	0.54	650.61	0.17	673.11	0.66	690.46
Nov 2012	0.22	-	0.18	650.35	0.17	-	0.29	-	0.58	649.45	0.58	647.54	0.28	649.10	0.72	670.06	0.36	687.42
Abr 2013	0.26	-	0.78	650.85	0.45	-	0.79	-	0.40	650.82	0.76	-	0.72	-	0.73	672.57	0.69	686.49
Ago 2013	0.39	659.97	0.29	-	0.21	650.78	0.80	653.08	0.20	648.64	0.58	-	0.25	-	0.71	-	0.29	-
Nov 2013	0.16	-	0.77	649.61	0.18	-	0.25	-	0.17	649.09	0.56	646.84	0.21	648.79	0.59	670.08	0.27	683.75
Abr 2014	0.24	-	0.25	649.74	0.24	-	0.63	-	0.33	647.79	0.75	649.44	0.30	640.48	0.18	671.06	0.44	683.27
Nov 2014	0.23	-	0.21	649.04	0.17	-	0.21	-	0.17	648.98	0.70	647.88	0.38	645.51	0.57	667.47	0.30	680.04
Abr 2015	0.55	-	0.35	648.82	0.34	-	0.74	-	0.18	-	0.62	644.94	0.37	646.19	0.18	667.51	0.76	678.37
Nov 2015	0.19	-	0.40	647.12	0.18	-	0.23	-	0.25	645.82	0.50	644.06	0.26	646.69	0.42	666.33	0.74	676.01
Abr 2016	0.31	-	0.73	645.99	0.55	-	0.34	-	0.41	645.89	0.41	643.37	0.69	641.55	0.24	-	0.75	675.13
Nov 2016	0.17	-	0.26	644.70	0.20	-	0.25	-	0.18	642.23	0.60	642.83	0.23	645.51	0.66	-	0.51	671.73
May 2017	0.41	-	0.44	643.88	0.29	-	0.30	-	0.13	642.17	0.51	-	0.31	-	0.32	-	0.83	673.59
Nov 2017	0.17	-	0.45	643.56	0.21	-	0.29	-	0.60	638.77	0.38	646.45	0.38	644.02	0.76	-	0.53	-
Abr 2018	0.24	-	0.27	642.63	0.20	-	0.24	-	0.17	-	0.29	649.71	0.22	641.55	0.21	-	0.82	-

Particularmente, durante el período de noviembre de 2014, el pozo P-170/55 presentó un NDVI de 0.21 con aproximadamente 3 m de abatimiento. El pozo CNA-35-08 en la misma fecha presentó un abatimiento similar con un NDVI promedio de 0.57. El pozo 127-TMI registró un abatimiento de aproximadamente 1 m con un NDVI promedio de 0.3. Los pozos P-44R y P-045A registraron un abatimiento de aproximadamente 9 y 8 m respectivamente con NDVIs promedios de 0.38 y 0.7, respectivamente (Tabla 16). Para el mes de abril de 2018, el mayor abatimiento se registró en el pozo P-170/55, con aproximadamente 9 m y un NDVI promedio de 0.27. De manera similar, el pozo P-44R registró uno de los mayores abatimientos, con aproximadamente 13 m y un NDVI promedio de 0.22.

El comportamiento espacial del NDVI promedio para cada pozo se puede ver claramente en la Figura 27, donde se observa que los valores superiores a 0.5 están asociados con las áreas de mayor cobertura vegetal registradas en los meses de abril (Figs. 27a y 27c). Excepto en abril de 2018, fecha en la cual se presenta la menor cobertura vegetal, esto se relaciona con las bajas precipitaciones registradas durante enero, febrero y marzo de ese mismo año. Asimismo, la vegetación se puede encontrar en los alrededores del VON y, particularmente, con valores entre 0.6 y 0.8 en las zonas de cultivo que están en la zona central de ON y RC (Fig. 27d). Los meses con menor cobertura vegetal se registran entre mayo y noviembre (Fig. 27b), destacando áreas con valores de NDVI por debajo de 0.3. Con la excepción de las zonas de cultivo ubicadas en la parte central de ON y RC, donde, a pesar de la temporada seca, los cultivos mantienen un NDVI promedio entre 0.5 y 0.8 debido a los procesos de riego.

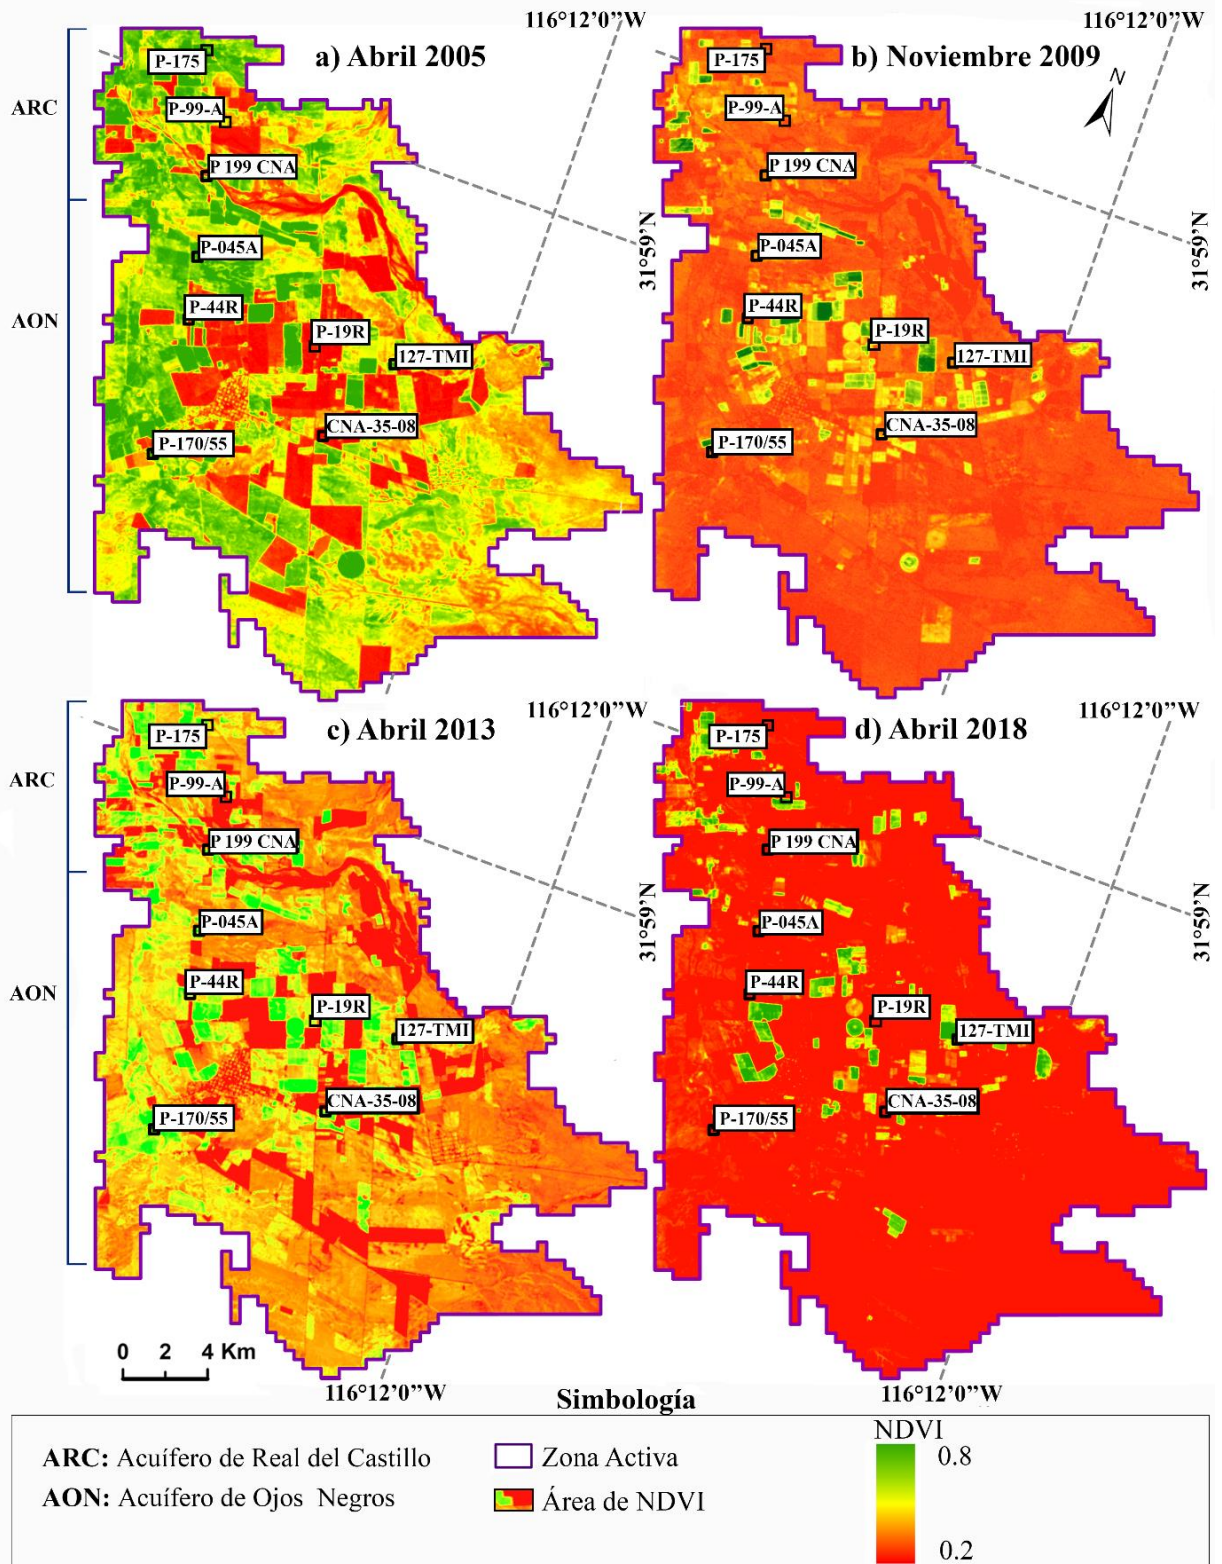


Figura 27. Resultados para el análisis del NDVI en los AVON durante el periodo 2005 - 2018

Las elevaciones de NF presentan una disminución progresiva en los AVON, dicho comportamiento se puede observar en la figura 28. El cual, podría relacionarse con la explotación de los acuíferos para mantener el vigor de los cultivos, especialmente durante las temporadas secas, cuando los valores de NDVI oscilan entre 0.5 y 0.8. Por otro lado, el NDVI presenta variaciones dentro de un rango de 0.2 a 0.8, con una tendencia general de reducción en las áreas verdes, lo que podría estar asociada con una disminución progresiva en los eventos de precipitación (Fig. 3a), agravando los efectos negativos de la explotación de los acuíferos de VON.

Además, se encontró estacionalidad en la mayoría de los pozos con promedios más altos al final de la temporada de lluvias (noviembre - abril) (Tabla 16). El comportamiento estacional de la vegetación es evidente, con la temporada seca produciendo los valores más bajos de NDVI. Sin embargo, durante las estaciones secas se muestran valores de NDVI entre 0.4 y 0.8, principalmente en las áreas de cultivo ubicadas en la parte central de ON y RC. Asimismo, los registros del NF muestran un descenso ya que en la temporada seca los cultivos reciben una contribución del agua subterránea (Fig. 28).

La alta variabilidad de los valores de NDVI refleja la influencia de las lluvias en cada período de análisis (Bhavani et al., 2017). La fluctuación del NDVI y del NF son fenómenos estacionales y cíclicos a lo largo del año, donde un período de crecimiento es seguido por un período de declive (Teramoto et al., 2018). En ambos casos, estas variaciones están controladas por períodos alternantes de lluvias (noviembre a abril) y períodos secos (mayo a octubre).

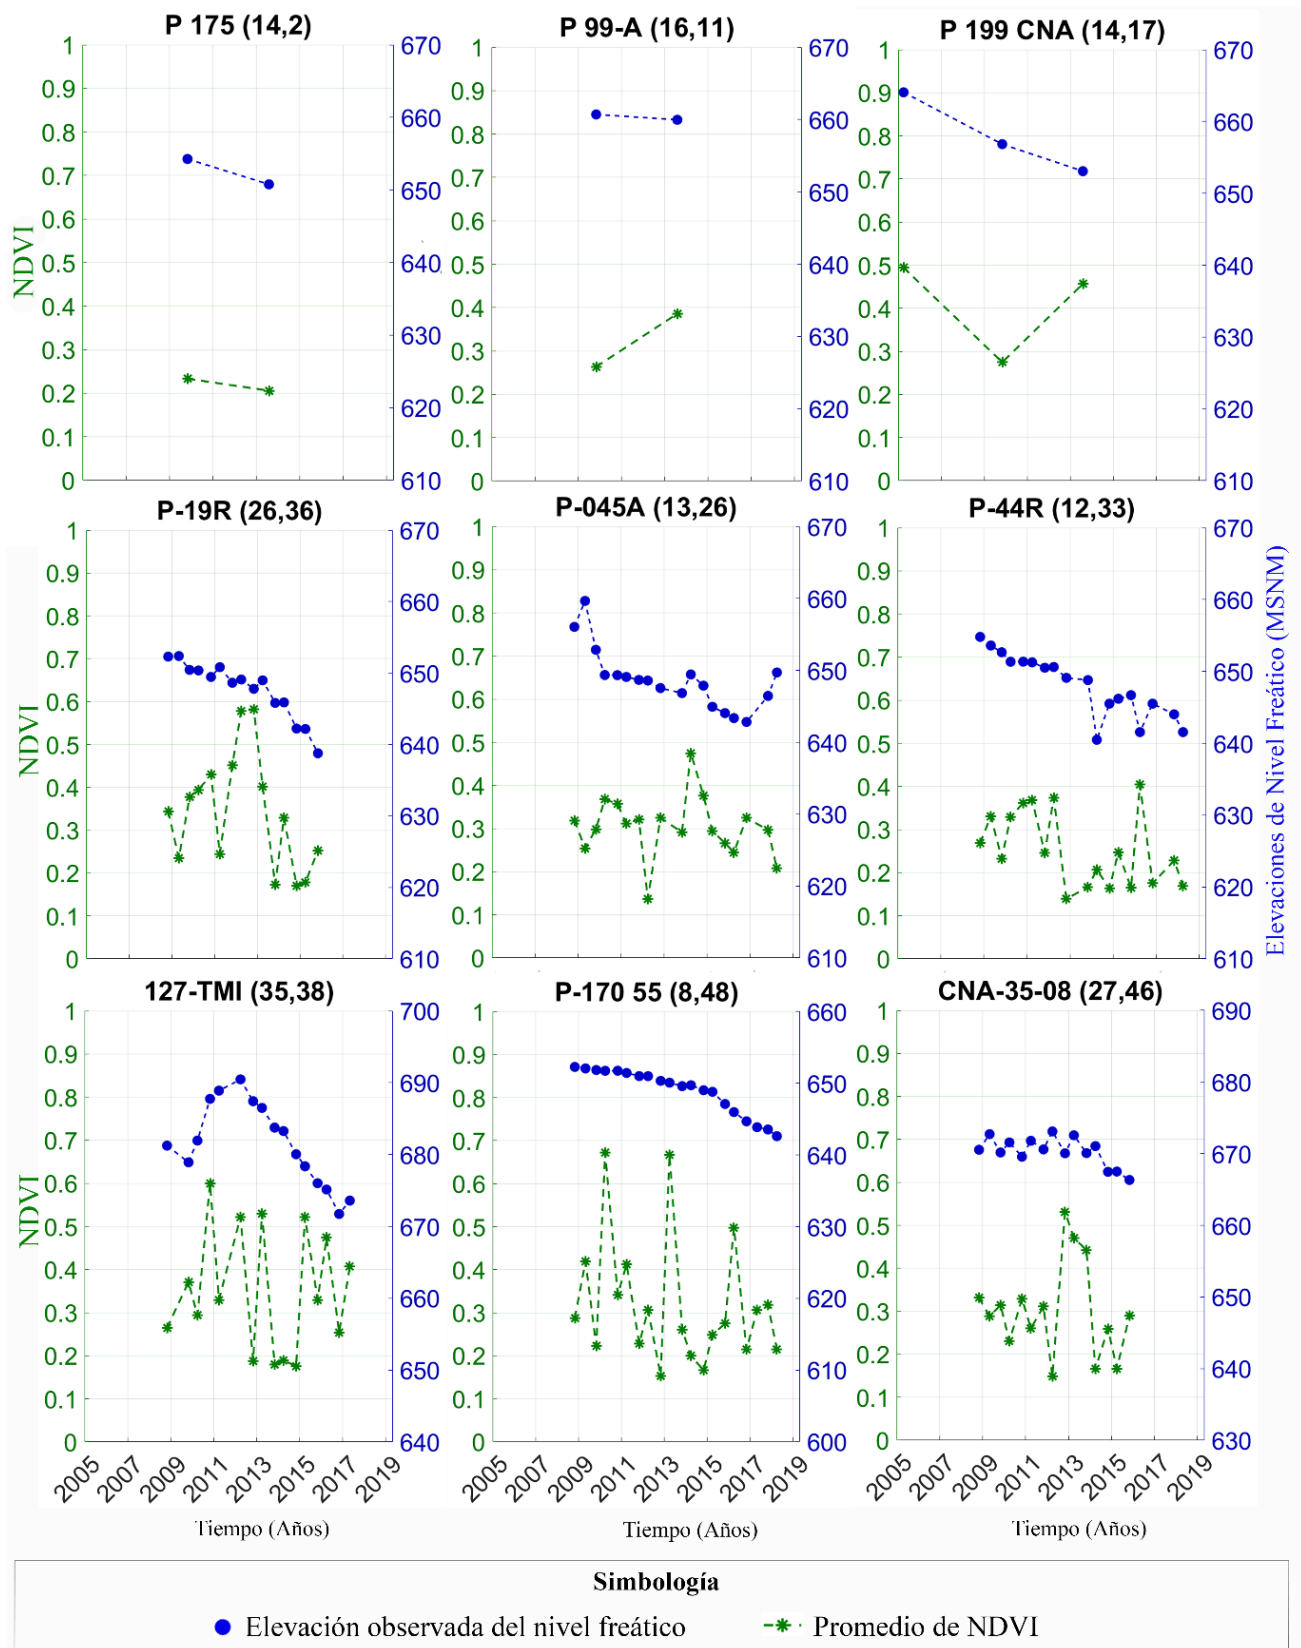


Figura 28. Registro del NDVI promedio y del nivel freático

Los valores de NDVI refleja la respuesta de la vegetación a los cambios en la disponibilidad de agua, dicho comportamiento es evidente puesto que la vegetación es más vigorosa durante las temporadas húmedas y menos durante las temporadas secas.

Las relaciones entre el NDVI de los cultivos y el NF solo se observaron durante años secos cuando la lluvia era escasa y la evapotranspiración alta. El agua subterránea se convirtió en la principal (es posible que la única, inclusive) fuente de agua para los cultivos. Se observa que, durante las estaciones secas, cuando se podría esperar que los cultivos estuvieran más estresados debido a una menor disponibilidad de agua, logran mantener su vigor, gracias al uso de agua subterránea para el riego. Por lo cual, los valores de NDVI podrían manifestar una relación indirecta con la explotación de los acuíferos. Puesto que, esto se refleja en una disminución en el NF, lo que indica una intensificación de la extracción de agua subterránea para sostener los cultivos. Por lo tanto, el NDVI fue un buen indicador de la disponibilidad de agua subterránea en las estaciones secas, ya que el bombeo de agua subterránea se convierte en la principal fuente de agua para los cultivos y sirve de apoyo a las actividades agrícolas.

Durante años húmedos, la absorción de agua por parte de la vegetación y los cultivos fue compensada por eventos de infiltración de lluvia. Del mismo modo el NDVI dependía de la lluvia, dado que, NF se comportaba de manera diferente en años húmedos y secos. Esto demuestra la importancia del agua subterránea como apoyo a la agricultura en períodos de sequía.

La tendencia general en la disminución del vigor de la vegetación a lo largo del tiempo se muestra en la disminución de las áreas verdes en los AVON. Debido a las fluctuaciones naturales en las condiciones climáticas se espera cierta variabilidad anual en los valores de NDVI, no obstante, la tendencia a largo plazo muestra un declive en la vegetación lo que sugiere la posibilidad de estar relacionado con la sobreexplotación del acuífero o con posibles cambios climáticos. Esto podría incluir desertificación, degradación del suelo, los cuales podrían tener consecuencias devastadoras para la biodiversidad y la sostenibilidad (Piao et al., 2005; Wang et al., 2015).

IV.4. Resultados de la Simulación del Modelo de Flujo

La evaluación del rendimiento del modelo de flujo correspondiente al RMSE, de aquellos pozos de observación para los que se disponía de información, se presenta en la Tabla 17. Dicha tabla presenta una síntesis completa de los resultados obtenidos en la aplicación del modelo de flujo, ofreciendo una visión global de su desempeño. A través de la simulación se permitió visualizar la orientación del flujo de agua subterránea y observar la variación de los NF en los AVON a lo largo de intervalos mensuales, durante los años para los cuales se disponía de datos comparativos. Aunque el estado estacionario sólo puede evaluarse en términos de sus características generales, las elevaciones freáticas que muestra un flujo de agua subterránea con dirección predominante de sureste a noroeste, influenciado por barreras impermeables y la forma irregular de los límites de los acuíferos. Sin embargo, los registros históricos de NF y la simulación del modelo presentan diferencias en algunas partes de los AVON, en la parte centro-norte del AON, el modelo subestima la reproducción de los NF. Esto se atribuye a la concentración de pozos de extracción en la zona, lo que provoca una disminución del NF.

Tabla 17. Valores promedios del RMSE. Nota: El símbolo "-" indica que no se dispone de información o datos. La columna de puntos de observación indica el número de pozos considerados con registro del NF

Fecha	RMSE promedio (m)		Puntos de observación	
	ON	RC	ON	RC
Julio 1989	4.98	2.87	19	5
Noviembre 1995	4.42	-	17	-
Febrero 1997	5.15	-	19	-
Febrero 1999	-	2.05	-	5
Abril 2005	-	6.51	-	10
Diciembre 2007	-	5.88	-	23
Noviembre 2008	7.60	-	45	-
Mayo 2009	8.85	-	46	-
Noviembre 2009	8.64	8.72	48	18
Abril 2010	8.86	-	45	-
Noviembre 2010	8.22	-	53	-
Abril 2011	8.83	-	52	-
Noviembre 2011	8.74	-	51	-
Abril 2012	8.94	-	50	-
Noviembre 2012	8.93	-	50	-
Abril 2013	9.30	-	34	-
Agosto 2013	-	7.42	-	39
Noviembre 2013	9.12	-	46	-
Abril 2014	9.76	-	47	-
Noviembre 2014	9.86	-	43	-
Abril 2015	10.95	-	46	-
Noviembre 2015	9.84	-	42	-
Abril 2016	13.55	-	45	-
Noviembre 2016	11.66	-	30	-
Mayo 2017	13.44	-	42	-
Noviembre 2017	13.36	-	31	-
Abril 2018	15.03	-	39	-
Promedio	9.48	5.58	41	17

De manera similar, las fluctuaciones observadas del NF en algunos pozos no se reflejan con precisión en el modelo, como en el caso de CNA-B1/P-020A y 127-TMI. Estudios previos han establecido que existe una variación estacional de la fluctuación de los NF. Por ejemplo, las fluctuaciones temporales pueden presentar ciclos periódicos y estacionales debido a condiciones climatológicas (Yu et al., 2016). El agua infiltrada por precipitación generalmente experimenta dispersión en su camino debido a la heterogeneidad espacial, y al tiempo de llegada al sistema de agua subterránea (Jeong et al., 2018). En respuesta a la precipitación, los NF tienden a aumentar durante la temporada de lluvias, alcanzando su punto máximo aproximadamente entre dos y cuatro meses después del pico de precipitación (Lutz et al., 2015). Apaydin (2009) menciona que, cuando ocurren eventos de lluvia intensa o por encima del promedio en ciertas áreas, puede generar

fluctuaciones rápidas y locales en los NF; las cuales, es posible que no se reflejen adecuadamente en el modelo, ya que, este se basa en datos mensuales y asume una recarga constante o promedio. Los eventos de precipitación intensa pueden introducir una complejidad adicional en la respuesta del acuífero que es difícil de modelar con precisión.

Además, como se mencionó anteriormente, la conductividad hidráulica no es constante en todo el acuífero. En ciertas áreas, puede haber variaciones en la conductividad hidráulica debido a diferencias geológicas y litológicas. Si no se capturan estas variaciones, los NF simulados pueden no coincidir con las observaciones. Es posible que en las áreas de los pozos CNA-B1/P-020A y 127-TMI haya una mayor complejidad en términos de conductividades hidráulicas, la cual, no se ha logrado representar completamente en el modelo. Esta complejidad puede influir en la respuesta del acuífero a la recarga por precipitación.

Asimismo, también se observa un desajuste vertical entre los NF calculados y observados en pozos tales como: P-19R y P-169/ON-3. Cuyo desajuste vertical podría ser provocado debido a que tales pozos se utilizan tanto para fines riego como para consumo doméstico, es decir, una actividad humana con efectos locales que el modelo no tiene en cuenta.

Con base en los resultados, se puede describir el siguiente comportamiento entre los NF calculados y observados en los AVON. Existe una sobreestimación de 9 m hasta una subestimación de 19 m en el AON, mientras que, para el ARC, esta fluctuación va desde una sobreestimación de 14 m hasta una subestimación de 10 m (Tabla 17). La subestimación en ambos acuíferos podría explicarse por la falta de una recarga adecuada considerada en la simulación, y es posible que las mediciones del NF no reflejen completamente las condiciones de bombeo existentes, puesto que el bombeo se basó en los registros de los estudios previos, los cuales pueden no reflejar correctamente la sobreexplotación en los AVON.

Aun así, los resultados demuestran la capacidad del modelo para reproducir los NF durante un período de 35 años, evaluada numéricamente mediante la relación del RMSE y cuyos valores promedio son de 9.48 m para el AON y 5.58 m para ARC (Tabla 17 y Fig. 26), estos se encuentran dentro de un rango aceptable para estudios hidrogeológicos desarrollados en diversos escenarios ambientales (Freyberg, 1988; Kresic, 1997; Marsily, 1986).

Por último, con base en los resultados del modelo, el cual cuenta con un período de simulación de 35 años (1983–2018), una refinación del tamaño de las celdas espaciales a 250 m x 250 m, así como con una calibración realizada utilizando los registros de hasta 58 pozos en promedio (41 de

ellos en el AON y el resto en el ARC), se considera y respalda la suposición de que el modelo hidrogeológico propuesto se encuentra calibrado.

IV.5. Resultados del Modelo Sintético con Aplicación de la RNA

En la Figura 29 se muestran los resultados del entrenamiento obtenidos por la RNA para el caso de estudio sintético descrito en la sección III.6. Los resultados durante el proceso de entrenamiento, el modelo neuronal mostró un buen desempeño al lidiar con la variabilidad de los datos diarios, presentando un error del 2.3% con un total de 50 épocas (Fig. 30).




Figura 29. Resultados del entrenamiento para el caso de estudio sintético

Durante la validación, se utilizaron los 12 días siguientes a la modelación del entrenamiento (Fig. 30). En general, el modelo mostró un buen entendimiento, excepto en los casos de los pozos 2 y 5 Ext. Es probable que, aumentando la cantidad de datos durante el entrenamiento, se pueda disminuir este comportamiento no deseado. Dichos resultados demostraron la aplicabilidad del modelo a zonas con variaciones en su configuración y su adaptación a diferentes periodicidades.

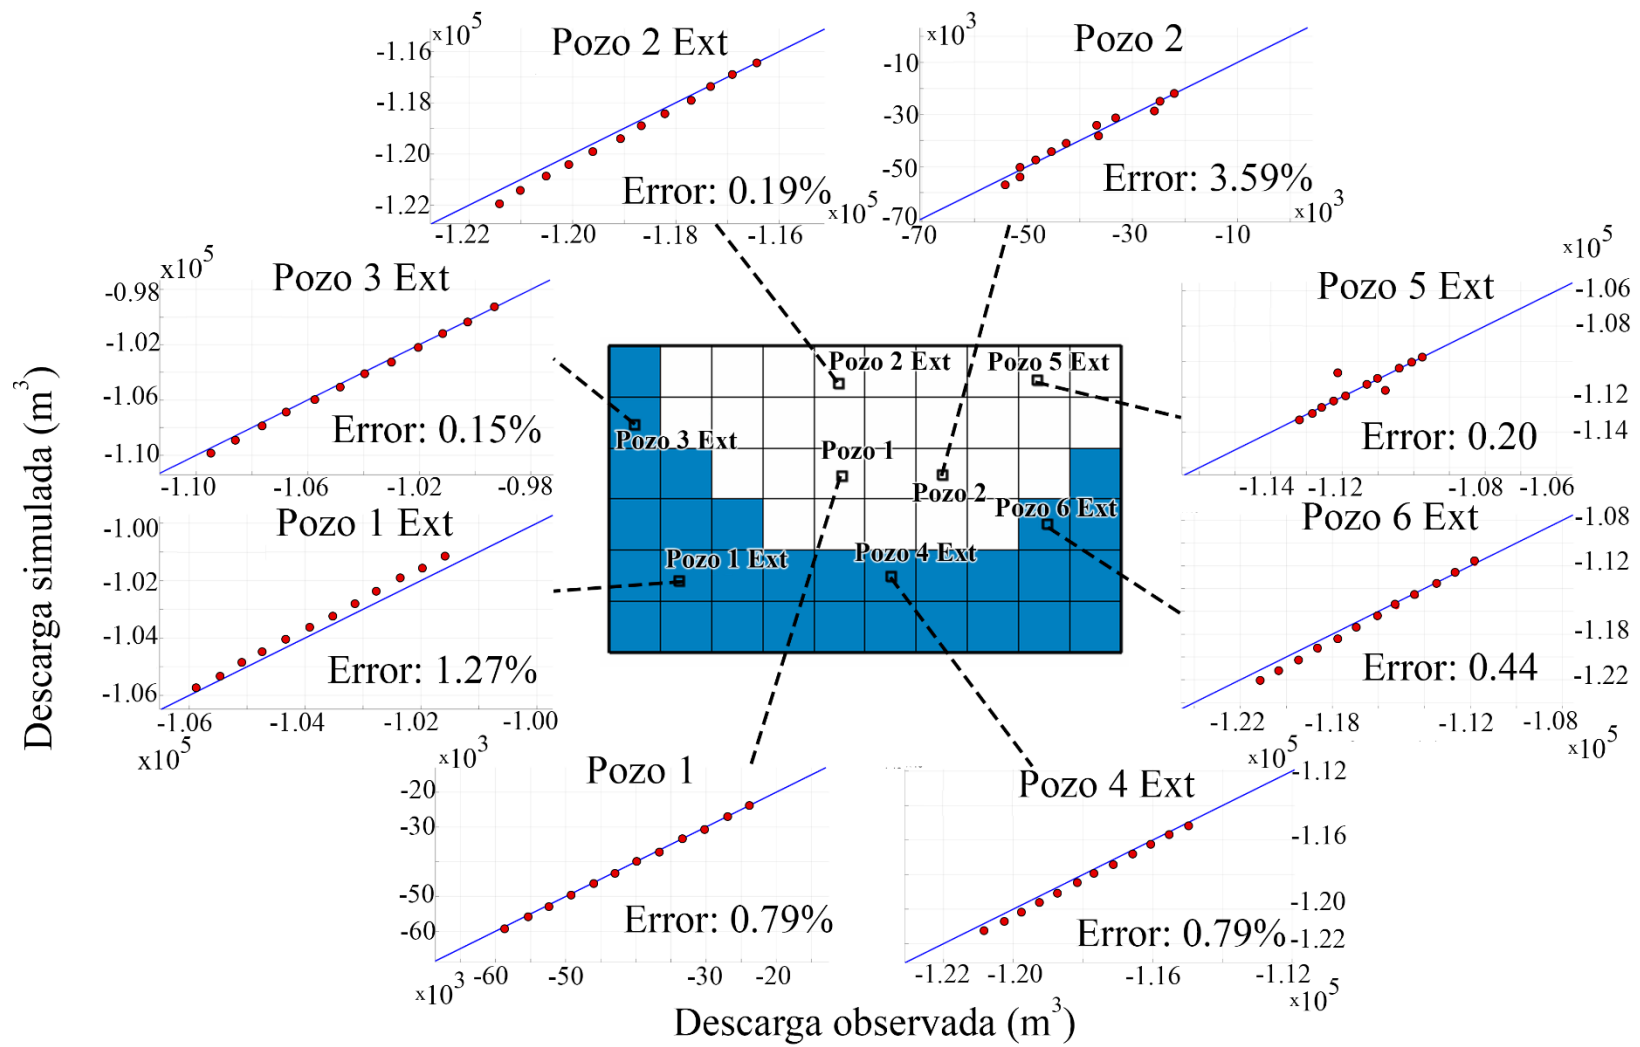


Figura 30. Resultados de validación para caso de estudio sintético

IV.6 Resultados del modelo de flujo con la aplicación de RNA

Para el desarrollo de esta sección se ha requerido llevar a cabo la implementación práctica del modelo neuronal utilizando el software MATLAB. Los resultados de la RNA se basaron en la aplicación del modelo de flujo previamente descrito y calibrado. Los valores de descarga se ingresaron mensualmente dentro de los intervalos establecidos por el modelo de flujo como períodos de extracción. Es decir, si se tiene un registro del NF para noviembre de un determinado año, el modelo neuronal recibirá la información correspondiente a ese mes (de forma similar, el registro de precipitación, etc.). Posteriormente, la descarga estimada por la RNA se ingresará de forma mensual y durante el período completo de funcionamiento de los pozos (es decir, de mayo a octubre).

Durante el proceso de entrenamiento, se optó por emplear la función de activación RELU en las dos primeras capas ocultas, mientras que en la capa de salida se utilizó la función de activación lineal. Además, se estableció una tasa de aprendizaje constante de $\eta = 0.01$. Los parámetros de entrada consisten en: x_1 = Precipitación, x_2 = Registro del NF, x_3 = Conductividad hidráulica, x_4 = Topografía superficial, x_5 = Basamento impermeable y x_6 = Evapotranspiración. Cuya elección de parámetros se fundamentó en la necesidad de adaptar el proceso de entrenamiento a la complejidad de los datos y a las particularidades del problema abordado en esta investigación.

IV.6.1. Resultados del modelo de RNA: julio de 1989

Después de entrenar la RNA, se determinaron las descargas para cada pozo. Es importante señalar que el modelo neuronal se evaluó bajo condiciones transitorias, ya que, durante este período de modelación, los pozos operan durante los meses de mayo a octubre, es decir, durante seis meses. El objetivo principal es calcular la cantidad de la GWW que ocurre en los AVON.

Por lo tanto, la primera fecha de modelación corresponde a julio de 1989, se acumulan 79 meses de operación con observaciones para ambos acuíferos, RC y ON. Esta fecha se cataloga como caso 1, en la que la ubicación de los puntos de observación coincide con la ubicación de los puntos de descarga. Se identificaron 5 pozos para el ARC y 21 para el ON (Fig. 31).

La distribución en la descarga en el caso de RC, se observa una única distribución con valores de descarga comprendidos entre -100,000 y -250,000 m³/mes. Por otro lado, en el caso de ON, se

ajustó su entrenamiento para reproducir dos distribuciones de descarga distintas: una que abarca desde 0 hasta -100,000, y otra desde -100,000 hasta -250,000 m³/mes.

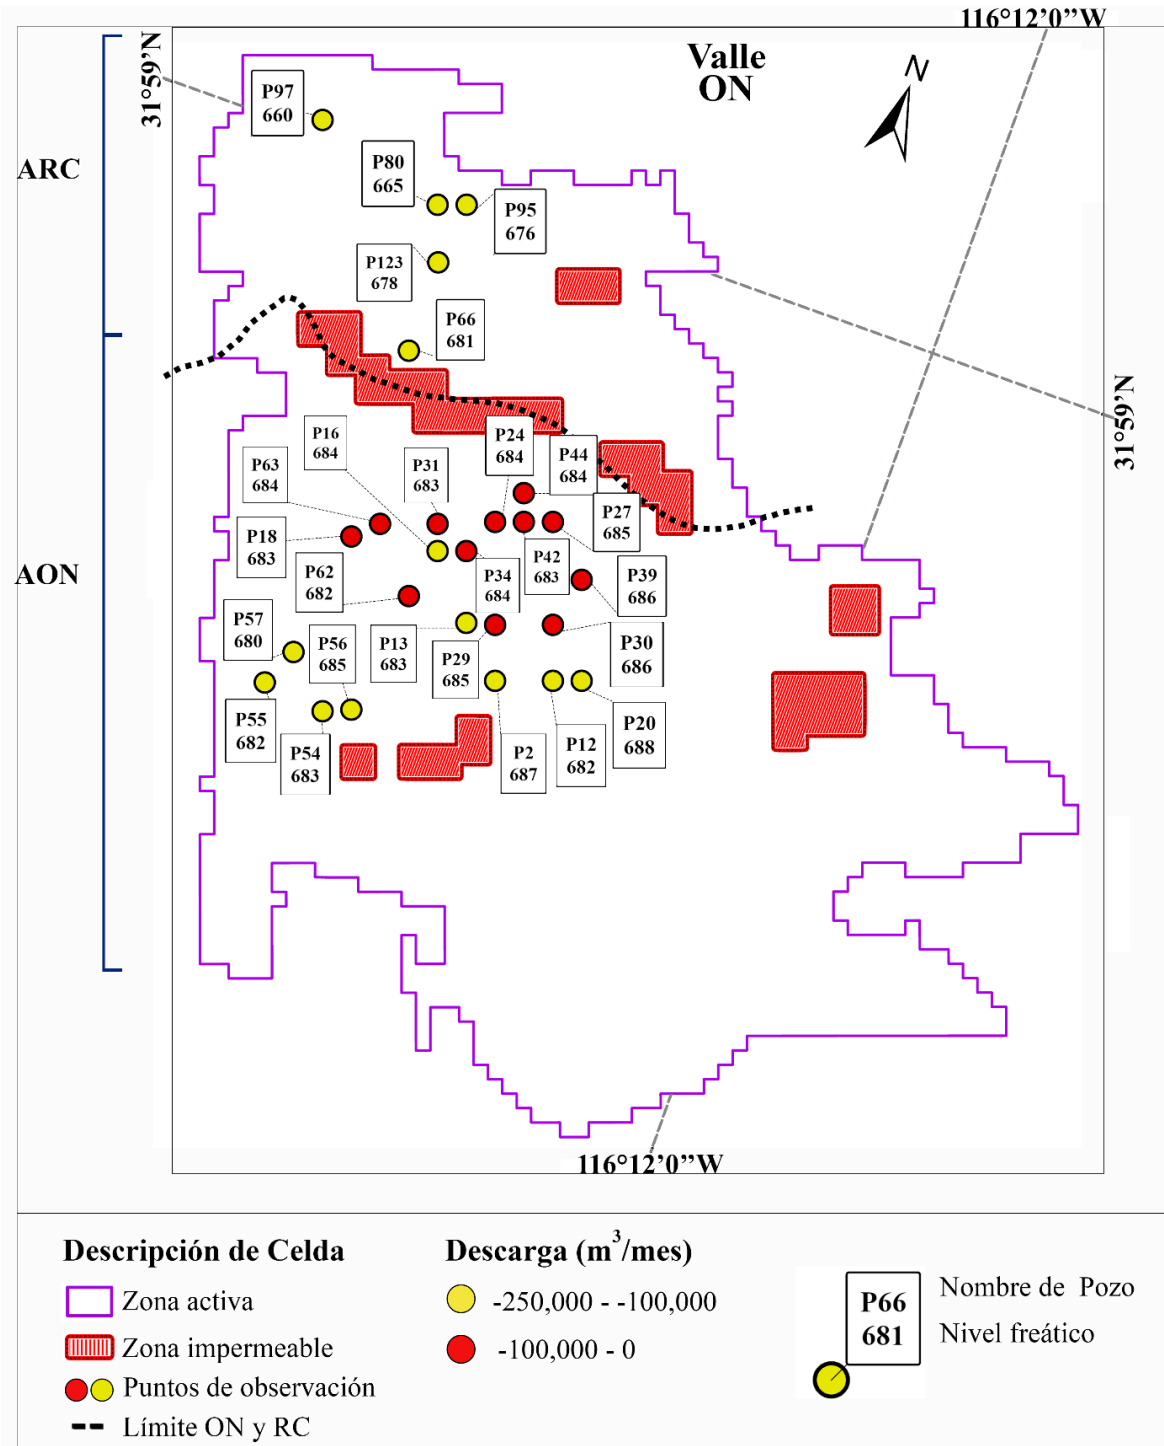


Figura 31. Puntos de observación y pozos de descarga para julio de 1989

Los resultados del entrenamiento se muestran en la Tabla 18, puede observar que se registran más épocas de entrenamiento cuando hay una mayor cantidad de datos disponibles, como en el caso de ON con el segmento de 804 datos (RNA 2). Esto podría deberse a que la RNA recibe una mayor cantidad de información proveniente de 12 puntos de descarga, lo que resulta en un aumento en el número de épocas necesarias. Dado que, la RNA podría lidiar con una mayor variabilidad en los patrones de los datos. Lo que deriva en una mayor cantidad de épocas. Por el contrario, se requiere de menos épocas cuando la RNA se enfrenta a menor variabilidad, lo que facilita que el modelo aprenda y se ajuste los patrones de manera más rápida y eficiente (RNA 1 y 3). También, se observa que los errores de validación son menores que los errores de entrenamiento, lo que podría evitar el sobre-entrenamiento del modelo neuronal (overfitting en inglés) (Tabla 18).

Tabla 18. Resultados del entrenamiento de la RNA. *Nota: Las RNA 1 y 3 indican el segmento de datos -100,000 a -250,000 m³/mes, y la RNA 2 valores de 0 a -100,000 m³/mes*

Acuífero	RNA	Puntos de descarga	Meses de Operación	Datos de Entrenamiento	Datos de Validación	Épocas	Error	
							Entrenamiento (%)	Validación (%)
ON	1	9	79	603	108	88	2.05	1.03
	2	12	79	804	144	102	2.41	0.89
RC	3	5	79	335	60	55	1.97	0.61
Total				1742	312			

Los resultados del proceso de entrenamiento se presentan en la Figura 32, donde se muestra el desempeño de la RNA en la predicción de los valores de descarga acumulada para cada año (por fines prácticos y para simplificar se presenta la descarga acumulada anual, aunque el entrenamiento es mensual). En el lado izquierdo de la figura (es decir, de la línea vertical, discontinua y verde) se observa la fase de entrenamiento, que concluye en 1988, mientras que en el lado derecho se muestra la etapa de validación del modelo. Se observa que, en los tres conjuntos de datos, la precisión en la fase de validación es mayor que en la fase de entrenamiento, lo cual indica que el modelo tiene una buena capacidad de generalización y captura los patrones en los datos. En general, la RNA presenta un desempeño satisfactorio con ambas distribuciones de descarga.

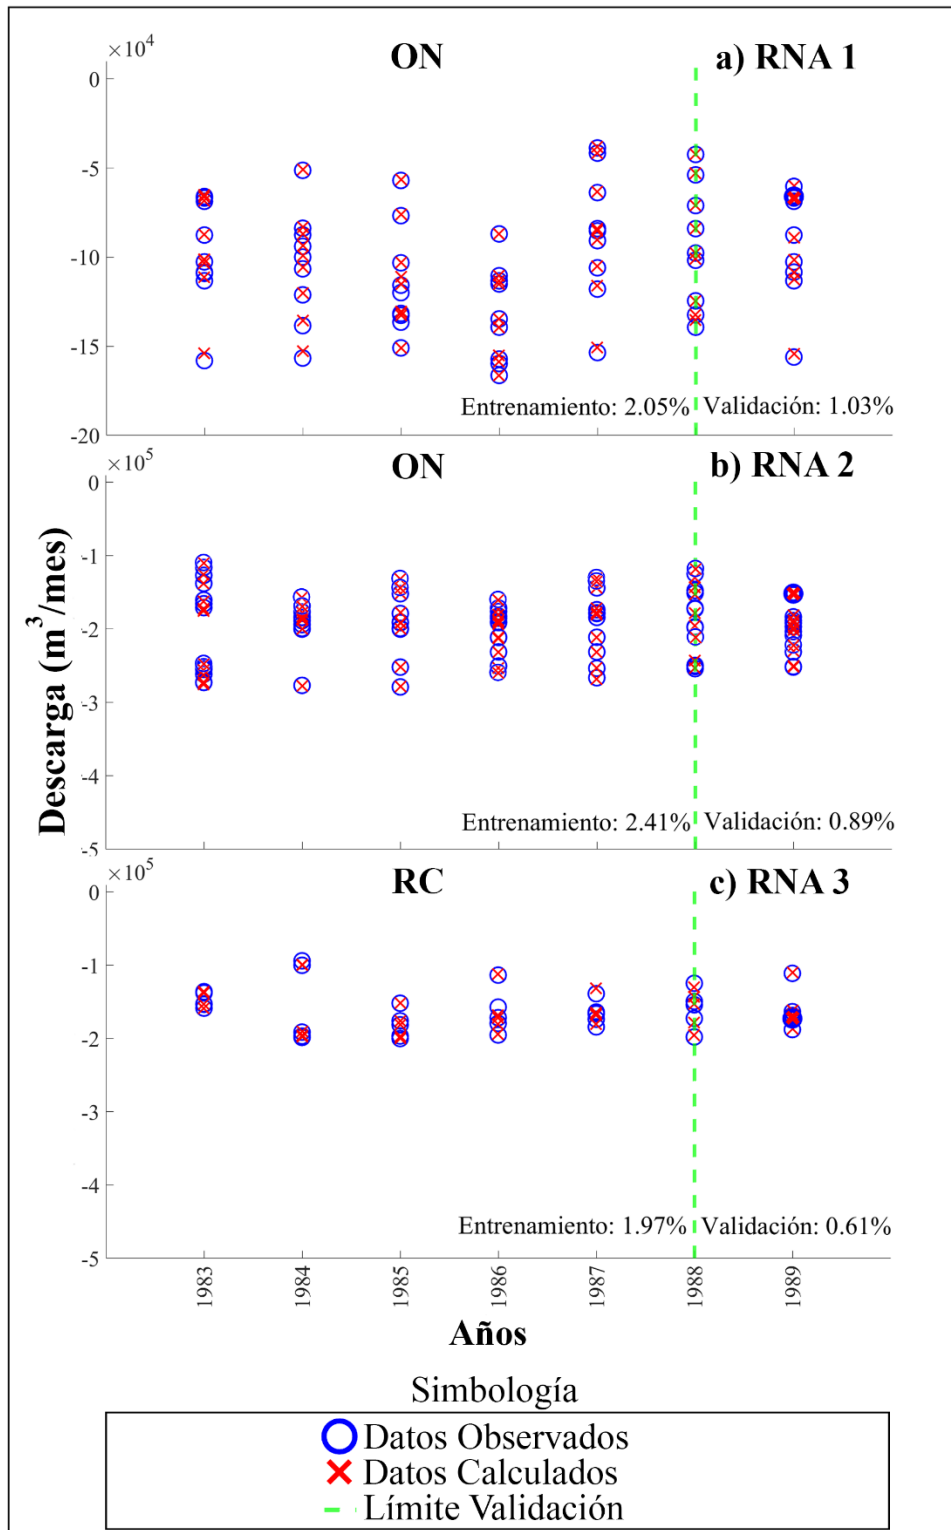


Figura 32. Resultados del entrenamiento del modelo neuronal para julio 1989. Entrenamiento y validación de la RNA: a) Para 9 pozos del AON. Rango de descarga considerado: -100,000 y -250,000 m^3/mes . b) Para 12 pozos del AON. Rango de descarga considerado: 0 hasta -100,000 m^3/mes . c) Para 5 pozos del ARC. Rango de descarga considerado: -100,000 hasta -250,000 m^3/mes

IV.6.1.1 Estimación de la descarga mediante RNA

Una vez que ha quedado validado el modelo de RNA, se procede a determinar los valores de descarga mensual para julio de 1989 (en el Apéndice D se muestra un ejemplo de cómo se ingresa la información a la RNA). Los resultados obtenidos a través del análisis de la RNA revelaron un incremento en las descargas estimadas con respecto a las reportadas previamente; en general, un aumento promedio del 80% (Tabla 19). Donde puede observarse que las diferencias positivas indican una disminución en el valor reportado; mientras que, las diferencias negativas indican un aumento en el valor reportado.

Los resultados indican que las descargas estimadas son mayores en las zonas del acuífero donde los abatimientos del NF son más intensos, y menores en aquellas donde los abatimientos son menos pronunciados. El mayor incremento se observa en los pozos P-31 y P-18 en el AON, con un aumento del 374 y 569%, respectivamente. Este aumento podría estar influenciado por la alta densidad de cultivos en esa área, ya que, es una región altamente explotada en términos agrícolas. Además, es probable que los valores originalmente reportados (-22,519 y -57,817 m³/mes) no refleje completamente la verdadera magnitud de la descarga, lo que sugiere una posible subestimación en los datos reportados originalmente.

En el ARC, se presenta una situación similar con el pozo P-95, con un aumento del 58%. Este pozo está ubicado en una zona de cultivos. Sin embargo, este aumento podría estar relacionado con una subestimación en el valor reportado inicialmente de -113,768 m³/mes, lo que no refleja adecuadamente la situación de explotación en el ARC. Además, se registra un aumento en los pozos P-20, P-24, P-27, P-29, P-31 y P-42, que oscila entre el 63% y el 230%. Una posible explicación podría estar relacionada con el crecimiento continuo de la demanda de agua en la región debido a la expansión de la agricultura u otros usos, doméstico y pecuario.

Tabla 19. Valores de descargas estimados por la RNA vs descargas previamente reportadas

Pozo	Columna	Renglón	Descargas previamente reportadas (en m ³ /mes)	Descargas obtenidas por la RNA (en m ³ /mes)	Diferencia entre Descargas Reportadas vs RNA (en %)
P-2	22	44	-250,396	-149,401	40
P-12	26	44	-177,068	-363,818	-105
P-13	20	40	-219,925	-111,336	49
P-16	18	35	-193,313	-115,904	40
P-18	12	34	-57,817	-386,805	-569
P-20	28	44	-187,068	-553,544	-196
P-24	22	33	-80,681	-144,372	-79
P-27	26	33	-56,022	-181,633	-224
P-29	22	40	-77,799	-126,994	-63
P-30	26	40	-82,524	-90,936	-10
P-31	18	33	-22,519	-106,787	-374
P-34	20	35	-83,623	-105,747	-26
P-39	28	37	-75,327	-305,369	-305
P-42	24	33	-78,427	-130,336	-66
P-44	24	31	-105,125	-125,746	-20
P-54	10	46	-263,948	-298,997	-13
P-55	6	44	-228,025	-331,591	-45
P-56	12	46	-248,400	-155,695	37
P-57	8	42	-122,137	-303,293	-148
P-62	16	38	-113,768	-116,173	-2
P-63	14	33	-88,176	-89,056	-1
P-66	16	21	-152,428	-142,060	7
P-80	18	11	-161,846	-117,808	27
P-95	17	11	-113,768	-180,111	-58
P-97	10	8	-132,823	-105,125	21
P-123	18	15	-248,529	-223,173	10
Promedio			-139,288	-194,685	-80

Asimismo, en el ARC se registró una disminución en la descarga que osciló entre 7 y 27 % en los pozos P-66, P-80, P-97 y P-123, dicha disminución plantea una redistribución de los valores de descarga; puesto que, la descarga muestra un aumento de 22.46% anuales (Tabla 20). Si bien, este aumento podría relacionarse con la densidad y tipos de cultivos en la zona, es importante considerar el incremento de las siembras en las zonas agrícolas, particularmente en la temporada de riego, cambios en los cultivos o cambios en los patrones de riego. Además, de la posibilidad de la existencia de pozos clandestinos o actividades de extracción no autorizadas. Adicionalmente, la ausencia de registro tanto mediante métodos directos e indirectos de estas extracciones podría

explicar el aumento observado en la descarga, puesto que, los registros oficiales pueden estar sujetos a limitaciones técnicas o de muestreo que afectan su precisión y representatividad. Estas limitaciones pueden llevar a una subestimación de la descarga de agua subterránea.

Tabla 20. Resultados de la descarga estimada por la RNA en 1989

Descarga 1989 (m³/año)		
Descarga Reportada	Descarga estimada por la RNA	Diferencia entre RNA vs Reportado (%)
-30,116,888	-36,881,895	-22.46%

También, el aumento en la descarga se refleja en una notable mejora en el ajuste entre los NF simulados por el modelo y los valores reportados (Fig. 33). Las nuevas estimaciones de la descarga ofrecen una representación más precisa de la explotación en los AVON. A diferencia de los volúmenes de descarga reportados, que son estimaciones, nuestros resultados refinan estas estimaciones, alineándolas mejor con la dinámica real del acuífero. Este ajuste mejorado no solo reduce el error de ajuste, además, muestra el comportamiento del NF a lo largo del período de estudio.




Figura 33. Ajustes del NF para julio de 1989. a) Modelado del flujo de agua subterránea sin considerar las descargas estimadas mediante las RNA, y b) Modelado del flujo de agua subterránea considerando las descargas estimadas mediante las RNA

Para el área de ON, las mejoras implementadas en el modelado numérico, (es decir, considerar las descargas estimadas mediante las RNA), se ven reflejadas con un 59% de mayor ajuste vertical entre los registros del NF calculados y los observados, esto, en contraste con aquellos NF obtenidos mediante el modelo de flujo sin considerar las descargas estimadas mediante las RNA. Adicionalmente, se observa una mejora en el ajuste vertical del 26% con respecto a los resultados reportados por Campos-Gaytán (2002) (Tabla 21). En el caso del área de RC, se evidencia una mejora del 37% en relación con los registros de NF obtenidos con el modelo de flujo, así como una mejora del 60% en comparación con los resultados reportados por Campos-Gaytán (2002) (Tabla 21). Para esta simulación fue posible comparar los registros de los modelos reportados, lo cual, se mantuvo hasta que los registros recopilados lo permitieron (febrero de 1999). Posteriormente, se compararon únicamente contra los resultados del modelo de flujo desarrollado en este trabajo.

Tabla 21. Comparación de los errores de ajuste vertical entre los NF observados contra los calculados con el modelo de Campos-Gaytán (2002), el modelo MODFLOW desarrollado en este trabajo, así como con el modelo MODFLOW desarrollado en este trabajo considerando la descarga estimada mediante la RNA

Acuífero	RMSE (m) en el MODELO:			Porcentaje de mejora (%)	
	<i>Campos- Gaytán (2002)</i>	<i>Modelo MODFLOW</i>	<i>Modelo MODFLOW considerando la descarga estimada mediante la RNA</i>	<i>Modelo MODFLOW considerando la descarga estimada mediante la RNA vs Modelo MODFLOW</i>	<i>Modelo MODFLOW considerando la descarga estimada mediante la RNA vs Campos- Gaytán (2002)</i>
ON	2.74	4.98	2.03	59.24	25.91
RC	4.56	2.87	1.81	36.93	60.31

Por otro lado, la distribución piezométrica obtenida del Modelo MODFLOW considerando la descarga estimada mediante la RNA se muestra en la Figura 34a. Donde se observa que en el AON los NF en julio de 1989 oscilan entre aproximadamente 685 y más de 740 msnm; en contraste, los NF en el ARC variaron de 655 a 690 msnm (Fig. 35a). Los errores residuales muestran que el modelo tiene un buen ajuste en relación con los registros de NF. Las zonas en color azul indican el modelo calcula elevaciones menores que las reales, es decir, una subestimación de los NF por parte del modelo, mientras que las zonas en color rojo reflejan una sobrestimación, con elevaciones calculadas mayores que las reales. Los ajustes generales oscilan entre -4 m y 1 m (Fig. 34b). En términos generales, los errores del modelo son aceptables y menores comparados con los modelos de flujos previos presentados en la Tabla 21. No obstante, persisten algunos errores, especialmente en la parte central de ON y RC, donde los errores varían de -3 a -4 m.

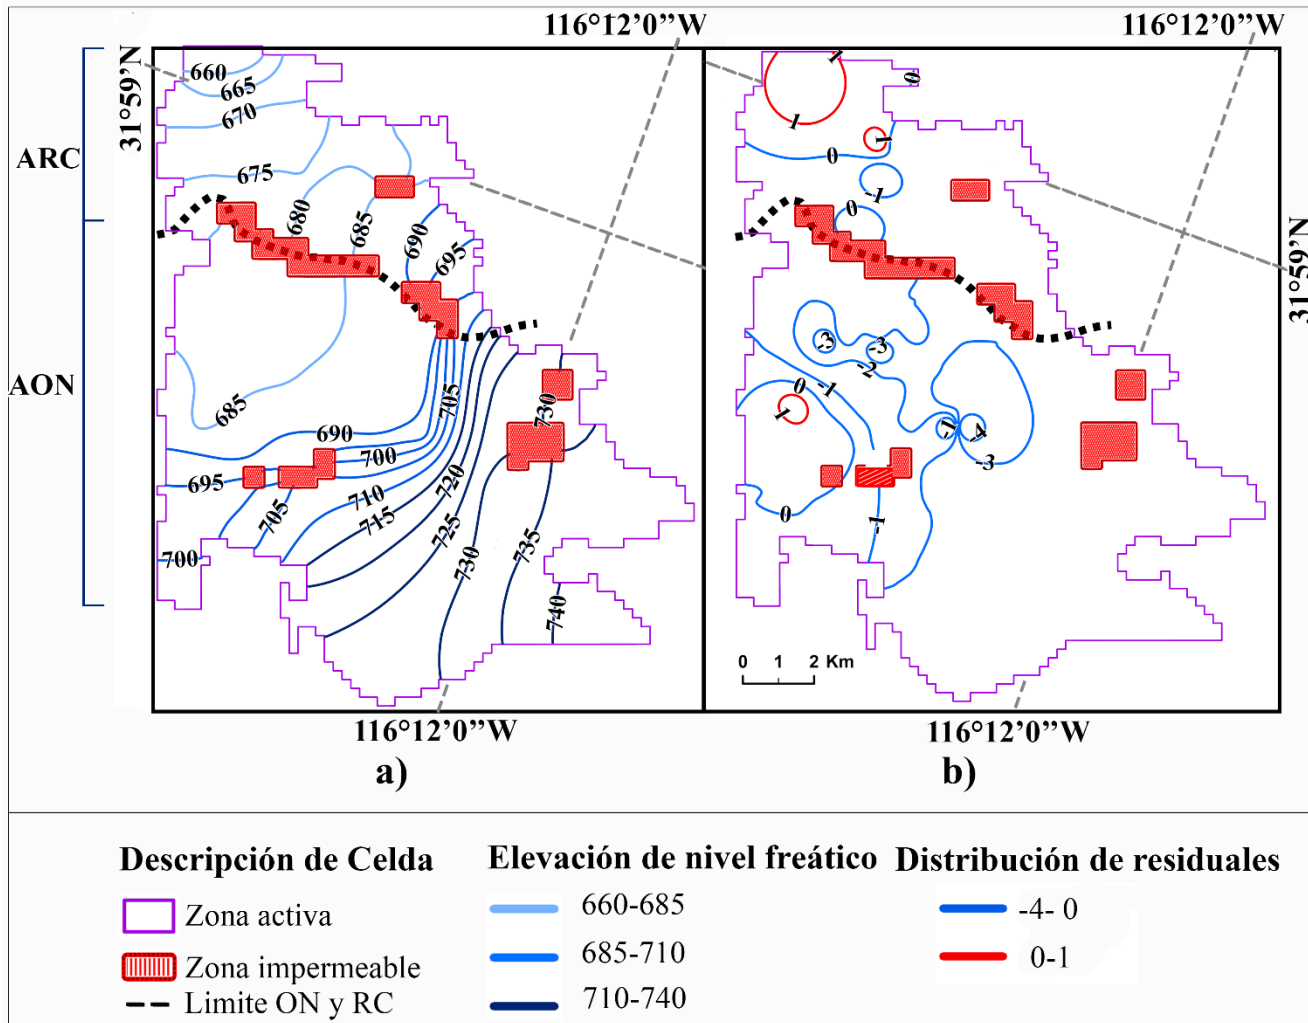


Figura 34. Registro del nivel freático (a) y mapa de residuales para julio de 1989 (b)

IV.6.2 Resultados del modelo de RNA para agosto de 2013

Continuando con el análisis de los resultados del modelo de RNA, la siguiente fecha de modelación es agosto de 2013. Esta fecha representa el punto más reciente con registro disponible del NF para el ARC que ha sido utilizada en este trabajo. Durante la simulación numérica, partiendo de la fecha establecida como condición estacionaria se consideran en el análisis hasta 368 meses de operación, comparando los NF calculados contra los observados en el ARC únicamente (Fig. 35). Esta fecha se cataloga como caso 2; debido a que, a partir de esta fecha, los puntos de observación no coinciden con los puntos de descarga. Por consiguiente, se ha desarrollado y aplicado el siguiente procedimiento de estudio: Se identificaron los pozos con registro del NF más cercanos a cada punto de observación y se realizó una interpolación (mediante Kriging). A cada punto de observación se le asignó una elevación del NF generada mediante interpolación, utilizando como base para ello, los 39 registros disponibles del NF (los registros utilizados para dicha interpolación se encuentran en el Apéndice C de este trabajo).

El modelo de RNA se entrenó con un total de 23 pozos de descarga; cuya distribución de la descarga se divide en dos segmentos de datos: de 0 a -100,000 m³/mes y de -100,000 a -200,000 m³/mes (Fig. 35)

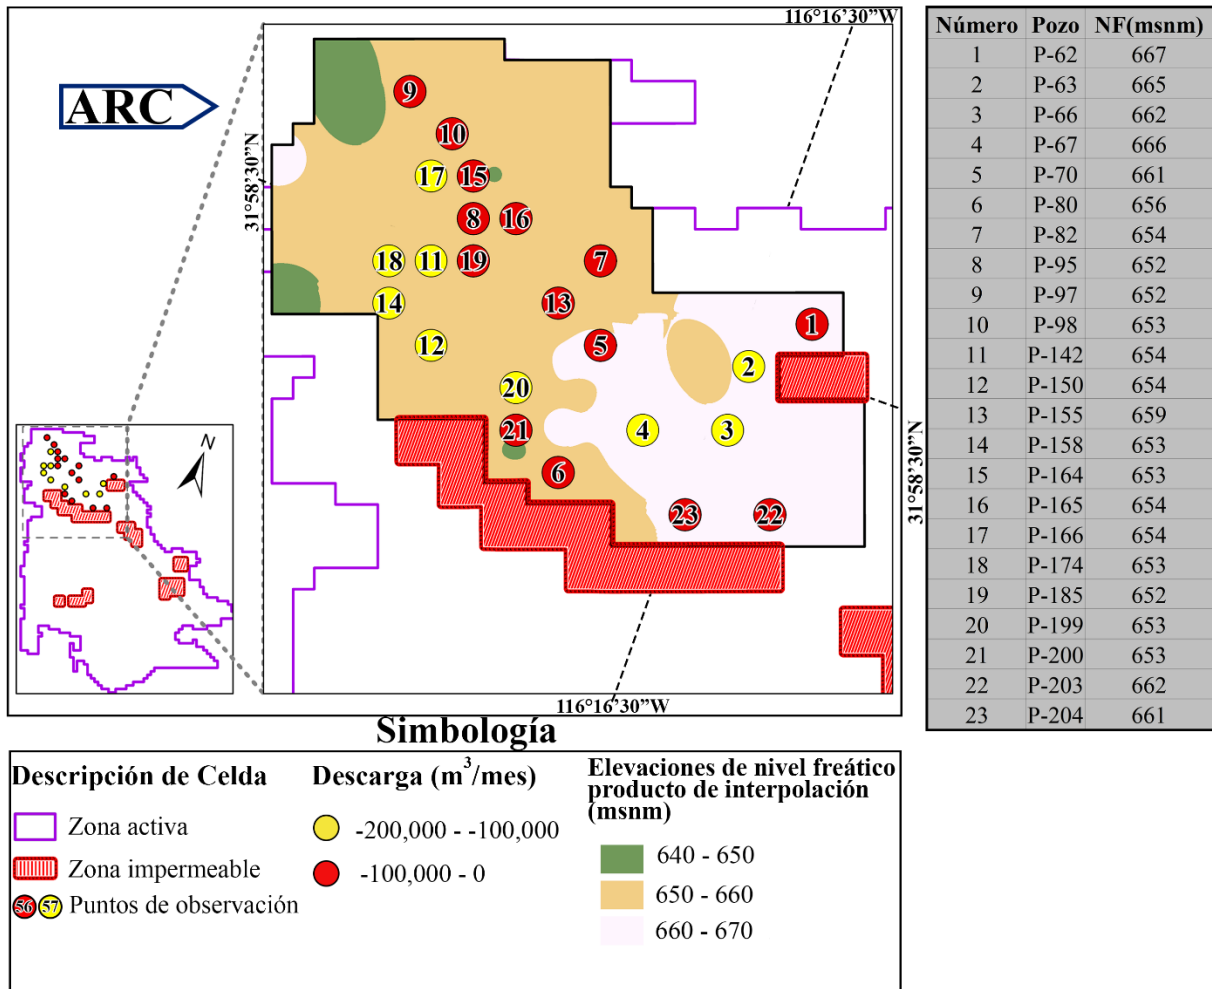


Figura 35. Puntos de descarga y registro del NF utilizados en el entrenamiento de la RNA para agosto 2013 en el ARC

Los resultados del entrenamiento de la RNA se muestran en la Tabla 22, se puede observar una posible correlación entre la cantidad de datos disponibles y la complejidad en la distribución de los datos. Como se observó en la fecha de modelación anterior, se evidencia que a medida que aumenta la cantidad de datos utilizados para el entrenamiento, también aumenta el número de épocas requeridas para lograr la convergencia del modelo, este comportamiento se presenta en la RNA 1 de la Tabla 22. Este podría sugerir que una mayor cantidad de información beneficia a la RNA lo que conlleva a una mayor complejidad en su proceso de aprendizaje.

Por otro lado, a pesar de que los segmentos de descarga con solo 9 puntos (RNA 2) tuvieron menos épocas de entrenamiento (un total de 103), los resultados muestran un ajuste de 4.10%

y 2.73% durante la etapa de entrenamiento y validación, respectivamente. Lo que refleja que la RNA logró adaptarse a diferentes distribuciones de descarga incluso cuando los valores de entrenamiento variaron entre -100,000 y -200,000 m³/mes.

Tabla 22. Resultados del entrenamiento de la RNA. *Nota: La RNA 1 indica el segmento de datos 0 a -100,000 m³/mes, la RNA 2 indica de -100,000 a -250,000 m³/mes, ambos segmentos para RC*

Acuífero	RNA	Puntos de descarga	Meses de Operación	Datos de Entrenamiento	Datos de Validación	Épocas	Error	
							Entrenamiento (%)	Validación (%)
RC	1	14	368	4648	504	177	5.81	3.23
	2	9	368	2997	324	103	4.10	2.73
			Total	7645	828			

Además, nuevamente, se observa que los valores de validación (Registros del año 2011 al 2013 en la Fig. 36) presentan un porcentaje de error menor en comparación con los valores del entrenamiento (Tabla 22 y la Figura 36). Este comportamiento sugiere que el modelo no está sobreentrenado.

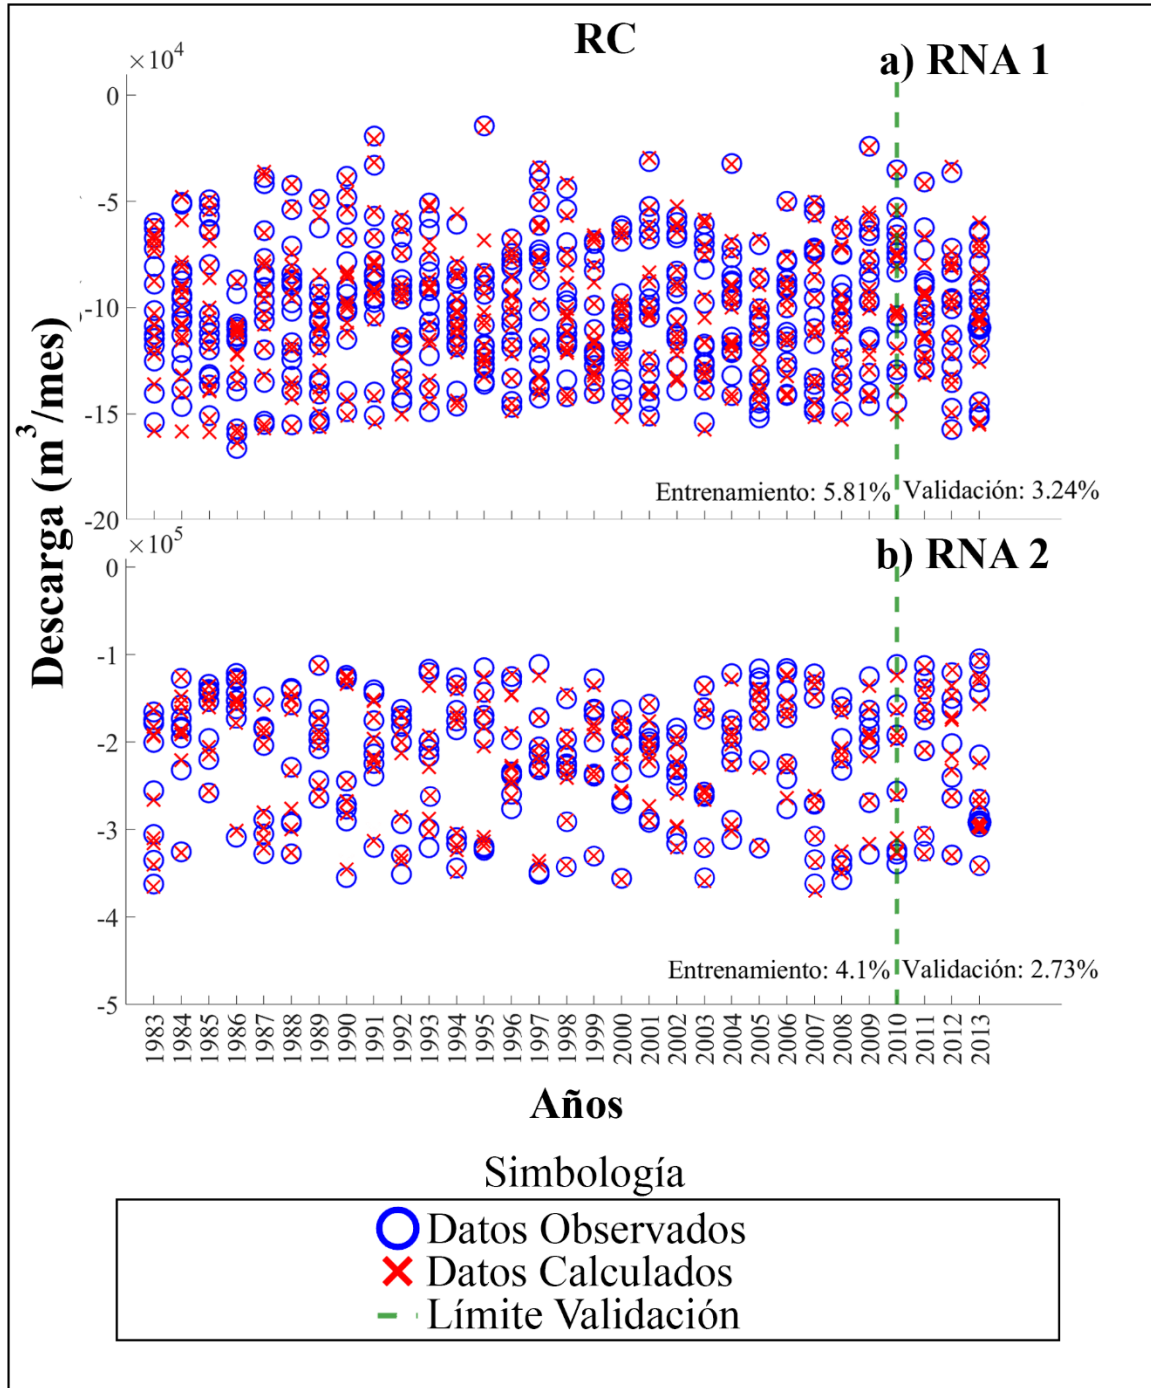


Figura 36. Resultados del entrenamiento y validación para agosto 2013 en el ARC, únicamente: a) RNA para 14 pozos. b) RNA para 9 pozos

IV.6.2.1 Estimación de la descarga mediante la RNA para agosto de 2013

Entrenado el modelo de RNA se procede a determinar los valores de la descarga mensual. Por lo tanto, se ingresa la información correspondiente a agosto de 2013 (un ejemplo de la estructura que dicha información debe contener para su ingreso a la RNA se encuentra en el Apéndice D). Los resultados obtenidos a través del análisis de la RNA mostraron una disminución en la descarga con un promedio de 8.5% con respecto a los registros previos (Tabla 23). Cuyas diferencias positivas indican una disminución en el valor reportado, mientras que las diferencias negativas indican un aumento en el valor reportado.

Tabla 23. Descarga estimada por la RNA vs descarga previamente reportada para agosto 2013

Pozo	Columna	Renglón	Reportadas (en m ³ /mes)	RNA (en m ³ /mes)	Diferencia entre descarga Reportada vs estimada por la RNA (en %)
P-62	28	14	-105,125	-6,680	-94
P-63	25	16	-49,667	-5,689	-89
P-66	24	19	-105,125	-12,030	-89
P-67	20	19	-157,675	-52,373	-67
P-70	18	15	-105,125	-5,052	-95
P-80	16	21	-105,125	-108,405	3
P-82	18	11	-105,125	-4,250	-96
P-95	12	9	-105,125	-97,614	-7
P-97	9	3	-20,391	-114,891	463
P-98	11	5	-115,625	-52,200	-55
P-142	10	11	-20,391	-44,164	117
P-150	10	15	-20,391	-30,343	49
P-155	16	13	-20,391	-4,374	-79
P-158	8	13	-20,391	-53,352	162
P-164	12	7	-20,391	-12,778	-37
P-165	14	9	-20,391	-4,280	-79
P-166	10	7	-86,725	-83,454	-4
P-174	8	11	-20,391	-57,680	183
P-185	12	11	-20,391	-24,966	22
P-199	14	17	-20,391	-5,357	-74
P-200	14	19	-20,391	-19,321	-5
P-203	26	23	-20,391	-11,915	-42
P-204	22	23	-20,391	-42,684	109
Promedio			-1,305,525	-853,850	8.5

Se observa un incremento notable en la descarga del pozo P-97, con un aumento del 463% en comparación con los valores previamente registrados. Este aumento sugiere un cambio significativo en las condiciones de extracción del agua en ARC, por ejemplo, debido a una expansión agrícola, o cambios en el uso del agua. Puesto que, también se registró un aumento en los pozos P-142, P-150, P-158 y P-174, que oscila entre el 49 y 183% la mayoría ubicados cerca del límite norte de la salida del ARC. Además, en 15 de los pozos analizados por la RNA se registra una disminución que oscila entre el 5 y 96 %. Principalmente, tales pozos están ubicados en la sección Este del ARC (P-62, P-63, P-66, P-67, P-70, P-82, P-155). No obstante, a pesar de que algunos pozos aumentan su descarga, se registra una disminución del 8.03% en la descarga promedio global registrada en el ARC (Tabla 24). Es posible que haya habido cambios en la demanda de agua en diferentes áreas del acuífero, lo que podría haber llevado a una disminución en la extracción de agua en ciertos pozos. Los cuales pudieron haberse secado debido al fuerte abatimiento del NF, puesto que, en dicha zona se ha presentado una disminución del NF de hasta 10 m en comparación con julio de 1989. Por lo tanto, el aumento de la descarga en el límite norte, a la salida del ARC, y la disminución en la descarga registrada en la sección Este del ARC, principalmente, podría indicar que el modelo de RNA está distribuyendo las descargas hacia áreas que experimentan una mayor explotación o demanda de agua. Cuyo comportamiento puede reflejar una adaptación del modelo para optimizar la distribución de agua en el acuífero, respondiendo a las condiciones cambiantes de extracción y la dinámica de la zona.

Tabla 24. Descarga estimada por la RNA para agosto 2013 en el ARC

Descarga estimada para agosto 2013 en el ARC (m³/mes)		
Reportada	Estimada por la RNA	Diferencia RNA vs Reportada (%)
-7,721,268	-7,100,668	8.03

Además, los ajustes en la estimación de la descarga, al igual que en la fecha anterior, se refleja con una mejora en la precisión del modelo en MODFLOW (Fig. 37). Por ello, en este escenario (caso 2), es posible evaluar el rendimiento de la RNA utilizando los registros de NF interpolados, donde se observa el mejor ajuste con 3.28 m (Fig. 37a). Lo cual, se debe a que la RNA intentará ajustar la descarga para alinearse con los registros interpolados del NF. Por lo tanto, se espera una mayor precisión, dado que la RNA tiende a mostrar un mejor

desempeño cuando el registro del NF coincide con el punto de descarga y el mes de operación de los pozos (Fig. 37).

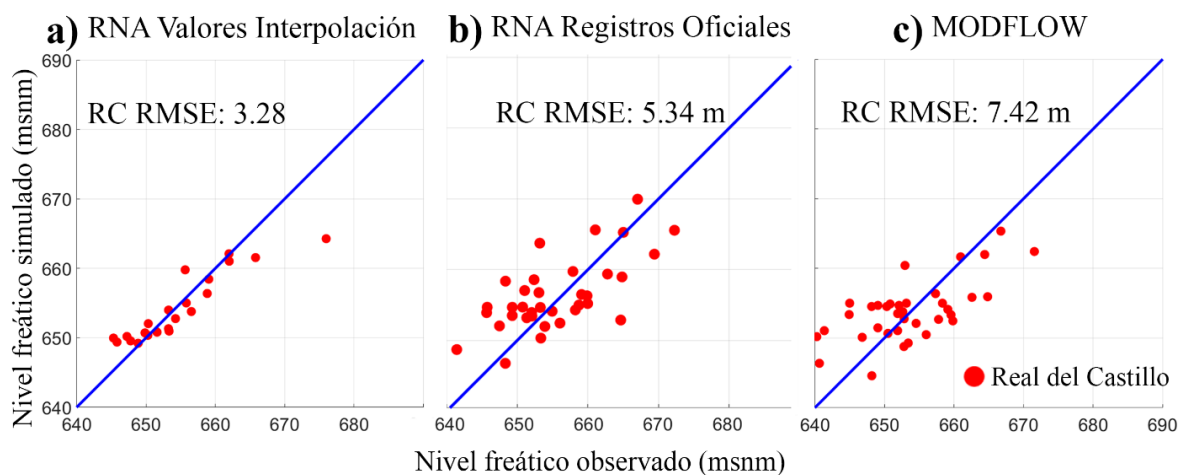


Figura 37. Ajustes del NF para agosto de 2013. a) Modelado del flujo de agua subterránea considerando la descarga estimada por la RNA contra los registros del NF interpolados; b) Modelado del flujo de agua subterránea considerando la descarga estimada por la RNA contra los registros oficiales, y c) Modelo de flujo sin considerar la descarga estimada por la RNA

Por otro lado, los ajustes verticales del NF calculado y observado considerando las descargas estimadas por la RNA en el modelado numérico del flujo de agua subterránea se ven reflejados con una mejora del 28%, en comparación con aquellos registros del NF obtenidos mediante el modelo de flujo en el área del ARC sin considerar tales descargas. Aunque el proceso de interpolación afecta la precisión del modelo neuronal para estimar la descarga en los puntos de observación reportados, llevar a cabo el modelado del flujo de agua subterránea considerando la descarga estimada con la RNA genera un mejor ajuste en los NF calculados y observados, para muestra el RMSE resultante de 5.34 m (Tabla 25). Sin embargo, los puntos donde la RNA estimó la descarga cuentan con un RMSE de 3.28 m. Esta situación surge porque la RNA se ve afectada al utilizar el proceso de interpolación, lo que genera una disminución en su precisión. Debido a que la RNA está ajustando la descarga a los pozos en los que se estimó la descarga, los cuales tienen un registro del NF producto de la interpolación. Mientras que, los registros del NF reportados no están precisamente ubicados en los pozos en los que se está determinado la descarga.

Tabla 25. Comparación de resultados obtenidos de la RNA comparados con el modelo de flujo para Agosto de 2013

Acuífero	MODELO			Modelo MODFLOW considerando la descarga estimada mediante la RNA vs Modelo MODFLOW
	RMSE (m)			
	Modelo de flujo MODFLOW	RNA valores interpolados	Modelo MODFLOW considerando la descarga estimada mediante la RNA	(%) de Mejora
RC	7.42	3.28	5.34	28

La distribución piezométrica obtenida para agosto de 2013 se muestra en la Figura 38a. Se observa que los NF mostraron fluctuaciones que oscilaron entre los 645 y 730 msnm en el área de ON. Por otra parte, en el ARC, estos niveles variaron de 655 a 680 msnm (Fig. 39a). Esta variación indica una disminución en el NF de alrededor de 10 m en la parte central y norte del ARC en comparación con Julio de 1989 (Fig. 34a y 38a).

Por otro lado, los registros de errores residuales muestran ajustes generales que van desde -6 a 6 m (Fig. 38b). En la parte norte de RC, se observan errores de -4 y -6 m. Estos podrían estar relacionados con la ausencia de pozos de extracción en esa área, los cuales no fueron considerados por el modelo neuronal en su estimación.

A pesar de que se registra una disminución en la precisión del modelo (Modelo MODFLOW considerando la descarga estimada mediante la RNA vs Modelo MODFLOW) en comparación con julio de 1989, donde se observó una mejora de aproximadamente 37% (Tabla 21), en esta última fecha con registro del NF para el ARC, también se registró una mejora del 28% (Tabla 25). La aplicación del caso 2 podría ser responsable de esta disminución, aunque, en general, los errores muestran buenos ajustes en comparación con los resultados de MODFLOW. Esta tendencia sugiere que, aunque la precisión del modelo puede disminuir con la extensión de las fechas de modelación, el modelo neuronal sigue ofreciendo ajustes satisfactorios en comparación con los resultados de MODFLOW.

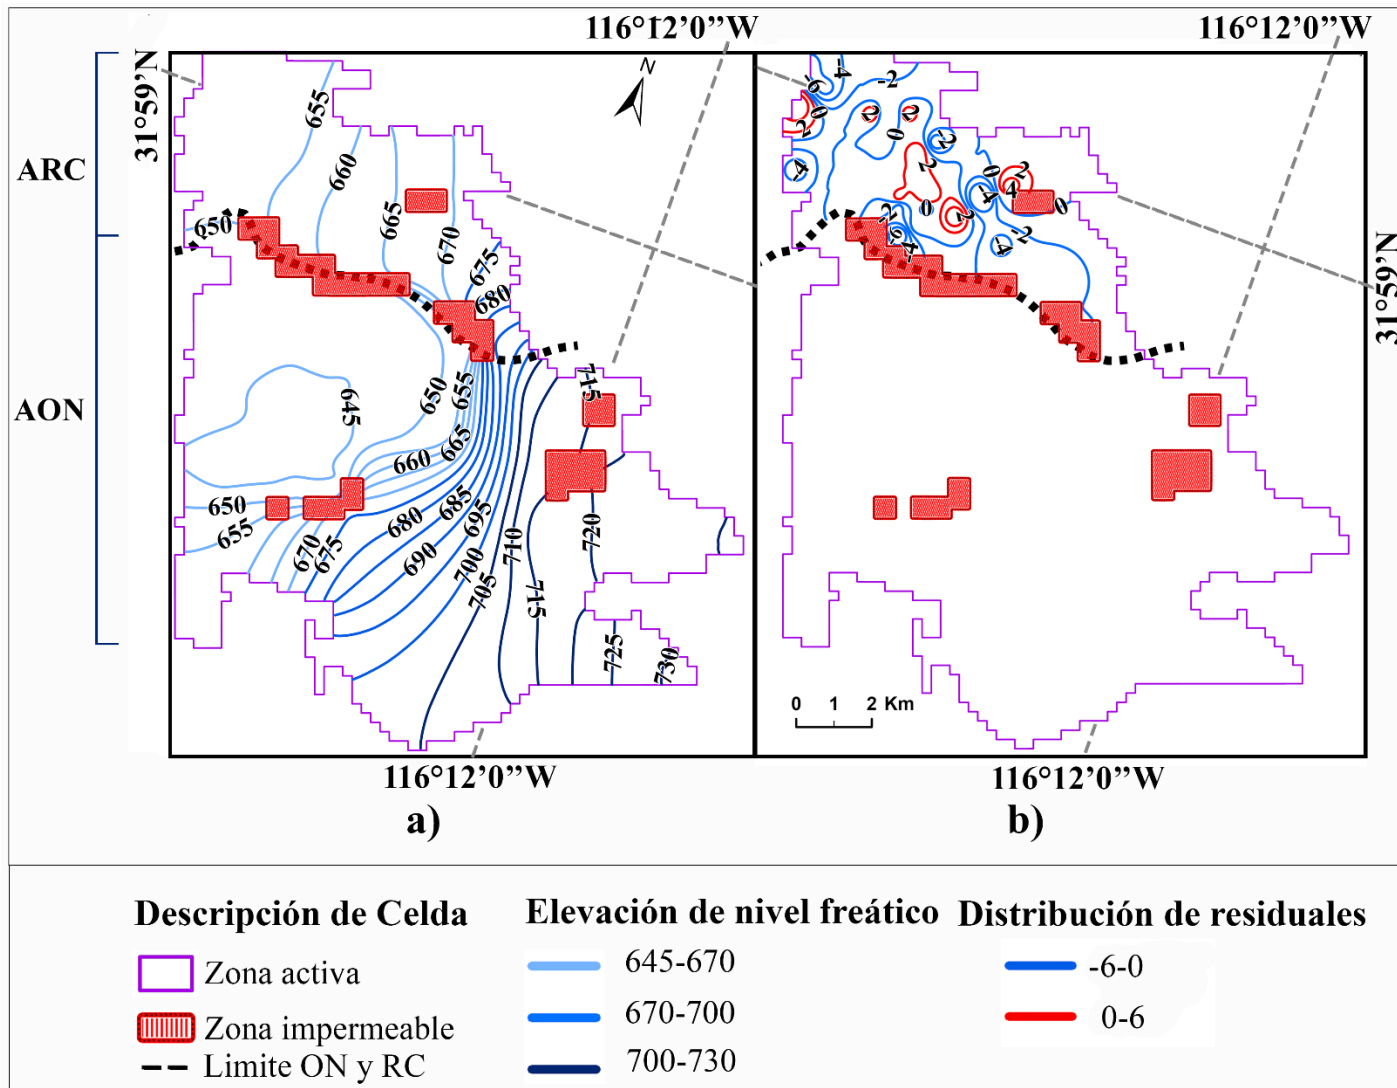


Figura 38. Registros del nivel freático (a) y mapa de residuales para agosto de 2013 (b)

IV.6.3 Resultados del modelo de RNA para noviembre de 2013

La siguiente fecha de análisis corresponde a noviembre de 2013, en la cual, se consideran 372 meses de operación con observaciones únicamente para el AON (Fig. 39). Esta fecha se clasifica como caso 2, por lo tanto, se aplicó la misma metodología que para agosto de 2013. Se cuenta con 46 registros del NF utilizados la interpolación (Apéndice C). El modelo neuronal es entrenado con datos de 54 pozos; cuya distribución de la descarga considera dos segmentos: 0 a -100,000 m³/mes y -100,000 a -250,000 m³/mes (Fig. 39).

Los resultados del entrenamiento no muestran grandes diferencias con relación a los análisis anteriores; es decir, la RNA 1 requirió más épocas para alcanzar un error de 6.83%, mientras que la RNA 2 necesitó menos épocas para llegar a un error de 6.32%. Lo anterior, a pesar de que el número de datos utilizados durante el entrenamiento fue muy similar. Esta diferencia mínima en el número de épocas no produce diferencias significativas en el rendimiento general de ambas redes (etapas de entrenamiento y validación) (Tabla 26).

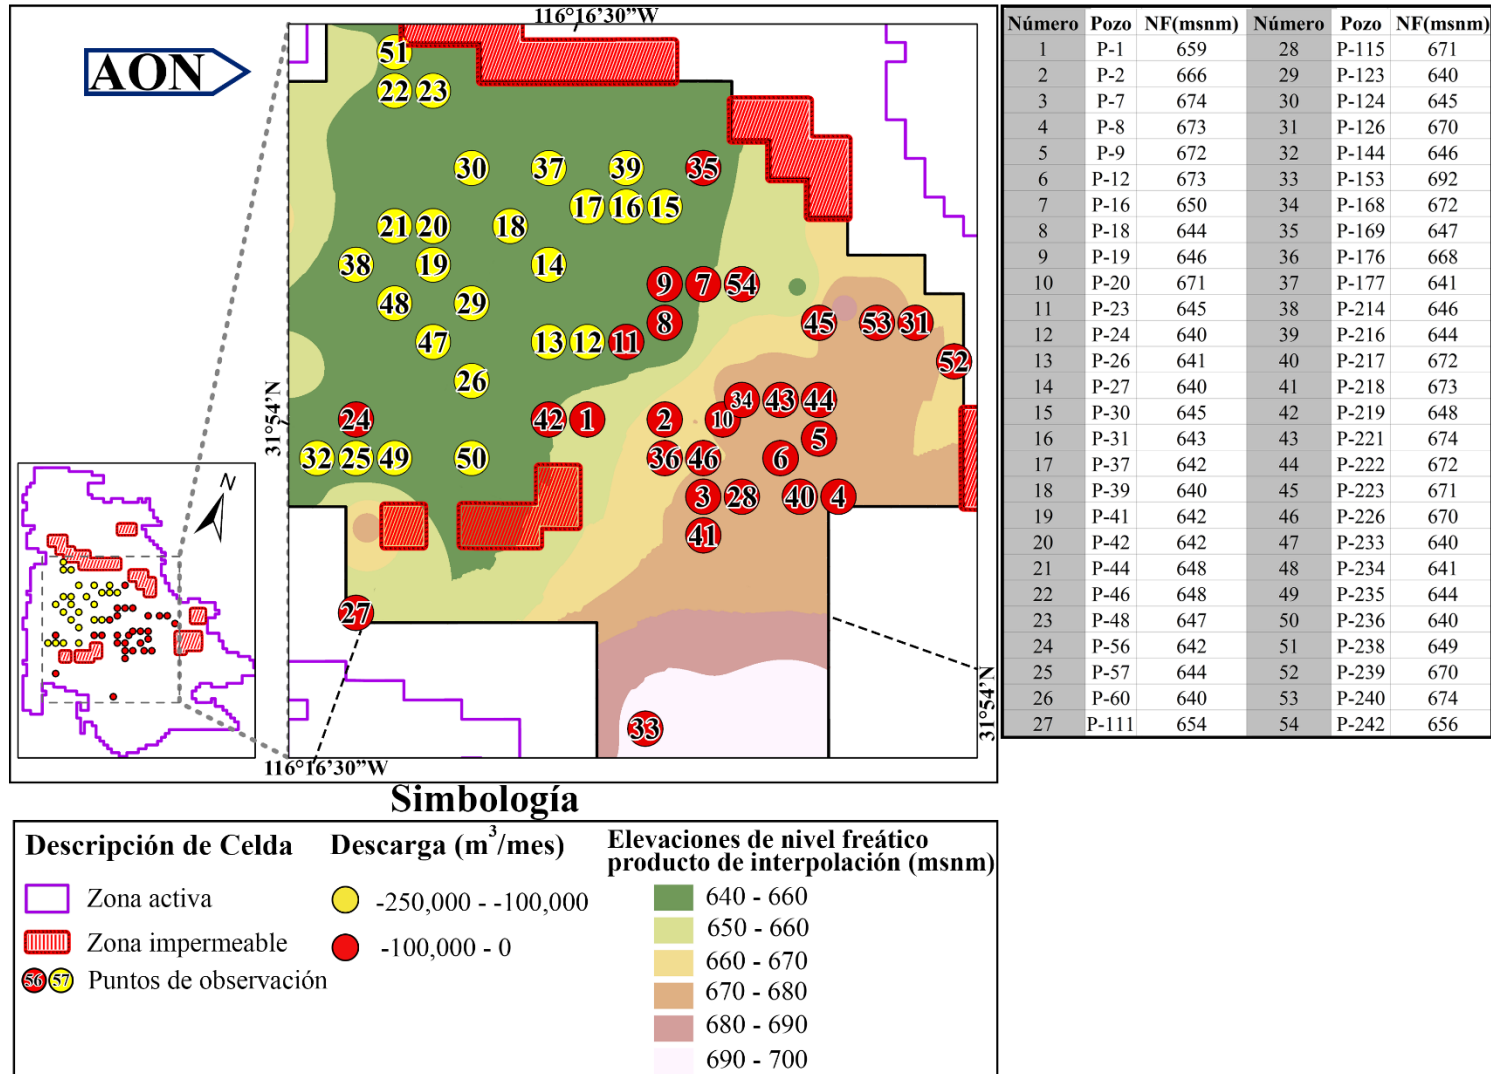


Figura 39. Puntos de descarga y registros del nivel freático utilizados en el entrenamiento y validación de la RNA para noviembre de 2013

Tabla 26. Resultados del entrenamiento y validación de la RNA. *Nota: La RNA 1 indica el segmento de datos 0 a -100,000 m³/mes, y la RNA 2 indica de segmento de -100,000 a -250,000 m³/mes*

Acuífero	RNA	Puntos de descarga	Meses de Operación	Datos de Entrenamiento	Datos de Validación	Épocas	Error	
							Entrenamiento (%)	Validación (%)
ON	1	29	371	9380	1008	264	6.83	5.54
	2	25	371	8710	936	259	6.32	4.65
Total				18090	1944			

Nuevamente, se observa que los valores de validación (Registro de 2011 a 2013) muestran una consistencia al presentar un porcentaje de error menor que los valores de entrenamiento (Fig. 40). Esto podría estar relacionado con la dispersión de los pozos utilizados, ya que, se distribuyen en diferentes zonas de conductividad hidráulica, lo que le proporciona una mayor solidez durante el entrenamiento, dado que, se tienen más ejemplos de las diferentes zonas del modelo. En contraste, el conjunto de pozos con valores de 0 a -100,000 m³/mes en su mayoría se encuentran agrupado o distribuidos en menos zonas de conductividad hidráulica, lo que podría generar ruido en el modelo de RNA al ingresar información de pozos que están alejados de estas agrupaciones (Fig. 40).

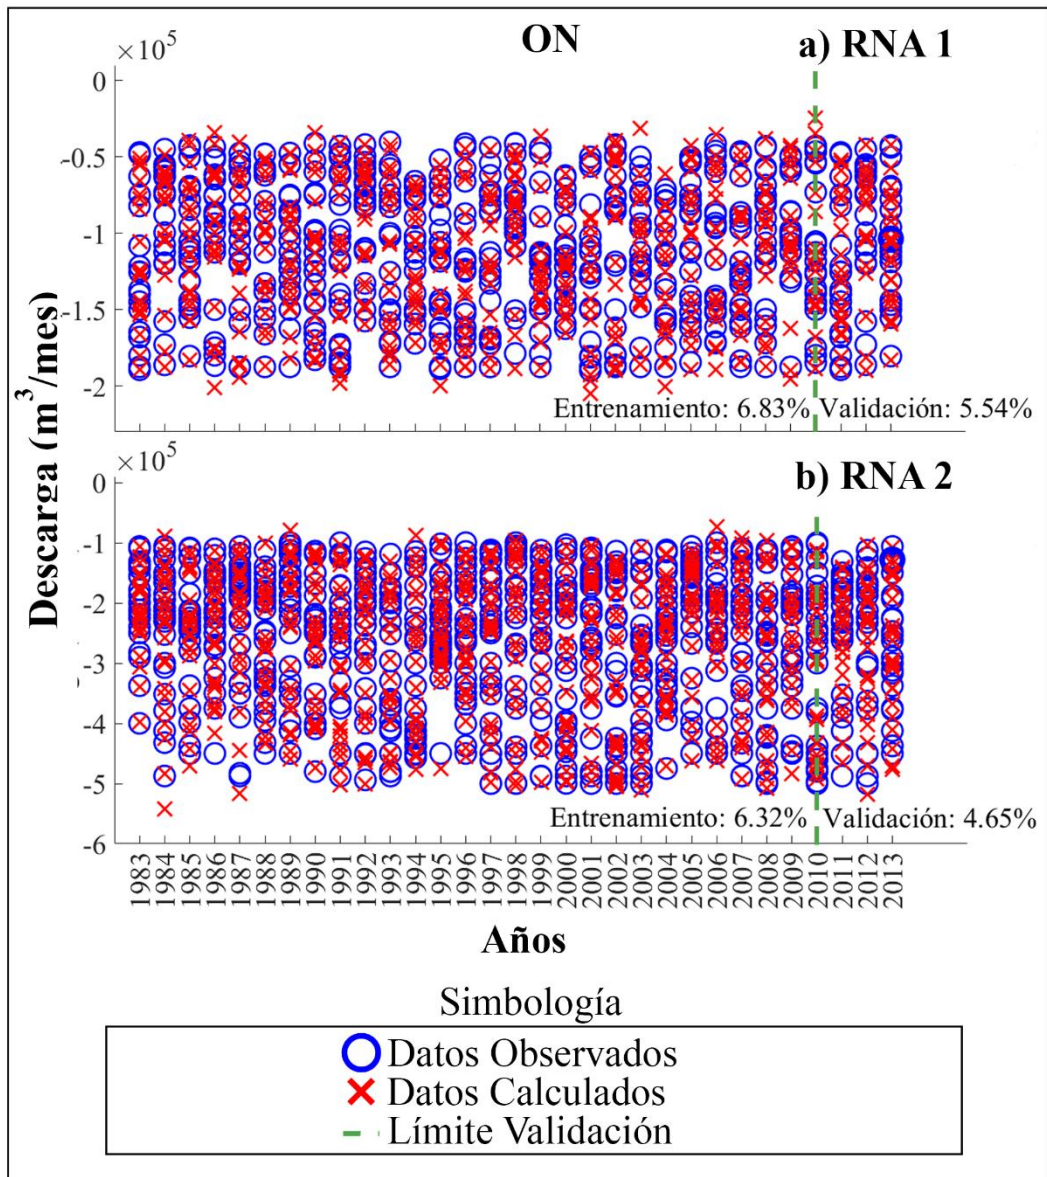


Figura 40. Resultados del entrenamiento y validación de la RNA para noviembre 2013 en el AON únicamente. a) RNA 1 con 29 pozos y considerando valores en el orden de -100,000 a -250,000 m³/mes, y b) RNA 2 con 25 pozos y considerando valores en el orden de 0 a -100,000 m³/mes

IV.6.3.1 Estimación de la descarga mediante la RNA para noviembre de 2013

Es importante destacar que la RNA estima un incremento del 196% en la descarga promedio global respecto a la descarga reportada. Este aumento se ve influenciado principalmente por algunos pozos que presentan incrementos significativos, como los pozos P-18 y P-153 (Tabla 27).

Tabla 27. Descarga estimada por la RNA para Noviembre de 2013 vs descarga reportada. Simbología: C: Columna, R: Renglón, A: Descarga reportada (original; m³/mes), B: Descarga estimada por la RNA (m³/mes), E: Diferencia entre ambas descargas (%)

Pozo	C	R	A	B	E
P-1	22	44	-87,660	-2,274	97
P-2	26	44	-22,826	-3,621	84
P-7	28	48	-43,983	-3,644	92
P-8	35	48	-972	-2,018	-108
P-9	34	45	-66,260	-3,581	95
P-12	32	46	-26,150	-3,182	88
P-16	28	37	-22,144	-45,204	-104
P-18	26	39	-540	-21,767	-3931
P-19	26	37	-23,300	-55,628	-139
P-20	29	44	-32,936	-1,564	95
P-23	24	40	-10,983	-33,738	-207
P-24	22	40	-125,000	-378,458	-203
P-26	20	40	-125,000	-151,792	-21
P-27	20	36	-250,000	-209,940	16
P-30	26	33	-125,000	-252,748	-102
P-31	24	33	-125,000	-274,125	-119
P-37	22	33	-125,000	-278,991	-123
P-39	18	34	-125,000	-280,471	-124
P-41	14	36	-250,000	-213,795	14
P-42	14	34	-125,000	-205,184	-64
P-44	12	34	-125,000	-90,128	28
P-46	12	27	-166,667	-68,311	59
P-48	14	27	-125,000	-91,916	26
P-56	10	44	-83,333	-93,676	-12
P-57	10	46	-208,333	-80,200	62
P-60	16	42	-208,333	-125,762	40
P-111	10	54	-83,333	-2,381	97
P-115	30	48	-22,983	-2,806	88

Pozo	C	R	A	B	E
P-123	16	38	-208,333	-138,156	34
P-124	16	31	-250,000	-289,623	-16
P-126	39	39	-3,942	-10,803	-174
P-144	8	46	-208,333	-97,075	53
P-153	25	60	-38	-2,542	-6589
P-168	30	43	-20,832	-1,940	91
P-169	28	31	-35,854	-59,391	-66
P-176	26	46	-19,217	-2,105	89
P-177	20	31	-125,000	-261,154	-109
P-214	10	36	-125,000	-39,308	69
P-216	24	31	-146,347	-162,922	-11
P-217	33	48	-90,180	-60,411	33
P-218	28	50	-16,213	-1,606	90
P-219	20	44	-99,944	-19,696	80
P-221	32	43	-2,172	-2,055	5
P-222	34	43	-47,040	-2,088	96
P-223	34	39	-31,662	-2,710	91
P-226	28	46	-80,021	-2,380	97
P-233	14	40	-208,333	-138,750	33
P-234	12	38	-208,333	-363,612	-75
P-235	12	46	-125,000	-167,199	-34
P-236	16	46	-125,000	-108,540	13
P-238	12	25	-166,667	-69,876	58
P-239	41	41	-1,728	-2,781	-61
P-240	37	39	-20,747	-17,726	15
P-242	30	37	-63,661	-126,939	-99
Promedio			-95,654	-94,968	-196

El incremento en la descarga de los pozos P-18 y P-153, que alcanza un 3931% y 6589%, respectivamente, refleja la capacidad de la RNA para ajustar las estimaciones de descarga, corrigiendo posibles subestimaciones en los valores originalmente reportados (-540 y 38 m³/mes). Además, el pozo P-18 se sitúa en la zona central de ON, donde en general se observa un aumento en la descarga que está alineada con la tendencia observada en otros pozos como: P-19, P-23, P-24, P-26, P-30, P-31, P-37 y P-39, donde los incrementos varían entre el 21% y el 207%. Esta tendencia también se presenta en la zona noroeste del AON, en el pozo P-177, que registra un aumento del 109%; así como en los pozos P-169 y P-216, con aumentos que van del 11 al 66%. Estos resultados indican que la RNA ha captado eficazmente la distribución de las descargas en función de la demanda de agua, particularmente, en áreas con intensa actividad agrícola. Por otro lado, la RNA también ha identificado áreas donde la descarga ha disminuido entre 5 y 98%, principalmente, en la zona centro y sureste del AON. De nuevo, esta redistribución de las descargas (Tabla 28), sugiere que la RNA ha afinado su proceso de estimación, debido a que el incremento en la descarga está relacionado con las zonas del acuífero donde los abatimientos del NF son más intensos, mientras que la disminución de la descarga se asocia con aquellas áreas donde los abatimientos son menos pronunciados.

Tabla 28. Descarga estimada por la RNA para Noviembre de 2013 en el AON

Descarga estimada para Noviembre de 2013 en el AON (m³/mes)		
Reportada	Estimada por la RNA	Diferencia RNA vs Reportada (%)
46,327,606	42,604,006	8.04

Al igual que en fechas anteriores, el empleo de la descarga estimada por la RNA en el modelado numérico del flujo de agua subterránea con MODFLOW, muestra una mejora en la precisión de los ajustes verticales del NF calculado y observado (Fig. 41). Destacándose un ajuste de 3.80 m considerando los valores interpolados (Fig. 41a). Cuyo resultado es notable si se compara con el RMSE de 6.34 m obtenido mediante la aplicación del modelo de flujo en el área del AON sin considerar tales descargas y los registros oficiales del NF sin interpolación (Fig. 41b). Aun así, este último resultado es el reflejo de una optimización en la descarga estimada por la RNA para la fecha de análisis, lo que produce una mejora en la precisión del ajuste vertical cuando se compara con los resultados del modelado del flujo de agua subterránea sin considerar la descarga estimada mediante las RNA contra el registro del NF observado.

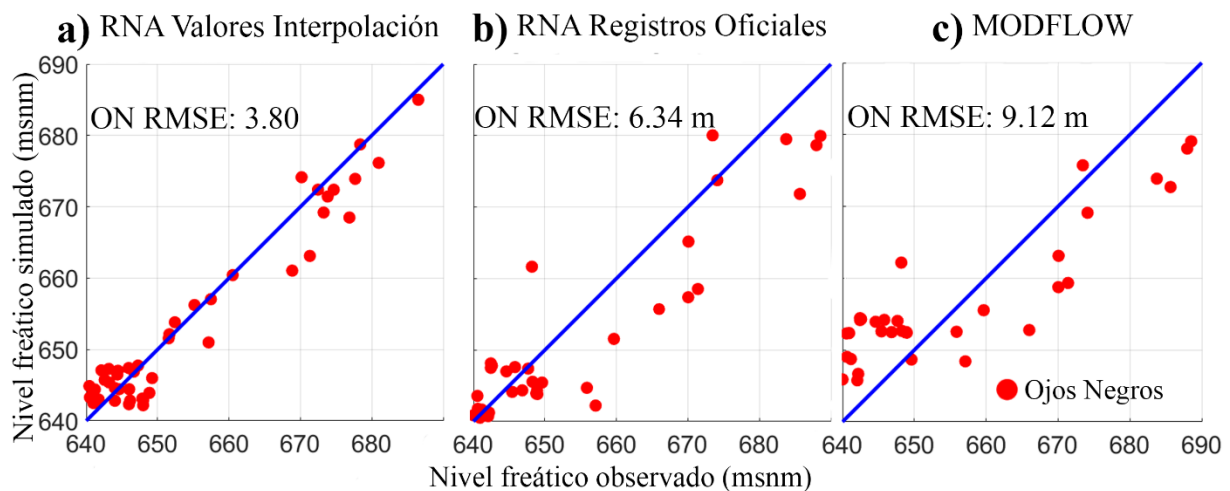


Figura 41. Ajustes del NF para Noviembre de 2013. a) Modelado del flujo agua subterránea considerando la descarga estimada por la RNA contra el registro del NF interpolado; b) Modelado del flujo de agua subterránea considerando la descarga estimada mediante por la RNA contra el registro oficial del NF, y c) Modelado del flujo de agua subterránea sin considerar la descarga estimada por la RNA

El uso del caso 2 muestra ciertos desafíos, ya que se observa una ligera disminución en la precisión del modelo al evaluar los registros reportados, obteniéndose un RMSE de 6.34 m. Esta reducción en la precisión puede atribuirse a que la RNA ajusta su comportamiento según los valores interpolados, lo cual introduce cierta variabilidad, debido a que estos valores se basan en una estimación derivada de datos cercanos. Sin embargo, a pesar de estas limitaciones, se logra una mejora del 30.48% en comparación con los valores estimados por MODFLOW (Tabla 29). Con estas estimaciones en la descarga la RNA de muestra su aplicabilidad, logrando ajustes más precisos en los registros del NF, incluso en escenarios donde no se dispone de información completa sobre las descargas en la zona de estudio.

Tabla 29. Comparación de los resultados obtenidos de la RNA contra los calculados con el modelo de flujo para Noviembre de 2013

	MODELO			Modelo MODFLOW considerando la descarga estimada mediante la RNA vs Modelo MODFLOW
	RMSE (m)			
Acuífero	Modelo de flujo MODFLOW	RNA valores interpolados	Modelo MODFLOW considerando la descarga estimada mediante la RNA	(%) de Mejora
ON	9.12	3.80	6.34	30.48

Por otro lado, la distribución piezométrica obtenida mediante el empleo de la descarga estimada por la RNA en el modelado numérico con MODFLOW se muestra en la Figura 42a. En el AON, los NF presentaron fluctuaciones que oscilaron entre aproximadamente 640 y 725 msnm. Esto indica un abatimiento de alrededor de 15 a 30 m en la zona central de ON, respecto a los registros piezométricos de julio de 1989. Por otro lado, en la zona de RC, las fluctuaciones oscilaron entre los 655 y 680 msnm, manteniendo consistencia con los valores estimados en agosto de 2013.

Los registros de errores residuales muestran un rango de ajustes que varía entre -10 m y 10 m (Fig. 42b). Los mejores ajustes se encuentran en la zona central de ON, donde los valores oscilan entre -2 m y -4 m, lo que refleja la capacidad del modelo para ajustar la descarga en áreas con alta densidad de pozos. Lo cual, sugiere que la RNA es capaz de captar la explotación intensiva en el AON y, por ende, refinar las estimaciones en la descarga.

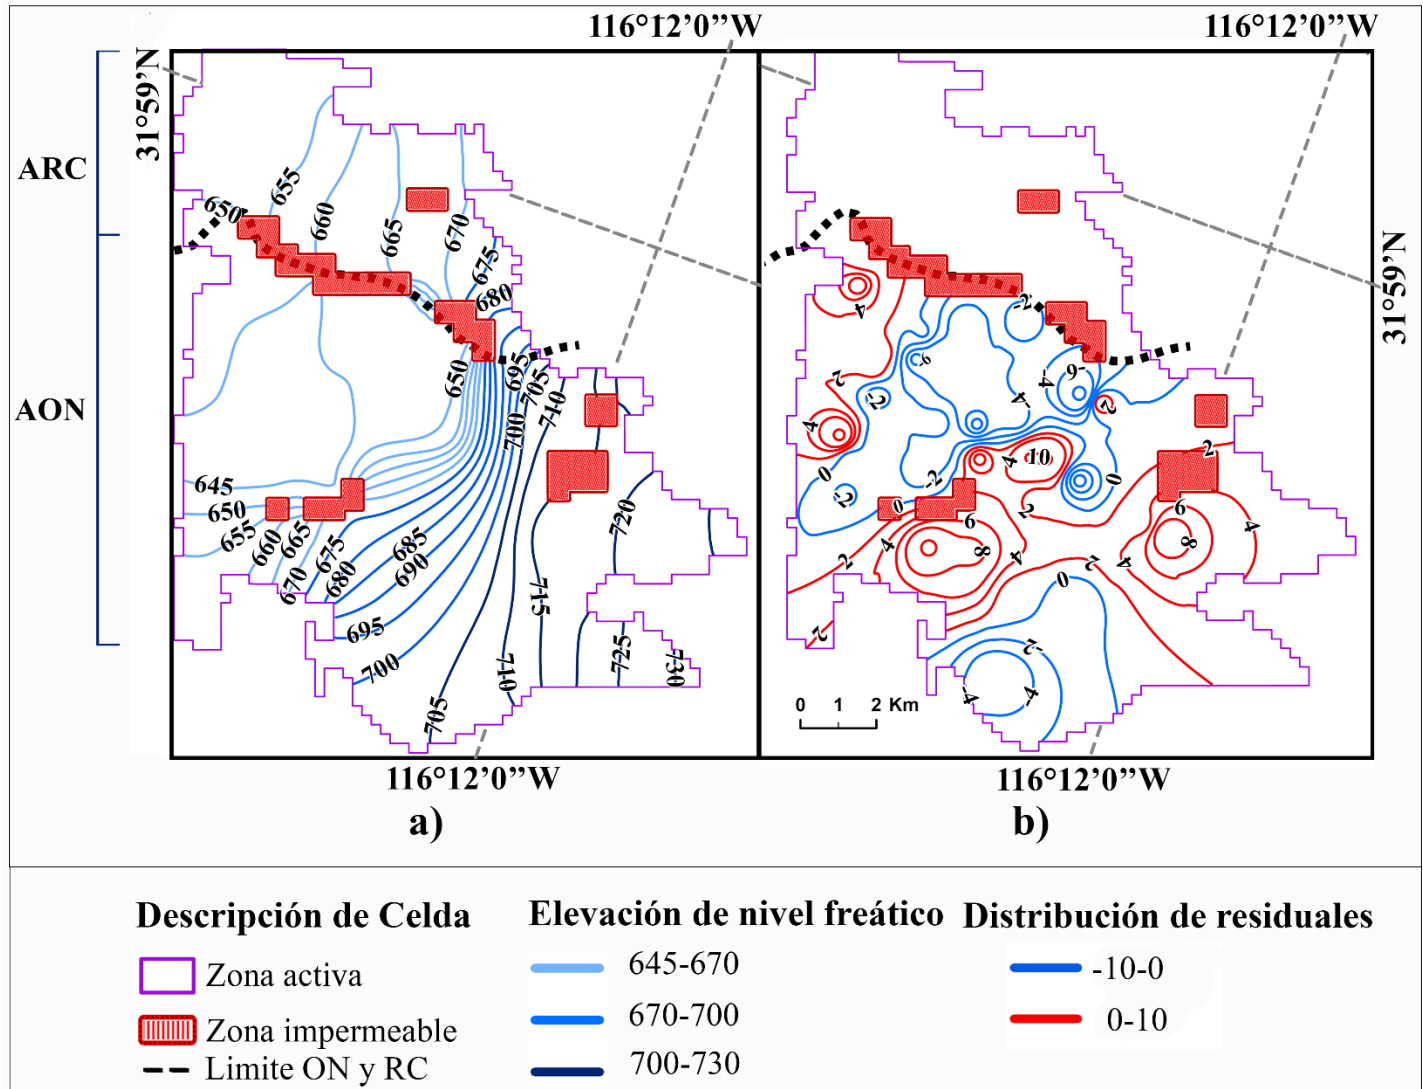


Figura 42. Registro del NF (a) y mapa de residuales (b) para Noviembre de 2013

IV.6.4 Resultados del modelo de RNA para noviembre de 2017

La última fecha para la que se estimó la descarga mediante un modelo neuronal es Noviembre de 2017; para ello, se analizan en total 418 meses de operación, con observaciones limitadas al AON (Fig. 43). Dicha fecha se analizó considerándola como Caso 2 y se emplearon 31 registros del NF durante el proceso de interpolación (Apéndice C). Para el entrenamiento y validación de la RNA se utilizaron 59 pozos de descarga (Fig. 43); cuya distribución de la descarga se categorizó en dos segmentos: de 0 a -100,000 m³/mes, y de -100,000 a -250,000 m³/mes.

Los resultados del entrenamiento muestran una mayor precisión en el segmento con más datos (correspondiente a la RNA 2 de la Tabla 30). Esto sugiere que una mayor dispersión entre los parámetros espaciales del modelo facilita que la RNA aprenda y represente las características de manera más efectiva. Sin embargo, esta mejora en la precisión implicó que el número de épocas haya sido ligeramente mayor.

En contraste, el segmento con menos datos presentó una precisión menor (RNA 1 en la Tabla 30). Tales datos cuentan con una menor dispersión en los valores de conductividad hidráulica. Por lo tanto, es posible que esta dispersión esté relacionada con la precisión de la RNA.

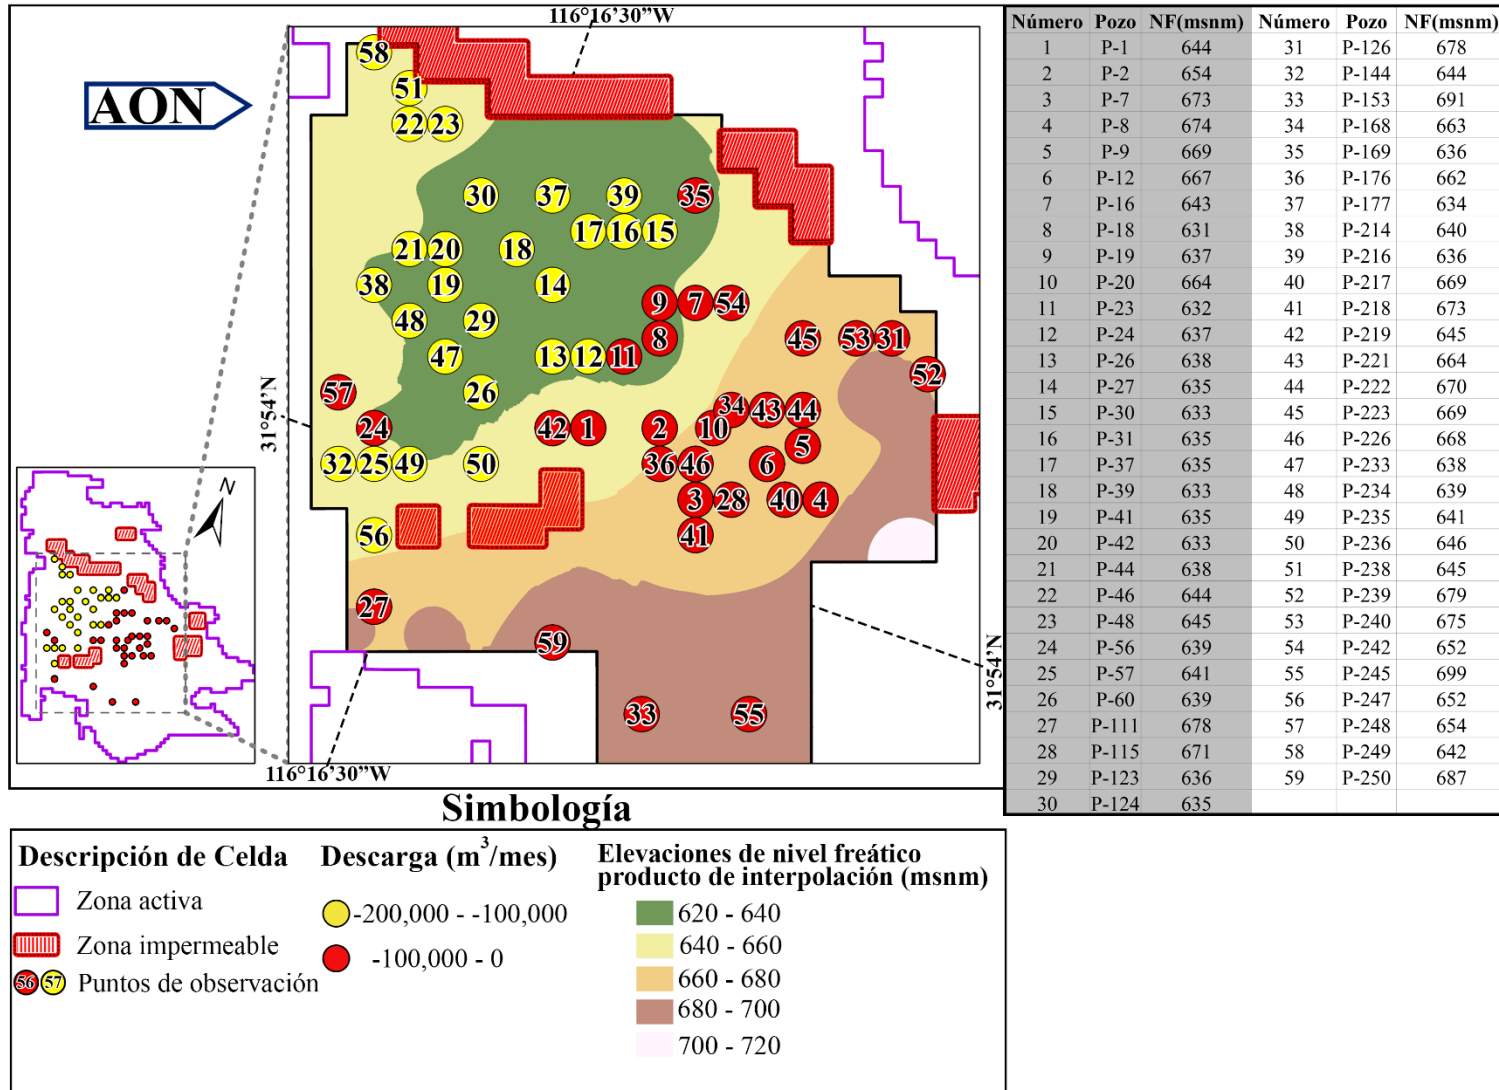


Figura 43. Puntos de descarga y registro del NF utilizados en el entrenamiento y validación de la RNA para Noviembre de 201

Tabla 30. Resultados del entrenamiento y validación de la RNA para Noviembre de 2017. *Nota: La RNA 1 indica el segmento de datos 0 a -100,000 m³/mes, y la RNA 2 indica de segmento de -100,000 a -250,000 m³/mes*

Acuífero	RNA	Puntos de descarga	Meses de Operación	Datos de Entrenamiento	Datos de Validación	Épocas	Error	
							Entrenamiento (%)	Validación (%)
ON	1	27	418	10314	972	375	7.22	5.58
	2	32	418	12224	1152	402	6.34	4.14
Total				22538	2124			

De nuevo, se observa que los valores de validación (Registro de 2015 a 2017, Figs. 44) muestran consistencia al presentar un porcentaje de error menor en comparación con los valores de entrenamiento. Sin embargo, las diferencias mostradas durante la etapa de entrenamiento también se reflejaron en la etapa de validación. La RNA 2 mostro un error del 4.14%, en comparación con el 5.58% de la RNA 1. Considerando los resultados anteriores del modelo neuronal, se sugiere que existe una tendencia de mayor precisión sujeta a mayor variabilidad de los parámetros analizados por el modelo neuronal. Dicha variabilidad podría estar relacionado con en la heterogeneidad espacial de los pozos, los cuales de distribuyen en distintas áreas con variaciones en la conductividad hidráulica. Puesto que, se observa que los pozos utilizados en la RNA 1 tienden a estar más concentrados en un número menor de zonas de conductividad hidráulica. Esta concentración podría introducir sesgos cuando se incorporan datos de pozos situados fuera de estas zonas.

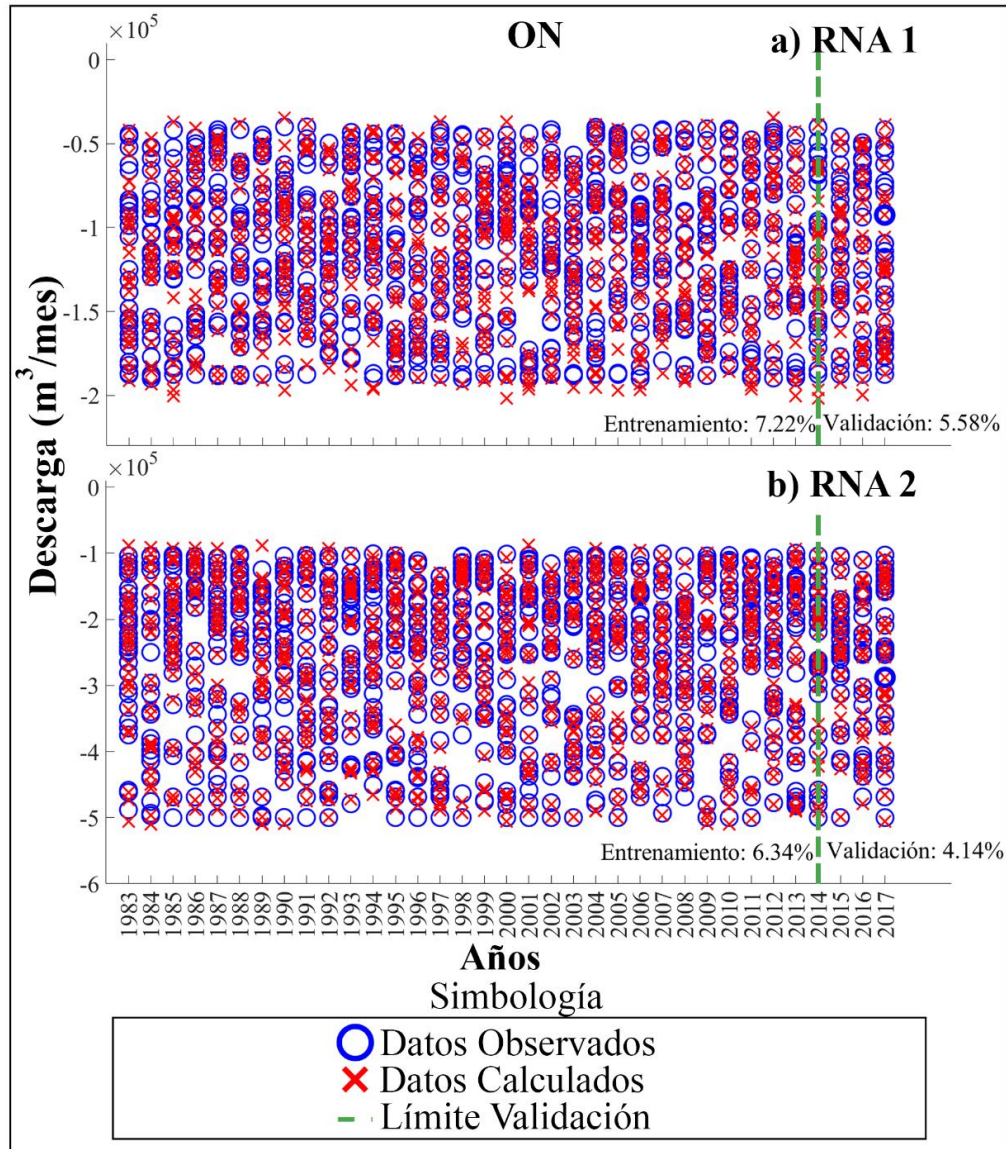


Figura 44. Resultados del entrenamiento y validación de la RNA para noviembre 2017. a) RNA 1 con 27 pozos, y b) RNA 2 con 32 pozos

IV.6.4.1 Estimación de la descarga mediante la RNA para Noviembre de 2017

Los resultados para Noviembre de 2017 mostraron un aumento en la descarga de los pozos analizados por la RNA, con un promedio de incremento global de hasta el 324% (Tabla 31).

Tabla 31. Descarga estimada por la RNA para Noviembre de 2017 vs descarga previamente reportada.
Simbología: C: Columna, R: Renglón, A: Descarga reportada (original; m³/mes), B: Descarga estimada por la RNA (m³/mes), E: Diferencia entre ambas descargas (%)

Pozo	C	R	A	B	E
P-1	22	44	-87,660	-84,029	4
P-2	26	44	-22,826	-58,795	-158
P-7	28	48	-43,983	-42,443	4
P-8	35	48	-972	-3,845	-296
P-9	34	45	-66,260	-90,670	-37
P-12	32	46	-26,150	-71,176	-172
P-16	28	37	-22,144	-160,961	-627
P-18	26	39	-540	-2456	-355
P-19	26	37	-23,300	-155,856	-569
P-20	29	44	-32,936	-30,595	7
P-23	24	40	-10,983	-157,127	-1331
P-24	22	40	-125,000	-212,185	-70
P-26	20	40	-125,000	-124,199	1
P-27	20	36	-250,000	-137,373	45
P-30	26	33	-125,000	-209,287	-67
P-31	24	33	-125,000	-227,929	-82
P-37	22	33	-125,000	-191,226	-53
P-39	18	34	-125,000	-206,897	-66
P-41	14	36	-250,000	-146,577	41
P-42	14	34	-125,000	-229,448	-84
P-44	12	34	-125,000	-177,595	-42
P-46	12	27	-166,667	-134,380	19
P-48	14	27	-125,000	-138,381	-11
P-56	10	44	-83,333	-121,612	-46
P-57	10	46	-208,333	-144,066	31
P-60	16	42	-208,333	-100,783	52
P-111	10	54	-83,333	-7,478	91
P-115	30	48	-22,983	-68,630	-199
P-123	16	38	-208,333	-112,265	46
P-124	16	31	-250,000	-238,625	5
P-126	39	39	-3,942	-7,942	-101
P-144	8	46	-208,333	-138,803	33
P-153	25	60	-38	-5,463	-14276
P-168	30	43	-20,832	-16,864	19
P-169	28	31	-35,854	-104,456	-191
P-176	26	46	-19,217	-54,060	-181
P-177	20	31	-125,000	-215,661	-73
P-214	10	36	-125,000	-102,598	18
P-216	24	31	-146,347	-5,893	96
P-217	33	48	-90,180	-88,653	2
P-218	28	50	-16,213	-25,405	-57
P-219	20	44	-99,944	-87,215	13
P-221	32	43	-2,172	-4,632	-113
P-222	34	43	-47,040	-42,524	10
P-223	34	39	-31,662	-51,013	-61
P-226	28	46	-80,021	-44,827	44
P-233	14	40	-208,333	-115,470	45
P-234	12	38	-208,333	-201,969	3
P-235	12	46	-125,000	-133,228	-7
P-236	16	46	-125,000	-104,995	16
P-238	12	25	-166,667	-109,739	34
P-239	41	41	-1,728	-4,428	-156
P-240	37	39	-20,747	-59,788	-188
P-242	30	37	-63,661	-96,805	-52
P-245	31	60	-2,129	-4,129	-94
P-247	10	50	-166,667	-113,967	32
P-248	8	42	-7,919	-10,232	-29
P-249	10	23	-166,667	-100,367	40
P-250	20	56	-2,595	-3,679	-42
Promedio			-93,412	99,012	-324

En esta ocasión, este incremento se ve influenciado por el pozo P-153, que originalmente se reporta con una descarga de 38 m³/mes. Posterior al análisis de la RNA, dicho pozo experimenta un aumento exponencial hasta el 6,589% en Noviembre de 2013 y 14,276% en Noviembre de 2017.

Del mismo modo, el pozo P-23, ubicado en la zona central del AON, mostró un incremento del 1,331%; así como los pozos P-2, P-8, P-12, P-16, P-18, P-19, P-24, P-30, P-31, P-37 y P-39, cuyo incremento es del 37% al 627%. Estos incrementos coinciden con el aumento de la descarga estimada por la RNA para los periodos anteriores y concuerda con el patrón general de aumentos ocurrido en estas zonas, lo que, sugiere de manera consistente una redistribución de la descarga estimada en zonas con mayor abatimiento del NF. Esta tendencia se replica en las zonas sur y suroeste del AON, con un incremento de la descarga en los pozos P-176, P-221, P-239, P-240 y P-259, que varía entre 42% y 188%. Este incremento de la descarga estimada por la RNA se observa en la mayoría de los pozos, lo que indica la existencia de una fuerte explotación del agua subterránea en la zona, probablemente, debido a la agricultura.

El acumulado de la descarga estimada por la RNA mostró una disminución del 7% (Tabla 32). A pesar de observarse este descenso en la descarga estimada, los registros del NF continúan mostrando una disminución constante. La redistribución de las descargas, captada por la RNA, es especialmente relevante en las áreas más explotadas de los acuíferos, destacando la utilidad del modelo para mejorar sus estimaciones.

Tabla 32. Descarga estimada por la RNA para Noviembre de 2017 en el AON

Descarga estimada para noviembre de 2017 en el AON (m³/año)		
Reportada	Estimada por la RNA	Diferencia RNA vs Reportada (%)
46,327,606	42,763,034	7.69

De forma similar a lo sucedido en las fechas previas, la modelación numérica del flujo de agua subterránea (MODFLOW + Descarga estimada por la RNA) produce una mejora en el ajuste vertical de los NF calculados y observados (Figura 45). Aquí se resalta un RMSE de 5.10 m producido por la diferencia de los NF calculados (con MODFLOW + Descarga estimada por la RNA) contra el registro del NF interpolado (Fig. 45a). Cuyo ajuste vertical es menor que la magnitud del RMSE de 9.98 m, la cual se obtiene de comparar los resultados del modelado numérico (con MODFLOW + Descarga estimada por la RNA) contra el registro oficial del NF. Aun así, dicha magnitud del RMSE supera el ajuste vertical logrado con el modelado numérico con MODFLOW sin considerar la descarga estimada (Fig. 45c).

Destacándose así, la capacidad de la RNA para optimizar una descarga estimada y mejorar la reproducción de los NF observados.

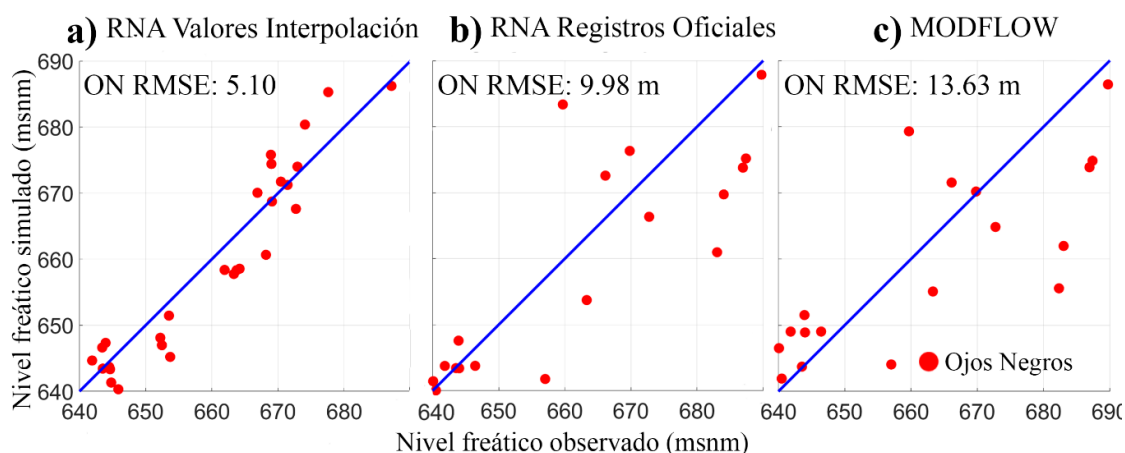


Figura 45. Ajustes del NF para Noviembre de 2017. a) Modelado del flujo de agua subterránea considerando la descarga estimada por la RNA contra el registro del NF interpolado; b) Modelado del flujo de agua subterránea considerando la descarga estimada por la RNA contra el registro oficial del NF, y c) Modelado del flujo de agua subterránea sin considerar la descarga estimada por la RNA

En general, el modelado numérico (con MODFLOW + Descarga estimada por la RNA) mejora hasta un 25.31% el ajuste vertical de los NF calculados (Tabla 33), lo que destaca la capacidad del modelo para reducir el error y mejorar la representación de los NF. Nuevamente la falta de información de los pozos de bombeo refleja la utilidad de la RNA. Aunque se detecta una ligera pérdida de precisión en comparación con las primeras fechas de modelación, esta variación puede estar asociada a la aplicación del caso 2, donde se emplearon datos interpolados. La cual, podría impactar en la precisión del modelo de RNA introducir cierto grado de error y distorsión en los datos. Aun así, el desempeño general del modelado numérico (con MODFLOW + Descarga estimada por la RNA) sigue presentando mejoras si se compara con el modelado numérico empleando MODFLOW sin considerar la descarga estimada (Tabla 33). A pesar de dichas complejidades, el modelo neuronal ha demostrado ser capaz de captar y ajustar la descarga, lo que refuerza su utilidad para futuras aplicaciones y mejoras.

Tabla 33. Comparación de los resultados obtenidos de la RNA contra los calculados con el modelo de flujo para Noviembre de 2017

	MODELO			Modelo MODFLOW considerando la descarga estimada mediante la RNA vs Modelo MODFLOW
	RMSE (m)			
Acuífero	Modelo de flujo MODFLOW	RNA valores interpolados	Modelo MODFLOW considerando la descarga estimada mediante la RNA	(%) de Mejora
ON	13.63	5.10	9.98	25.31

Por otro lado, la distribución piezométrica obtenida con MODFLOW + Descarga estimada por la RNA se muestra en la Figura 46a. Se observa que los NF para Noviembre de 2017 fluctúan entre aproximadamente 645 y 725 msnm en la zona de ON, mientras que, en RC los NF oscilan entre los 675 y 655 msnm. Ambas zonas presentan una disminución del NF, con respecto a las elevaciones presentadas en Julio de 1989. Si bien, por medio del análisis de los resultados del modelo neuronal se registra una disminución en la descarga estimada, la sobreexplotación del acuífero es de tal magnitud en la zona central, donde se encuentra la mayor concentración de los pozos de bombeo, que ha generado un abatimiento dramático del NF en toda el área analizada del AON.

Por otro lado, los registros de errores residuales muestran ajustes generales que van desde -18 hasta 18 m (Fig. 46b). Los mejores ajustes se presentan en la zona centro y norte de ON con ajustes que van desde los -6 a 3 m. Al igual que en fechas anteriores, en estas zonas se tiene una mayor cantidad de pozos de extracción, lo que beneficia el análisis para el logro de un mayor ajuste vertical, puesto que la RNA puede afinar mejor los procesos de descarga. Mientras que, los ajustes en la región oeste del AON alcanzan los valores más altos (entre -12 y 18 m). En general, esta zona mostró los mayores desajustes en la mayoría de las fechas simuladas, lo cual indica áreas donde la RNA podría mejorar su representación de la dinámica del acuífero. Tales discrepancias, aunque menores en comparación con los ajustes generales que mostró el desempeño de la RNA al realizar las estimaciones de la descarga, sugieren la necesidad de continuar afinando el modelo para capturar mejor las complejidades hidrológicas, especialmente, en lo referente a la recarga.

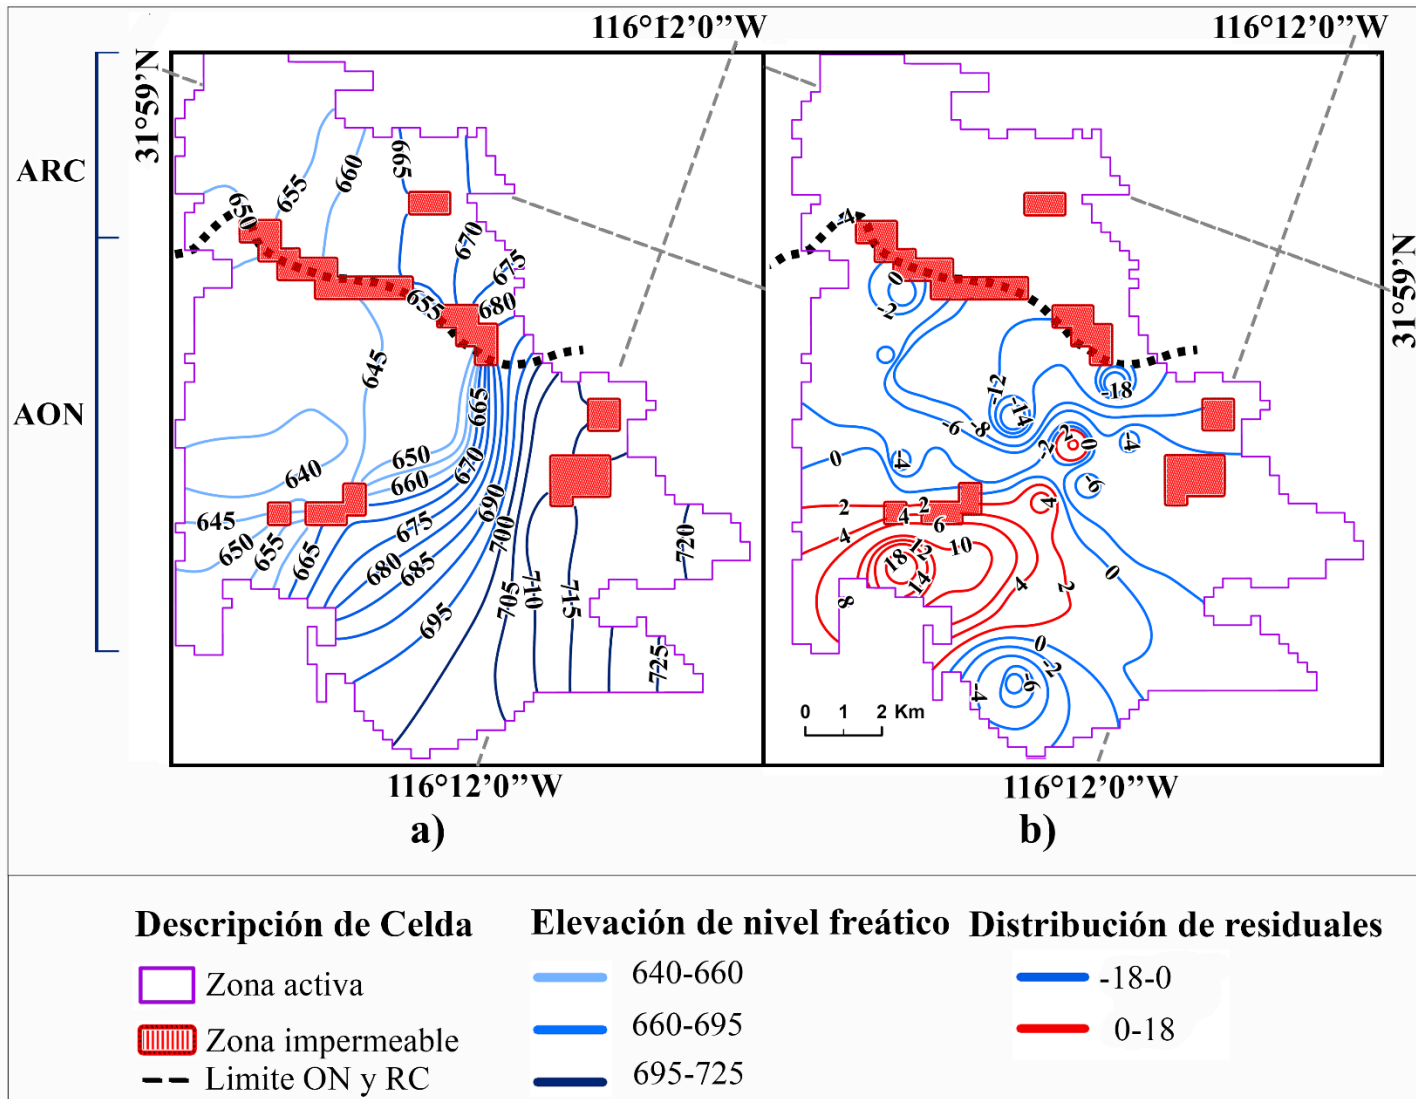


Figura 46. Registro del NF (a) y mapa de residuales (b) para Noviembre de 2017

V. ESTIMACIÓN DEL BOMBEO ANUAL DETERMINADO POR LA RNA

Las descargas estimadas por la RNA (en Mm³/año) oscilan entre 36 y 54 Mm³/año, con un promedio de 45 Mm³/año. La estimación más baja se registró en Julio de 1989; mientras que, la más alta ocurrió en Noviembre de 2011 (Tabla 34). Este último año se encuentra dentro de un período en el cual la RNA estima una fuerte explotación en los AVON, correspondiente a los años 2008-2012. Durante este período, en 2010 se registró una descarga de 45 Mm³/año, la más baja en esos 4 años. Cabe mencionar que también se registró una precipitación por encima de la media (aproximadamente 500 mm), lo que probablemente contribuyó a la disminución de la explotación durante ese año. A pesar de que en 2011 hubo un registro por encima de la media (aproximadamente 270 mm), este año no se observó ninguna disminución de la descarga (de hecho, tal como se comenta arriba, se observó la descarga estimada más alta del periodo de análisis), lo cual revela la fuerte explotación que se registra en ambos acuíferos (Tabla 34).

Por otra parte, la RNA estimó para el año 2013 una descarga menor a la reportada. A partir de esta fecha, se puede percibir una tendencia de disminución en la descarga, probablemente influenciada por la reducción en los NF.

Tabla 34. Registro de la descarga estimada por la RNA (m³/año)

Número	Período analizado	Descarga (m ³ /año)		
		Reportada	Estimada	Diferencia entre ambas (%)
1	1989	30,116,888	36,881,895	-22.46
2	1995	46,327,606	46,982,354	-1.41
3	1997	46,327,606	46,952,876	-1.35
4	1999	46,327,606	43,538,670	6.02
5	2004	46,327,606	48,991,117	-5.75
6	2007	46,327,606	43,748,373	5.57
7	2008	46,327,606	52,478,627	-13.28
8	2009	46,327,606	50,228,443	-8.42
10	2010	46,327,606	45,702,860	1.35
12	2011	46,327,606	54,088,493	-16.75
13	2012	46,327,606	52,110,632	-12.48
14	2013	46,327,606	42,604,006	8.04
15	2014	46,327,606	42,736,103	7.75
16	2015	46,327,606	41,281,117	10.89
17	2016	46,327,606	40,449,779	12.69
18	2017	46,327,606	42,763,034	7.69
	Promedio	45,314,436	45,460,419	

En términos generales, la RNA estimó valores de la descarga anual similares a las reportadas. Aun así, se puede resaltar como uno de los aportes significativos derivados de esta investigación, que el modelo neuronal realizó una redistribución espacial de la descarga estimada hacia áreas que experimentan una mayor explotación o demanda de agua. La explotación del agua subterránea ha tenido un impacto considerable en las zonas central y sur del AON, así como las áreas central y norte del ARC, para las cuales, la RNA estimó un aumento en la descarga de los pozos que en ellas se ubican. En ambos acuíferos, la RNA logró redistribuir la descarga hacia las zonas registradas con una fuerte explotación.

Un análisis de los valores de la descarga estimada por la RNA sugiere una disminución en la descarga anual en ambos acuíferos a partir de 2013. Por ejemplo, en el ARC se presenta una disminución en los pozos ubicados principalmente en la parte sur de acuífero; cuya disminución puede estar relacionada con el abatimiento del NF, lo que ha provocado que algunos pozos se sequen o sean poco accesible profundizar hasta el NF.

V.1. Mejoras en el modelo de flujo con la implementación de la RNA

El mejor ajuste vertical entre los NF calculados (con MODFLOW + Descarga estimada por la RNA) y observados se presentó en Julio de 1989, donde se obtuvo un 59 y 36 % de mejora en el AON y el ARC, respectivamente; lo anterior, con respecto al ajuste generado con el modelado numérico del flujo con MODFLOW sin considerar la descarga estimada por la RNA. A partir de estas fechas las mejoras oscilaron entre 22 y 42% con promedio de 32% para el AON; mientras que, para el ARC oscilaron entre el 27 y 31% con un promedio de 29% (Tabla 35). En general, considerar la descarga estimada por la RNA en el modelado numérico con MODFLOW ayuda a reducir de manera consistente los errores de ajuste vertical.

A pesar de estos logros, se identifican algunos aspectos que podrían ser optimizados. Por ejemplo, a partir de Julio de 1989, no fue posible obtener un mejor ajuste que se reflejara en un aumento en el porcentaje de mejora con respecto la estimación del NF. La precisión en dicha fecha puede estar vinculada a dos factores que contribuyen a mejores estimaciones de la descarga por la RNA: 1) el registro del NF concuerda con el punto de descarga, 2) el registro del NF se reportó durante un período de funcionamiento de los pozos (mayo a octubre). Aunque esta combinación de factores no se repitió por completo en otros períodos, los resultados obtenidos demuestran que optimizar la densidad de datos y la continuidad de los registros del NF podría impulsar aún más la precisión del modelo en el futuro.

Los registros del NF que coinciden con las fechas en que los pozos de descarga están en operación (uno de los factores que mejora las estimaciones de la RNA) son: Mayo de 2009, Agosto de 2013 y Mayo de 2017. De estas fechas, destacamos Mayo de 2009 para ON y Agosto de 2013 para RC; las cuales, corresponden al segundo mejor ajuste para ON y el cuarto mejor ajuste para RC, con una mejora del 34% y 27%, respectivamente. Para Mayo de 2017 en ON, se observó un 27% de mejora, manteniéndose dentro de los niveles más altos de ajuste. Puesto que, en general, todas las fechas mantuvieron porcentajes de mejora por encima del 20%.

A pesar de que las fechas mencionadas anteriormente coinciden con un registro de los pozos en operación, no fue posible obtener mejoras mayores al 34% en ON y al 31% en RC. Esto podría estar vinculado a factores como la metodología de interpolación aplicada en las fechas correspondientes al caso 2. Puesto que, la precisión de la RNA para estimar la descarga en

los puntos en los cuales se tiene registro del NF asignado por el proceso de interpolación, muestran valores del RMSE inferiores a los obtenidos con los registros reportados (Figuras 37, 41 y 45). Esto indica que la RNA es más precisa cuando se estima la descarga en el mismo punto donde se tiene registro del NF. Aún con estas limitaciones, la RNA superó consistentemente las estimaciones realizadas con el modelo de MODFLOW (sin considerar la descarga estimada).

Tabla 35. Error de ajuste vertical en el modelado. Nota: El símbolo “-” representa ausencia de datos

Número	Acuífero	Ojos Negros (RMSE en m)			Real del Castillo (RMSE en m)			Mejora en (%)	
	Modelo	Campos-Gaytán (2002)	MODFLOW sin Descarga estimada Actualización del modelo	MODFLOW + Descarga estimada por RNA	Campos-Gaytán (2002)	MODFLOW sin Descarga estimada Actualización del modelo	MODFLOW + Descarga estimada por RNA	AON	ARC
	Período analizado								
1	Julio de 1989	2.74	4.98	2.03	4.56	2.87	1.81	59.24	36.93
2	Noviembre de 1995	4.92	4.42	2.53	-	-	-	42.76	-
3	Febrero de 1997	6.51	5.15	3.54	-	-	-	31.26	-
4	Febrero de 1999	-	-	-	4.34	2.05	1.43	-	30.24
5	Abril del 2005	-	-	-	-	6.51	4.73	-	27.34
6	Diciembre del 2007	-	-	-	-	5.88	4.38	-	25.51
7	Noviembre de 2008	-	7.6	5.26	-	-	-	30.79	-
8	Mayo del 2009	-	8.85	5.80	-	-	-	34.46	-
9	Noviembre del 2009	-	8.64	6.04	-	6.72	4.63	30.09	31.10
10	Abril del 2010	-	8.86	6.65	-	-	-	24.94	-
11	Noviembre del 2010	-	8.22	5.87	-	-	-	28.59	-
12	Abril del 2011	-	8.83	6.67	-	-	-	24.46	-
13	Noviembre del 2011	-	8.74	6.04	-	-	-	30.89	-
14	Abril del 2012	-	8.94	6.72	-	-	-	24.83	-
15	Noviembre del 2012	-	8.93	6.08	-	-	-	31.91	-
16	Abril del 2013	-	9.3	7.09	-	-	-	23.76	-
17	Agosto del 2013	-	-	-	-	7.34	5.32	-	27.52
18	Noviembre del 2013	-	9.12	6.34	-	-	-	30.48	-
19	Abril del 2014	-	9.76	7.09	-	-	-	27.36	-
20	Noviembre del 2014	-	9.86	7.68	-	-	-	22.11	-
21	Abril del 2015	-	10.95	8.38	-	-	-	23.47	-
22	Noviembre del 2015	-	9.84	7.38	-	-	-	25.00	-
23	Abril del 2016	-	13.55	10.3	-	-	-	23.99	-
24	Noviembre del 2016	-	11.66	8.15	-	-	-	30.10	-
25	Mayo del 2017	-	13.44	9.79	-	-	-	27.16	-
26	Noviembre del 2017	-	13.36	9.98	-	-	-	25.30	-
27	Abril del 2018	-	15.03	11.69	-	-	-	22.22	-
	Promedio	4.72	9.48	6.83	4.45	5.23	3.72	29.36	29.78

VI. CONCLUSIONES

En este trabajo se estimó el bombeo de agua subterránea en los AVON y se analizó la relación entre los registros de NDVI, para ello, se diseñaron e implementaron un modelo numérico del flujo de agua subterránea en MODFLOW y un modelo de RNA en MATLAB. Mientras que, los registros de NDVI se analizaron mediante el procesamiento de las imágenes satelitales de las misiones Landsat 8 OLI/TIRS, Landsat 7 ETM y Landsat 4-5 TM utilizando el software ArcGIS Pro

- Se desarrolló un modelo numérico del flujo de agua subterránea basado en modelos conceptuales previos, introduciendo como mejora un refinamiento espacial en la rejilla mediante una discretización de celdas de 250m x 250m. Este ajuste permitió una mayor precisión en la definición de los límites de los acuíferos ON y RC, abarcando un total de 2,562 celdas (160.12 km²), lo que representa un área ligeramente menor de alrededor de 7.18% en comparación con la reportada previamente de aproximadamente 172.5 km². Este refinamiento espacial contribuyó a mejorar los ajustes verticales entre las elevaciones del nivel freático (NF) calculadas y observadas. Posteriormente, haciendo uso de la técnica de prueba y error, se realizaron las etapas de calibración y validación del modelo numérico, ajustando los parámetros que representan las propiedades del acuífero, en particular, conductividad hidráulica. Los resultados obtenidos derivados de la calibración del modelo sin incluir los ajustes de la RNA para 27 fechas de modelación mostraron un RMSE promedio de 9.48 y 5.23 m para el AON y el ARC, respectivamente. Además, dicho modelo numérico produce un ajuste vertical entre las elevaciones del NF, calculadas y observadas, menor que aquellos construidos previamente. Se alcanzaron ajustes verticales con una mejora del 59 y 43% para los años 1989 y 1995 en el AON, con respecto a los reportados por Campos-Gaytán (2002); mientras que, para el ARC, la mejora observada es de 37 y 30% para los años 1989 y 1999, respectivamente.
- El análisis del comportamiento promedio y la tendencia a largo plazo (durante el período 2005-2018) del Índice de Vegetación de Diferencia Normalizada (NDVI), como indicador del vigor vegetativo en una región árida. Se encontró que el NDVI refleja la respuesta de la vegetación a los cambios estacionales, siendo más vigorosa

durante las temporadas húmedas, en contraste con las temporadas secas. Además, se observó una relación entre el NDVI de los cultivos y la elevación del NF, siendo este último una importante fuente de abastecimiento de agua para mantener el vigor de los cultivos durante las temporadas secas con valores de NDVI que oscilan entre 0.5 y 0.8. Por lo cual, se podría considerar como un indicador indirecto de la explotación de los acuíferos para mantener dicho vigor en los cultivos. Otro hallazgo, se presenta en la disminución a largo plazo en la vigorosidad de la vegetación y reducción en las áreas verdes podría estar asociada con una disminución progresiva en los eventos de precipitación lo que indica posibles cambios ambientales destacando la importancia de monitorear y gestionar de manera sostenible los ecosistemas áridos.

- La implementación de la RNA, usando los datos generados para el modelo sintético de un acuífero libre con registros diarios, sugieren que el modelo neuronal desarrollado es adaptable a otras periodicidades para hacer estimaciones de la descarga. Validando la aplicación de la RNA a entornos con variaciones en su configuración y disponibilidad de datos.
- Por su parte, la implementación de la descarga estimada por la RNA en el modelado numérico con MODFLOW (considerando un promedio de $45 \text{ Mm}^3/\text{año}$ para los AVON) produce una mejora del 29% en el ajuste vertical entre las elevaciones del NF calculadas y observadas en los AVON en comparación con el modelo sin dicha estimación; empleando registros con periodicidad mensual y estimando la descarga para el periodo completo de simulación (1989-2017) con alrededor de 45 Mm^3 al año un aumento del 0.32% en comparación con los valores reportados. El mayor ajuste vertical se observó en julio de 1989, con una mejora del 59% en el acuífero ON y del 36% en el acuífero RC. Posteriormente, las mejoras para ON oscilaron entre el 22% y el 42%, con un promedio del 29%, mientras que para RC variaron entre el 27% y el 31%, con un promedio del 29%. Además, este régimen de descargas mejoró el ajuste de las elevaciones del NF calculadas con las observadas, si se compara con los resultados obtenidos del modelado numérico previo donde se contemplan los bombeos reportados (tal como Campos-Gaytán, 2002). Estos resultados demuestran que la integración de las descargas estimadas por la RNA optimiza el ajuste vertical del modelo numérico respecto a las elevaciones del NF. Además, de una

subestimación en la descarga por el encima del 10% durante los años 1989,2008, 2011 y 2012 en comparación con los registros oficiales. Mientras que se presentó una sobrestimación por encima del 5% durante los años 1999, 2007, 2013, 2014, 2015, 2016 y 2017.

- Un hallazgo clave de esta investigación es la capacidad de la RNA para estimar y redistribuir la descarga, logrando un mayor ajuste vertical en las áreas más afectadas por la explotación y donde se observa un mayor abatimiento del NF en los AVON. Aunque se observaron aumentos del 22% y disminuciones del 13% en la descarga estimada por año para los AVON, el cambio más significativo ocurrió en la distribución de dicha descarga en las zonas central y sur de ON, donde la explotación del agua subterránea ha tenido un impacto considerable con aumentos en el volumen de extracción que oscilan entre 37 y 627% para los pozos P-2, P-8, P-12, P-16, P-18, P-24, P-30, P-31, P-37 y P-39. Por otro lado, en RC, las áreas centro y norte resultaron ser las más afectadas por la explotación con aumentos del orden de 5 y 96% en los pozos P-62, P-63, P-66, P-67, P-70, P-82 y P-155.
- Con base en los resultados de este trabajo, se destacó la capacidad de la RNA para lograr mejores estimaciones de la descarga, particularmente, cuando se consideran dos factores clave: 1) la coincidencia entre el registro del NF y el punto de descarga, y 2) el reporte del NF durante el período de funcionamiento de los pozos (Mayo a Octubre). Estos factores fueron determinantes para maximizar la exactitud del modelo y destacan la importancia de un adecuado monitoreo en futuros trabajos.

De manera general, la estimación del bombeo de agua subterránea mediante la RNA ofrece una valiosa contribución al entendimiento y gestión de los recursos hídricos subterráneos. Los resultados revelan la capacidad de la RNA para estimar la extracción de agua subterránea de los acuíferos, un aspecto notoriamente complejo de estimar, y su flexibilidad de adaptarse a diferentes condiciones hidrológicas y de demanda. Los resultados sugieren que la RNA puede redistribuir eficazmente los flujos hacia áreas de mayor demanda. Esta capacidad se evidencia especialmente en períodos de alta explotación, como el observado durante los años 2008-2012, donde la RNA registró una fuerte explotación en los acuíferos.

Este enfoque no solo ha reducido el error en las estimaciones de los registros del NF en el modelo de flujo, sino que también ofrece un modelo aplicable a otras regiones. Así, este trabajo resalta la importancia de combinar modelos de flujo con RNA para enfrentar desafíos complejos en la gestión de recursos hídricos para las comunidades locales y el medio ambiente, promoviendo decisiones más informadas y sostenibles en la gestión de recursos hídricos.

VII. LITERATURA CITADA

- Aguilar, A. R., Moreno, R. S., Miranda, L., & Bustamante, W. O. (2021). Algoritmo ADAM en la inteligencia artificial. Paper presented at the Sexto Congreso Nacional de Riego, Drenaje y Biosistemas, Hermosillo, Sonora: Universidad de Sonora.
- Aguilar, C., Zinnert, J. C., Polo, M. J., & Young, D. R. (2012). NDVI as an indicator for changes in water availability to woody vegetation. *Ecological Indicators*, 23, 290-300. doi:<https://doi.org/10.1016/j.ecolind.2012.04.008>
- Al-Salamah, I. S., Ghazaw, Y. M., & Ghumman, A. R. (2011). Groundwater modeling of Saq Aquifer Buraydah Al Qassim for better water management strategies. *Environmental Monitoring and Assessment*, 173(1), 851-860. doi:10.1007/s10661-010-14281
- Anderson, M.P. and Woessner, W.W. (1992) *Applied Groundwater Modeling— Simulation of Flow and Advection Transport*. Academic Press, Inc., San Diego, CA, 381 p.
- Anderson, M. P., Woessner, W. W., & Hunt, R. J. (2015). *Applied groundwater modeling*, 2nd Edition (2 ed.): Academic Press.
- Aggarwal, C. (2018). *Neural Networks and Deep Learning: A Textbook*.
- Aggarwal, Y., Karan, B. M., Das, B. N., Aggarwal, T., & Sinha, R. K. (2007). Backpropagation ANN-Based Prediction of Exertional Heat Illness. *Journal of Medical Systems*, 31(6), 547-550. doi:10.1007/s10916-007-9097-5
- Ahmad, M.-u.-D., Bastiaanssen, W. G. M., & Feddes, R. A. (2005). A new technique to estimate net groundwater use across large irrigated areas by combining remote sensing and water balance approaches, Rechna Doab, Pakistan. *Hydrogeology Journal*, 13(5), 653-664. doi:10.1007/s10040-004-0394-5
- Aichouri, I., Hani, A., Bougherira, N., Djabri, L., Chaffai, H., & Lallahem, S. J. E. P. (2015). River flow model using artificial neural networks. 74, 1007-1014.
- Al-Faiz, M., Ibrahim, A., & Hadi, S. (2019). The effect of Z-Score standardization (normalization) on binary input due the speed of learning in back-propagation neural network. *Iraqi Journal of Information & Communications Technology*, 1, 42-48. doi:10.31987/ijict.1.3.41
- Apaydin, A. (2009). Response of groundwater to climate variation: fluctuations of groundwater level and well yields in the Halaclicaquifer (Cankiri, Turkey). *Environmental Monitoring and Assessment* 165, 653–663.
- Austin, C. (2014). Reactions: Legislators and organizations respond to the passage of groundwater legislation. Retrieved from <https://mavensnotebook.com/2014/08/30/reactions-legislators-and-organizations-respond-to-the-passage-of-groundwater-legislation/>
- Ayibotele, N. B. (1992). The World's Water: Assessing the Resource. *Paper presented at the International Conference on Water and the Environment: Development Issues for the 21st Century*, 26-31.
- Bear, J. (2013). *Dynamics of fluids in porous media*: Courier Corporation.
- Belmonte, A. C., Jochum, A. M., García, A. C., Rodríguez, A. M., & Fuster, P. L. (2005). Irrigation management from space: Towards user-friendly products. *Irrigation and Drainage Systems*, 19(3), 337-353. doi:10.1007/s10795-005-5197-x
- Beltrán L. (1997). Actualización Hidrogeológica del Valle Ojos Negros, Baja California. In. Ensenada, México: Comisión Nacional del Agua (CONAGUA). Gerencia Regional de la Península de Baja California. Subgerencia Técnica Regional.
- Berry, M. W., Mohamed, A., & Yap, B. W. (2019). *Supervised and unsupervised learning for data science*: Springer.
- Bhavani, P., Chakravarthi, V., P.S. Roy, P.K. Joshi, Chandrasekar, K.. Long-term agricultural performance and climate variability for drought assessment: a regional study from Telangana and Andhra Pradesh states, India. *Geomatics, Natural Hazards and Risk*, 8(2), 822-840. doi:10.1080/19475705.2016.1271831
- Campos Gaytán, J. R. (2002). Actualización del modelo geohidrológico del acuífero del Valle de Ojos Negros, Baja California. (Maestro), Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California, Retrieved from <http://biblioteca.cicese.mx/catalogos/tesis/ficha.php?id=15044> Available from Biblioteca del CICESE Pelicano database.
- Campos Gaytán, J. R. (2008). *Simulación del flujo de agua subterránea en el acuífero del Valle de Guadalupe, Baja California, México*. (Doctor), Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California, Retrieved from

- <http://biblioteca.cicese.mx/catalogos/tesis/ficha.php?id=17841> Available from Biblioteca del CICESE Pelicano database.
- Castañón, S., Sanz, D., & Gómez-Alday, J. J. (2010). Methodology for Quantifying Groundwater Abstractions for Agriculture via Remote Sensing and GIS. *Water Resources Management*, 24(4), 795-814. doi:10.1007/s11269-009-9473-7
- Cruz-Falcón, A., Vázquez-González, R., Ramírez-Hernández, J., Nava-Sánchez, E. H., Troyo-Diéguéz, E., Rivera-Rosas, J., & Vega-Mayagoitia, J. J. U. y. c. (2011). Precipitación y recarga en la cuenca de La Paz, BCS, México. 27(3), 251-263.
- Coppola, E., Szidarovszky, F., Poulton, M., Charles, E. (2003). Artificial neural network approach for predicting transient water levels in a multilayered groundwater system under variable state, pumping, and climate conditions. *J. Hydrol. Eng. ASCE* 8 (6), 348–360.
- Chang, F.-J., Huang, C.-W., Cheng, S.-T., & Chang, L.-C. (2017). Conservation of groundwater from over-exploitation—Scientific analyses for groundwater resources management. *Science of The Total Environment*, 598, 828-838. doi:<https://doi.org/10.1016/j.scitotenv.2017.04.142>
- Ciaburro, G., & Venkateswaran, B. (2017). *Neural networks with R : smart models using CNN, RNN, deep learning, and artificial intelligence principles*. In. Retrieved from <https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=1607842>
- Comisión Nacional del Agua (CONAGUA). (1997). Actualización Hidrogeológica del Valle Ojos Negros, Baja California. Ensenada, México. Gerencia Regional de la Península de Baja California, Subgerencia Técnica Regional
- Comisión Nacional del Agua. (2009). Determinación de la disponibilidad de agua en el acuífero Ojos Negros, Estado de Baja California. Reporte técnico.
- Comisión Nacional del Agua. (2013). Red De Monitoreo Piezométrico Acuífero Real Del Castillo. Ensenada Baja California. Reporte técnico.
- CONAGUA. (2018). Estadísticas del Agua en México (18 ed.). Ciudad de México. <https://files.conagua.gob.mx/conagua/publicaciones/Publicaciones/EAM2018.pdf>
- COTAS. (2017). *Actualización de la red de monitoreo piezométrica del acuífero 0208 Ojos Negros*. Comisión Nacional del Agua (CONAGUA): Valle de Ojos Negros, Municipio de Ensenada Baja California
- Darcy, H. (1856). *Les fontaines publiques de la ville de Dijon*.
- Del Brio, B.M. & Sanz A. (2001). *Redes neuronales y sistemas borrosos*. Editores Madrid Ra-Ma. Espana. ISBN: 84-7897-466-0
- Domenico, P. A., & Schwartz, F. W. (1997). *Physical and chemical hydrogeology*: John wiley & sons.
- Eesa, A., & Arabo, W. (2017). A Normalization Methods for Backpropagation: A Comparative Study. *Science Journal of University of Zakho*, 5, 319. doi:10.25271/2017.5.4.381
- Du, J., Shu, J., Yin, J., Yuan, X., Jiaerheng, A., Xiong, S., . . . Liu, W. (2015). Analysis on spatio-temporal trends and drivers in vegetation growth during recent decades in Xinjiang, China. *International Journal of Applied Earth Observation and Geoinformation*, 38, 216-228. doi:<https://doi.org/10.1016/j.jag.2015.01.006>
- Du, K.-L., Leung, C.-S., Mow, W. H., & Swamy, M. N. S. (2022). Perceptron: Learning, Generalization, Model Selection, Fault Tolerance, and Role in the Deep Learning Era. *10(24)*, 4730.
- Du, K. L., & Swamy, M. N. S. (2013). *Neural Networks and Statistical Learning*: Springer London.
- Eesa, A., & Arabo, W. (2017). A Normalization Methods for Backpropagation: A Comparative Study. *Science Journal of University of Zakho*, 5, 319. doi:10.25271/2017.5.4.381
- Emamgholizadeh, S., Moslemi, K., & Karami, G. (2014). Prediction the Groundwater Level of Bastam Plain (Iran) by Artificial Neural Network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS). *Water Resources Management*, 28(15), 5433-5446. doi:10.1007/s11269-014-0810-0
- Ercan, S. (1999). Sustainable Management of Water Resources in the Ojos Negros Valley, Baja California. (Master's Thesis), San Diego State University, San Diego, California.
- Escolero-Fuentes, O. A., & Hernández-Rosas, M. T. (1992). *Manejo conjunto en el Valle de Guadalupe, B.C., como una estrategia apropiada para el uso eficiente del agua en zonas áridas*. Comisión Internacional de riesgo y drenaje. Tercera Conferencia Panamericana de Riesgo y Drenaje: Modernización de los distritos de riego. Mazatlán, Sinaloa. November, 1992. 12 pp.
- Famiglietti, J. S., Lo, M., Ho, S. L., Bethune, J., Anderson, K. J., Syed, T. H., . . . Rodell, M. . (2011). Satellites measure recent rates of groundwater depletion in California's Central Valley. . *Geophysical Research Letters*, 38. doi:10.1029/2010GL046442

- Fan, X., Guan, Y., Bai, Z., Zhou, W., & Zhu, C. (2022). Optimization of Reclamation Measures in a Mining Area by Analysis of Variations in Soil Nutrient Grades under Different Types of Land Usage—A Case Study of Pingshuo Coal Mine, China. *Land*, 11(3). doi:10.3390/land11030321
- FAO. (2017). Escasez de agua: Uno de los grandes retos de nuestro tiempo. Retrieved 8 de Octubre de 2020, from www.fao.org http://www.fao.org/zhc/detail-events/es/c/880888/
- Fausett, L. (1994). *Fundamentals of neural networks*. Englewood Cliffs: Prentice Hall.
- Fetter, C. W. (2018). *Applied hydrogeology*: Waveland Press.
- Fetter, C. (2001). *Applied Hydrogeology*. Oshkosh: Pearson.
- Figuroa, A. (2018). Modelo De Simulación - Optimización Del Acuífero Del Valle De Guadalupe, Ensenada, Baja California. Tesis Doctorado. Universidad Autónoma De Baja California, ENSENADA B. C.
- Freyberg, D. L. (1988). AN EXERCISE IN GROUND-WATER MODEL CALIBRATION AND PREDICTION. 26(3), 350-360. doi:https://doi.org/10.1111/j.1745-6584.1988.tb00399.x
- Gao, Z., Shi, Q., Fukuda, T., Li, C., & Huang, Q. J. N. (2019). An overview of biomimetic robots with animal behaviors. 332, 339-350.
- García, E. 1981. Modificaciones al sistema de clasificación climática de Köppen. Instituto de Geografía, UNAM. México, D.F 244.
- Gasmi, A., Gomez, C., Lagacherie, P., Zouari, H., Laamrani, A., & Chehbouni, A. (2021). Mean spectral reflectance from bare soil pixels along a Landsat-TM time series to increase both the prediction accuracy of soil clay content and mapping coverage. *Geoderma*, 388, 114864. doi:https://doi.org/10.1016/j.geoderma.2020.114864
- Gastil, R. G., Phillips, R. P., & Allison, E. C. (1975). Reconnaissance Geology of the State of Baja California. In R. G. Gastil, R. P. Phillips, & E. C. Allison (Eds.), *Reconnaissance Geology of the State of Baja California* (Vol. 140, pp. 0): Geological Society of America.
- Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*: " O'Reilly Media, Inc."
- Giordano, M. (2006). Agricultural groundwater use and rural livelihoods in sub-Saharan Africa: A first-cut assessment. *Hydrogeology Journal*, 14(3), 310-318. doi:10.1007/s10040-005-0479-9
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*: MIT press., ISBN-10, 0262035618. 19(1), 305-307
- Gossel, W. (2013). GIS-MODFLOW: Ein kleines OpenSource-Werkzeug zur Anbindung von GIS-Daten an MODFLOW. *Grundwasser*, 18(2), 99-102. doi:10.1007/s00767-012-0218-9
- Goyal, M., Goyal, R., Venkatappa Reddy, P., & Lall, B. (2020). Activation Functions. In W. Pedrycz & S.-M. Chen (Eds.), *Deep Learning: Algorithms and Applications* (pp. 1-30). Cham: Springer International Publishing.
- Güldal, V., & Tongal, H. (2010). Comparison of Recurrent Neural Network, Adaptive Neuro-Fuzzy Inference System and Stochastic Models in Eğirdir Lake Level Forecasting. *Water Resources Management*, 24(1), 105-128. doi:10.1007/s11269-009-9439-9
- Hagan, M. T., Demuth, H. B., Beale, M. H., & De Jesús, O. (2014). *Neural Network Design*: Martin Hagan.
- Harbaugh, A. W. (2005). MODFLOW-2005 : the U.S. Geological Survey modular ground-water model--the ground-water flow process (6-A16). Retrieved from https://pubs.usgs.gov/publication/tm6A16
- Harris, M. A., & Diehl, T. H. (2017). A Comparison of Three Federal Datasets for Thermoelectric Water Withdrawals in the United States for 2010. *JAWRA Journal of the American Water Resources Association*, 53(5), 1062-1080. doi:https://doi.org/10.1111/1752-1688.12551
- Hera-Portillo, Á. D., López-Gutiérrez, J., Mayor, B., López-Gunn, E., Henriksen, H. J., Gejl, R. N., . . . Martínez-Santos, P. (2021). An Initial Framework for Understanding the Resilience of Aquifers to Groundwater Pumping. *Water*, 13(4). doi:10.3390/w13040519
- Hernández-Juárez, R. A., Martínez Rivera, L. M., Peñuela-Arévalo, L. A., & Rivera-Reyes, S. J. I. g. (2020). Identificación de zonas potenciales de recarga y descarga de agua subterránea en la cuenca del río Ayuquila-Armería mediante el uso de SIG y el análisis multicriterio. (101).
- Hornik, K., Sttnchcombe, M. y White, H. (1989): "Multilayer feedforward networks are universal approximators". *Neural Networks*, 2, pp. 359-366.
- Hosseini, S. M., Parizi, E., Ataie-Ashtiani, B., & Simmons, C. T. (2019). Assessment of sustainable groundwater resources management using integrated environmental index: Case studies across Iran. *Sci Total Environ*, 676, 792-810. doi:10.1016/j.scitotenv.2019.04.257
- Hurr, R. T., & Litke, D. W. (1989). *Estimating pumping time and ground-water withdrawals using energy-consumption data* (89-4107). Retrieved from http://pubs.er.usgs.gov/publication/wri894107

- Ichii, K., Kawabata, A., & Yamaguchi, Y. (2002). Global correlation analysis for NDVI and climatic variables and NDVI trends: 1982-1990. *International Journal of Remote Sensing*, 23(18), 3873-3878. doi:10.1080/01431160110119416
- INEGI. (1974). Carta Topografica. H11B13. Real del Castillo Nuevo, Baja California. Retrieved from https://www.inegi.org.mx/contenidos/productos/prod_serv/contenidos/espanol/bvinegi/productos/geografia/imagen_cartografica/1_50_000/702825666156.pdf
- INEGI. (1977). Carta geológica Real del Castillo Nuevo, Baja California (H11B13). Retrieved from https://www.inegi.org.mx/contenidos/productos/prod_serv/contenidos/espanol/bvinegi/productos/geografia/tematicas/Geologia_hist/702825647469.pdf
- INEGI. (2017). Anuario estadístico y geográfico de Baja California 2017. Baja California, México. Retrieved from https://www.inegi.org.mx/contenido/productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_eestruc/anuarios_2017/702825094874.pdf
- Isasi, P. & Galván I.M. (2004). *Redes Neuronales Artificiales. Un Enfoque Práctico*. Pearson Educación. ISBN 84-205-4025-0
- Izaurieta, F., & Saavedra, C. J., Universidad de Concepción Chile. (2000). *Redes neuronales artificiales*.
- Jang, C.-S., Chen, C.-F., Liang, C.-P., & Chen, J.-S. (2016). Combining groundwater quality analysis and a numerical flow simulation for spatially establishing utilization strategies for groundwater and surface water in the Pingtung Plain. *Journal of Hydrology*, 533, 541-556. doi:<https://doi.org/10.1016/j.jhydrol.2015.12.023>
- Jang, C.-S., Liu, C.-W., & Chou, Y.-L. (2012). Assessment of groundwater emergency utilization in Taipei Basin during drought. *Journal of Hydrology*, 414-415, 405-412. doi:<https://doi.org/10.1016/j.jhydrol.2011.11.016>
- Jeong, J., Park, E., Shik Han, W., Kim, K.-Y., Suk, H., & Beom Jo, S. (2018). A generalized groundwater fluctuation model based on precipitation for estimating water table levels of deep unconfined aquifers. *Journal of Hydrology*, 562, 749-757. doi:<https://doi.org/10.1016/j.jhydrol.2018.05.055>
- Javed, F., Gilani, S. O., Latif, S., Waris, A., Jamil, M., & Waqas, A. J. J. o. p. m. (2021). Predicting risk of antenatal depression and anxiety using multi-layer perceptrons and support vector machines. *11*(3), 199.
- Jia, S., Zhang, T., Cheng, X., Liu, H., & Xu, B. (2021). Neuronal-Plasticity and Reward-Propagation Improved Recurrent Spiking Neural Networks. *15*. doi:10.3389/fnins.2021.654786
- Jiang, L., Guli-Jiapaer, Bao, A., Guo, H., & Ndayisaba, F. (2017). Vegetation dynamics and responses to climate change and human activities in Central Asia. *Science of The Total Environment*, 599-600, 967-980. doi:<https://doi.org/10.1016/j.scitotenv.2017.05.012>
- Joodaki, G., Wahr, J., & Swenson, S. (2014). Estimating the human contribution to groundwater depletion in the Middle East, from GRACE data, land surface models, and well observations. *Water Resources Research*, 50(3), 2679-2692. doi:<https://doi.org/10.1002/2013WR014633>
- Kang, T., & Banerjee, A. (2017). Learning Feedforward and Recurrent Deterministic Spiking Neuron Network Feedback Controllers.
- Kent, C. R., Pandey, S., Turner, N., Dickinson, C. G., & Jamieson, M. (2020). Estimating current and historical groundwater abstraction from the Great Artesian Basin and other regional-scale aquifers in Queensland, Australia. *Hydrogeology Journal*, 28(1), 393-412. doi:10.1007/s10040-019-02074-0
- Kim, N. W., Chung, I. M., Won, Y. S., & Arnold, J. G. (2008). Development and application of the integrated SWAT-MODFLOW model. *Journal of Hydrology*, 356(1), 1-16. doi:<https://doi.org/10.1016/j.jhydrol.2008.02.024>
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980
- Kohonen, T. (1988). An introduction to Neural Computing. *Neural Networks*. Vol. 1. Pp 3-16
- Konikow, L. F., & Neuzil, C. E. (2007). A method to estimate groundwater depletion from confining layers. *Water Resources Research*, 43. doi:10.1029/2006WR005597
- Kresic, N. (1997). *Quantitative solutions in hydrogeology and groundwater modeling*.
- Kundzewicz, Z. W., & DÖLI, P. (2009). Will groundwater ease freshwater stress under climate change? *Hydrological Sciences Journal*, 54(4), 665-675. doi:10.1623/hysj.54.4.665
- Kuzevic, S., Bobikova, D., & Kuzevicova, Z. (2022). Land Cover and Vegetation Coverage Changes in the Mining Area—A Case Study from Slovakia. *Sustainability*, 14(3). doi:10.3390/su14031180

- Lee, J., & Kim, I. (2022). Long-term stagnation monitoring using machine learning: comparison of artificial neural network model and convolution neural network model. *Water Resources Management*, 36(7), 2117-2130. doi:10.1007/s11269-022-03120-5
- Leake, S. A. (1997). Modeling Ground-Water Flow with MODFLOW and Related Programs (121-97). Retrieved from <https://pubs.usgs.gov/publication/fs12197>
- Li, D., Hu, L., Zhang, M., & Liu, X. (2019). Evaluation of groundwater withdrawals in Tongzhou District, Beijing, China. *Human and Ecological Risk Assessment: An International Journal*, 1-17. doi:10.1080/10807039.2019.1604117
- Liu, H.-J., Hsu, N.-S., & Yeh, W. W. G. (2015). Independent component analysis for characterization and quantification of regional groundwater pumping. *Journal of Hydrology*, 527, 505-516. doi:<https://doi.org/10.1016/j.jhydrol.2015.05.013>
- López, A. (2014). Calibración de un Modelo de Flujo del Acuífero de la Zona Metropolitana de la Ciudad de México. Facultad de Ingeniería, UNAM.
- López, R. F., & Fernández, J. M. F. (2008). *Las redes neuronales artificiales*: Netbiblo.
- Luckey, R. R. (1972). Analyses of selected statistical methods for estimating groundwater withdrawal. *Water Resources Research*, 8(1), 205-210. doi:10.1029/WR008i001p00205
- Lutz, A., Minyila, S., Saga, B., Diarra, S., Apambire, B., & Thomas, J. (2015). Fluctuation of Groundwater Levels and Recharge Patterns in Northern Ghana. *Climate*, 3(1), 1-15. doi:10.3390/cli3010001
- Lv H. (2021). Martial Arts Competitive Decision-Making Algorithm Based on Improved BP Neural Network. *Journal of healthcare engineering*, 2021, 9920186. <https://doi.org/10.1155/2021/9920186> (Retraction published J Healthc Eng. 2023 May 24;2023:9816704. doi: 10.1155/2023/9816704)
- Majumdar, S., Smith, R., Butler, J. J., Jr., & Lakshmi, V. (2020). Groundwater Withdrawal Prediction Using Integrated Multitemporal Remote Sensing Data Sets and Machine Learning. *Water Resources Research*, 56(11). doi:10.1029/2020WR028059
- Maren A.J., Harston, C:T:, & Papa, R.M. (1990). Handbook of Neural Computing Applications. Ed. Academic Press.
- Margat, J., Foster, S. & Droubi, A. (2006). Concept and importance of non-renewable resources. In: Non-Renewable.
- Marsily, G. D. (1986). Quantitative hydrogeology : groundwater hydrology for engineers. Orlando, FL: Academic Press Orlando, FL.
- Martindill, J. R., Good, R. T., & Loge, F. J. (2021). Estimating Agricultural Groundwater Withdrawals with Energy Data. *Journal of Water Resources Planning and Management*, 147(5). doi:10.1061/(ASCE)WR.1943-5452.0001348
- Martínez-Santos, P., Castaño-Castaño, S., & Hernández-Espriú, A. (2018). Revisiting groundwater overdraft based on the experience of the Mancha Occidental Aquifer, Spain. *Hydrogeology Journal*, 26(4), 1083-1097. doi:10.1007/s10040-018-1735-0
- Martínez-Santos, P., & Martínez-Alfaro, P. E. (2010). Estimating groundwater withdrawals in areas of intensive agricultural pumping in central Spain. *Agricultural Water Management*, 98(1), 172-181. doi:<https://doi.org/10.1016/j.agwat.2010.08.011>
- Martos-Rosillo, S., Rodríguez-Rodríguez, M., Moral, F., Cruz-Sanjulián, J. J., & Rubio, J. C. (2009). Analysis of groundwater mining in two carbonate aquifers in Sierra de Estepa (SE Spain) based on hydrodynamic and hydrochemical data. *Hydrogeology Journal*, 17(7), 1617. doi:10.1007/s10040-009-0464-9
- Massuel, S., Amichi, F., Ameer, F., Calvez, R., Jenhaoui, Z., Bouarfa, S., . . . Hammani, A. (2017). Considering groundwater use to improve the assessment of groundwater pumping for irrigation in North Africa. *Hydrogeology Journal*, 25(6), 1565-1577. doi:10.1007/s10040-017-1573-5
- McDonald, M. G., & Harbaugh, A. W. (1988). A modular three-dimensional finite-difference ground-water flow model (06-A1). Retrieved from <http://pubs.er.usgs.gov/publication/twri06A1>
- Mehl, S., & Hill, M. (2004). Three-dimensional local grid refinement for block-centered finite-difference groundwater models using iteratively coupled shared nodes: a new method of interpolation and analysis of errors. *Advances in Water Resources*, 27, 899-912. doi:10.1016/j.advwatres.2004.06.004
- Meza-Gastelum, M. A., Campos-Gaytán, J. R., Ramírez-Hernández, J., Herrera-Oliva, C. S., Villegas-León, J. J., & Figueroa-Núñez, A. (2022). Review of Groundwater Withdrawal Estimation Methods. 14(17), 2762.

- Mohd Jamaludin, S. Z., Mohd Kasihmuddin, M. S., Md Ismail, A. I., Mansor, M. A., & Md Basir, M. F. J. E. (2020). Energy based logic mining analysis with hopfield neural network for recruitment evaluation. *23*(1), 40.
- Monterroso-Rivas, A. I., & Gómez-Díaz, J. D., (2021). Impact of climate change on potential evapotranspiration and growing season in Mexico. 39.
- Moreno Mena, J. (1999). "Flexibilización y precariedad en los mercados de trabajo agrícolas en Baja California" en Primer foro de trabajo en el campo michoacano, CIDEN, SEDESOL, Jornaleros Agrícolas, Colegio de Michoacán, México.
- Moreo, M. T., Halford, K.J., La Camera, R.J., Lacznia, R.J.,. (2003). *Estimated ground-water withdrawals from the Death Valley regional flow system, Nevada and California, 1913-98*. Retrieved from
- Moroney, L. (2020). *Ai and machine learning for coders*: O'Reilly Media.
- Murkowski, L., & United States. (2014). The energy-water nexus: Interlinked resources that are vital for economic growth and sustainability.
- Myneni, R. B., Maggion, S., Iaquinta, J., Privette, J. L., Gobron, N., Pinty, B., . . . Williams, D. L. (1995). Optical remote sensing of vegetation: Modeling, caveats, and algorithms. *Remote Sensing of Environment*, *51*(1), 169-188. doi:[https://doi.org/10.1016/0034-4257\(94\)00073-V](https://doi.org/10.1016/0034-4257(94)00073-V)
- Ngako, K., Kenfack, J. V., Pelap, F. B., & Demanou Messe, M. R. (2021). Structural analysis of Haut-Nkam division, Central-Africa using remote sensing data and GIS technics. *The Egyptian Journal of Remote Sensing and Space Science*, *24*(3, Part 2), 687-698. doi:<https://doi.org/10.1016/j.ejrs.2021.06.008>
- Ogilbee, W., & Mitten, H. T. (1970). *A continuing program for estimating ground-water pumpage in California--Methods* (70-246). Retrieved from <http://pubs.er.usgs.gov/publication/ofr70246>
- Padilla Morín, M. (2013). Aplicación de un modelo numérico para simular el flujo hidráulico del acuífero de Ojos Negros. (Maestro), Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California, Retrieved from <http://biblioteca.cicese.mx/catalogos/tesis/ficha.php?id=19205> Available from Biblioteca del CICESE Pelicano database.
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., . . . Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *372*, n71. doi:10.1136/bmj.n71 %J BMJ
- Panahi, M., Sadhasivam, N., Pourghasemi, H. R., Rezaie, F., & Lee, S. (2020). Spatial prediction of groundwater potential mapping based on convolutional neural network (CNN) and support vector regression (SVR). *Journal of Hydrology*, *588*, 125033. doi:<https://doi.org/10.1016/j.jhydrol.2020.125033>
- Parizi, E., Mossa Hosseini, S., Ataie-Ashtiani, B., & Simmons, C. T. (2019). Representative pumping wells network to estimate groundwater withdrawal from aquifers: Lessons from a developing country, Iran. *Journal of Hydrology*, *578*, 124090. doi:<https://doi.org/10.1016/j.jhydrol.2019.124090>
- Park, Changhui, Chung, Il-Moon. (2020). Evaluating the groundwater prediction using LSTM model. *Journal of Korea Water Resources Association*, *53*(4), 273-283. doi:10.3741/JKWRA.2020.53.4.273.
- Pérez González, R. (2021). *Deep Learning Methods for Automotive Radar Signal Processing*. Göttingen: Cuvillier Verlag.
- Petronici, F., Pujades, E., Jurado, A., Marcaccio, M., & Borgatti, L. (2019). Numerical Modelling of the Mulino Delle Vene Aquifer (Northern Italy) as a Tool for Predicting the Hydrogeological System Behavior under Different Recharge Conditions. *Water*, *11*, 2505. doi:10.3390/w11122505
- Piao, S., Fang, J., Liu, H., & Zhu, B. (2005). NDVI-indicated decline in desertification in China in the past two decades. *Geophysical Research Letters*, *32*(6). doi:<https://doi.org/10.1029/2004GL021764>
- Ponce, V. M., Pandey, R. P., & Kumar, S. (1999). Groundwater recharge by channel infiltration in El Barbon basin, Baja California, Mexico. *Journal of Hydrology*, *214*(1), 1-7. doi:[https://doi.org/10.1016/S0022-1694\(98\)00220-0](https://doi.org/10.1016/S0022-1694(98)00220-0)
- Ponce V. M., Zúñiga Castillo, W. R., Venegas Cardoso, R., Gaona Arredondo, T., García Cueto, O. R., Sepúlveda Betancourt, J. I., Vipinchandra Shetty, A. (2003). Manejo sustentable del agua en el Valle de Ojos Negros, Baja California, México. Instituto Nacional de Investigaciones Agrícolas, Forestales y Pecuarias. Retrieved October 15, 2023, from [ponce.sdsu.edu: https://ponce.sdsu.edu/ponce.sdsu.edu/ojos_negros_reporte_final.html](https://ponce.sdsu.edu/ponce.sdsu.edu/ojos_negros_reporte_final.html)
- Ponce, V. J., UABC, INIFAP. (2009). Manejo sustentable del agua en el Valle de Ojos Negros, Baja California, México.

- Rejani, R., Jha, M. K., Panda, S. N., & Mull, R. (2007). Simulation Modeling for Efficient Groundwater Management in Balasore Coastal Basin, India. *Water Resources Management*, 22(1), 23. doi:10.1007/s11269-006-9142-z
- Restrepo, J. I., Montoya, A. M., & Obeysekera, J. (1998). A Wetland Simulation Module for the MODFLOW Ground Water Model. *Groundwater*, 36(5), 764-770. doi:https://doi.org/10.1111/j.1745-6584.1998.tb02193.x
- Richey, A. S., Thomas, B. F., Lo, M.-H., Reager, J. T., Famiglietti, J. S., Voss, K., . . . Rodell, M. (2015). Quantifying renewable groundwater stress with GRACE. 51(7), 5217-5238. doi:https://doi.org/10.1002/2015WR017349
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. 351(1), 309.
- Rosenblat, F. (1958). The Perceptron: A Probabilistic Model For Information Storage And Organization In The Brain. *Psychological Review*, 386-408. doi:10.1037/h0042519
- Ruud, N., Harter, T., & Naugle, A. (2004). Estimation of groundwater pumping as closure to the water balance of a semi-arid, irrigated agricultural basin. *Journal of Hydrology*, 297, 51-73. doi:10.1016/j.jhydrol.2004.04.014
- Salar, A., & Ahmadi, A. (2023). Improving loss function for deep convolutional neural network applied in automatic image annotation. *The Visual Computer*, 40, 1-13. doi:10.1007/s00371-023-02873-3
- Salas, R. J. (2004). Redes neuronales artificiales. 1, 1-7.
- Salinas-Zavala, C. A., Martínez-Rincón, R. O., & Morales-Zárate, M. V. (2017). Tendencia en el siglo XXI del Índice de Diferencias Normalizadas de Vegetación (NDVI) en la parte sur de la península de Baja California. *Investigaciones Geográficas*, 0(94). doi:10.14350/rig.57214
- SARH. (1979). *Estudio Geohidrológico de los Valles de Ojos Negros- Real del Castillo*.
- Schulze, F., Wolf, H., Jansen, H., Van der Veer, P. J. W. s., & technology. (2005). Applications of artificial neural networks in integrated water management: fiction or future? , 52(9), 21-31.
- Secretaría de Agricultura y Recursos Hidráulicos (SARH). (1974). *Estudio Geohidrologico de los Valles Ojos Negros- Real del Castillo*. Dirección de geohidrología y Zonas Áridas. Técnicas
- Secretaría de Gobernación. (2017). Acuerdo Por El Que Se Dan A Conocer Los Resultados Del Estudio Técnico De Las Aguas Nacionales Subterráneas Del Acuífero Ojos Negros, Clave 0208, En El Estado De Baja California, Región Hidrológico-Administrativa Península De Baja California. Estados Unidos Mexicanos. Retrieved August 03, 2023, from , Available in version HTML: https://www.dof.gob.mx/nota_detalle.php?codigo=5487746&fecha=22/06/2017#gsc.tab=0
- SEFOA. (2015). Programa Estatal de Desarrollo Agropecuario 2015-2019. In. México: Secretaría del Campo y Seguridad Alimentaria.
- Shafiq S, Azim T. (2021). Introspective analysis of convolutional neural networks for improving discrimination performance and feature visualisation. *PeerJ Computer Science* 7:e497 <https://doi.org/10.7717/peerj-cs.497> Shao, J., Cui, Y., Hao, Q., Han, Z., & Cheng, T. (2014). Study on the estimation of groundwater withdrawals based on groundwater flow modeling and its application in the North China Plain. *Journal of Earth Science*, 25(6), 1033-1042. doi:10.1007/s12583-014-0493-8
- Sinha, R. K., Aggarwal, Y., & Das, B. N. (2007). Backpropagation artificial neural network classifier to detect changes in heart sound due to mitral valve regurgitation. *Journal of medical systems*, 31(3), 205–209. <https://doi.org/10.1007/s10916-007-9056-1>
- Su, C., Cui, Y., Wang, L., & Li, L. (2012). Estimation of the Groundwater Exploitation Based on Land Subsidence Numerical Model: a Case Study in the Plain Area of Tianjin. *Advanced Materials Research*, 610-613, 2734-2739. doi:10.4028/www.scientific.net/AMR.610-613.2734
- Sun, W., Song, X., Mu, X., Gao, P., Wang, F., & Zhao, G. (2015). Spatiotemporal vegetation cover variations associated with climate change and ecological restoration in the Loess Plateau. *Agricultural and Forest Meteorology*, 209-210, 87-99. doi:<https://doi.org/10.1016/j.agrformet.2015.05.002>
- Sun, Y., Yang, Y., Zhang, Y., & Wang, Z. (2015). Assessing vegetation dynamics and their relationships with climatic variability in northern China. *Physics and Chemistry of the Earth, Parts A/B/C*, 87-88, 79-86. doi:<https://doi.org/10.1016/j.pce.2015.09.018>
- Tao, H., Li, M., Wang, M., & Lü, G. (2019). Genetic algorithm-based method for forest type classification using multi-temporal NDVI from Landsat TM imagery. *Annals of GIS*, 25(1), 33-43. doi:10.1080/19475683.2018.1552621
- Taher, T. M. (2016). Groundwater abstraction management in Sana'a Basin, Yemen: a local community approach. *Hydrogeology Journal*, 24(6), 1593-1605. doi:10.1007/s10040-016-1435-6

- Taie Semiromi, M., & Koch, M. (2019). Analysis of spatio-temporal variability of surface-groundwater interactions in the Gharehsoo river basin, Iran, using a coupled SWAT-MODFLOW model. *Environmental Earth Sciences*, 78(6), 201. doi:10.1007/s12665-019-8206-3
- Teramoto, E. H., Benjumea, M. T., Gonçalves, R. D., & Kiang, C. H. (2018). Séries Temporais do índice NDVI na Avaliação do Comportamento Sazonal do Aquífero Rio Claro. *Revista Brasileira de Cartografia*, 70(3), 1135-1157. doi:10.14393/rbcv70n3-45986
- Tian, S., Zhang, J., Shu, X., Chen, L., Niu, X., & Wang, Y. (2022). A Novel Evaluation Strategy to Artificial Neural Network Model Based on Bionics. *Journal of Bionic Engineering*, 19(1), 224-239. doi:10.1007/s42235-021-00136-2
- Tillman, F. D., Callegary, J. B., Nagler, P. L., & Glenn, E. P. (2012). A simple method for estimating basin-scale groundwater discharge by vegetation in the basin and range province of Arizona using remote sensing information and geographic information systems. *Journal of Arid Environments*, 82, 44-52. doi:https://doi.org/10.1016/j.jaridenv.2012.02.010
- Todd, D. K., & Mays, L. W. (2004). *Groundwater hydrology*: John Wiley & Sons.
- Trescott, P., & Larson, S. (1977). Comparison of Iterative Methods of Solving Two-Dimensional. *Water Resources Research*, 125-136. doi:10.1029/WR013i001p00125
- Tsanis, I. K., & Apostolaki, M. G. (2009). Estimating Groundwater Withdrawal in Poorly Gauged Agricultural Basins. *Water Resources Management*, 23(6), 1097-1123. doi:10.1007/s11269-008-9317-x
- UABC (Universidad Autónoma de Baja California y San Diego State University). 1999. Proyecto SCERP-Frontera XXI-1991-2001. Manejo Sustentable del Agua en el Valle de Ojos Negros, B.C.
- van Zyl, J. J. (2001). The Shuttle Radar Topography Mission (SRTM): a breakthrough in remote sensing of topography. *Acta Astronautica*, 48(5), 559-565. doi:https://doi.org/10.1016/S0094-5765(01)00020-0
- Valderrama Purizaca, F., Chávez Barturen, D., Muñoz Pérez, S., Tuesta-Monteza, V., & Mejía-Cabrera, H. (2021). Importance of artificial neural networks in civil engineering: a systematic review of the literature. *ITECKNE*, 18(1), 71-83. https://doi.org/https://doi.org/10.15332/iteckne.v18i1.2542
- Vázquez, G. R., Traslosheros, C., Vega, M., Vega, R., & Espinoza, R., J. (1991). Evaluación Geohidrológica en el Noroeste de Baja California. Grupo de Geohidrología. In División Ciencias de la Tierra. CICESE. Ensenada, Baja California, México. https://cicese.repositorioinstitucional.mx/jspui/bitstream/1007/909/1/192051.pdf
- Vélez, J., & Nieto, P. (2016). Validación De Medidas De Evaluación Para El Pronóstico De La Tasa De Cambio En Colombia (Tesis de Maestría). Bogotá: Colegio de Estudios Superiores de Administración.
- Vásconez, J. P., Barona López, L. I., Valdivieso Caraguay, Á. L., & Benalcázar, M. E. (2023). A comparison of EMG-based hand gesture recognition systems based on supervised and reinforcement learning. *Engineering Applications of Artificial Intelligence*, 123, 106327. doi:https://doi.org/10.1016/j.engappai.2023.106327
- Vázquez, G. R., Traslosheros, C., Vega, M., Vega, R., & Espinoza, R., J. (1991). Evaluación Geohidrológica en el Noroeste de Baja California. Grupo de Geohidrología. In División Ciencias de la Tierra. CICESE. Ensenada, Baja California, México. https://cicese.repositorioinstitucional.mx/jspui/bitstream/1007/909/1/192051.pdf
- Venkatesan, M., & Kulkarni, A. V. K. (2016). Comparative Performance Investigation of Supervised and Unsupervised Learning Outlines applied in Cognitive Radio Systems. *Wireless Personal Communications*, 91(3), 1393-1417. doi:10.1007/s11277-016-3534-z
- Villada, F., Muñoz, N., & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores %J Información tecnológica. 23, 11-20.
- Vörösmarty, C. J., Lévêque, C., & Revenga, C. (2005). Fresh water. *Ecosystems and Human Well-being: Current State and Trends*, 1, 165-207.
- Wada, Y., van Beek, L. P. H., van Kempen, C. M., Reckman, J. W. T. M., Vasak, S., & Bierkens, M. F. P. (2010). Global depletion of groundwater resources. *Geophysical Research Letters*, 37(20). doi:https://doi.org/10.1029/2010GL044571
- Wang, X., Daryapour, M., Shahrabadi, A., Pirasteh, S., & Razavirad, F. (2023). Artificial Neural Networks in Predicting of the Gas Molecular Diffusion Coefficient. *Chemical Engineering Research and Design*. doi:https://doi.org/10.1016/j.cherd.2023.10.035

- Wang, J., Wang, K., Zhang, M., & Zhang, C. (2015). Impacts of climate change and human activities on vegetation cover in hilly southern China. *Ecological Engineering*, 81, 451-461. doi:<https://doi.org/10.1016/j.ecoleng.2015.04.022>
- Wang, Y., & Chen, H.-J. (2012). Use of percentiles and z-scores in anthropometry. In *Handbook of anthropometry: Physical measures of human form in health and disease* (pp. 29-48): Springer.
- Wei, D., Anurag, B., & Jianing, W. (2018). *Deep Learning Essentials : Your Hands-on Guide to the Fundamentals of Deep Learning and Neural Network Modeling*. Birmingham, UK: Packt Publishing.
- Wen-Hsing, C., & Wolfgang, K. (1999). Manual of processing MODFLOW, numerical model for groundwater flow.
- Wray, J. R. (1982). Estimating irrigation water use and withdrawal of ground water on the High Plains, U.S.A. *Advances in Space Research*, 2(8), 127-129. doi:10.1016/0273-1177(82)90229-0
- Wu, Y.-c., & Feng, J.-w. (2018). Development and Application of Artificial Neural Network. *Wireless Personal Communications*, 102(2), 1645-1656. doi:10.1007/s11277-017-5224-x
- Xue, S., Liu, Y., Liu, S., Li, W., Wu, Y., & Pei, Y. (2018). Numerical simulation for groundwater distribution after mining in Zhuanlongwan mining area based on visual MODFLOW. *Environmental Earth Sciences*, 77(11), 400. doi:10.1007/s12665-018-7575-3
- Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. J. I. i. i. (2018). Convolutional neural networks: an overview and application in radiology. 9, 611-629.
- Yang, L., Qi, Y., Zheng, C., Andrews, C. B., Yue, S., Lin, S., . . . Li, H. (2018). A Modified Water-Table Fluctuation Method to Characterize Regional Groundwater Discharge. *Water*, 10(4). doi:10.3390/w10040503
- Yu, X., Ghasemizadeh, R., Padilla, I. Y., Kaeli, D., & Alshawabkeh, A. (2016). Patterns of temporal scaling of groundwater level fluctuation. *Journal of Hydrology*, 536, 485-495. doi:<https://doi.org/10.1016/j.jhydrol.2016.03.018>
- Yuan, H. C., Xiong, F. L., & Huai, X. Y. (2003). A method for estimating the number of hidden neurons in feed-forward neural networks based on information entropy. *Computers and Electronics in Agriculture*, 40(1), 57-64. doi:[https://doi.org/10.1016/S0168-1699\(03\)00011-5](https://doi.org/10.1016/S0168-1699(03)00011-5)
- Zhang, Y., Gong, H., Gu, Z., Wang, R., Li, X., & Zhao, W. (2014). Characterization of land subsidence induced by groundwater withdrawals in the plain of Beijing city, China. *Hydrogeology Journal*, 22(2), 397-409. doi:10.1007/s10040-013-1069-x
- Zhang, Y., & Wu, L. (2008). Weights optimization of neural network via improved BCO approach. *Progress in Electromagnetics Research-pier - PROG ELECTROMAGN RES*, 83, 185-198. doi:10.2528/PIER08051403
- Zhao, J. (2013). Compact finite difference methods for high order integro-differential equations. *Applied Mathematics and Computation*, 221, 66-78. doi:10.1016/j.amc.2013.06.030

APÉNDICE A

Publicación elaborada con información recopilada y analizada con fines de desarrollo de una parte de la sección antecedentes que integra esta investigación.



Review

Review of Groundwater Withdrawal Estimation Methods

Marco Antonio Meza-Gastelum ¹, José Rubén Campos-Gaytán ^{1,*}, Jorge Ramírez-Hernández ²,
Claudia Soledad Herrera-Oliva ¹, José Juan Villegas-León ¹ and Alejandro Figueroa-Núñez ³

¹ Facultad de Ingeniería, Arquitectura y Diseño, Universidad Autónoma de Baja California, Ensenada 22860, Mexico

² Instituto de Ingeniería, Universidad Autónoma de Baja California, Mexicali 21280, Mexico

³ Comisión Estatal de Servicios Públicos de Ensenada, Ensenada 22800, Mexico

* Correspondence: rcampos@uabc.edu.mx

Abstract: The demand for groundwater resources in arid and semi-arid regions has increased due to their progressive use in agriculture, industry and domestic activities. Among the difficulties and uncertainties that arise when managing groundwater resources is the calculation of groundwater withdrawals (GWW). The objective of this research work is to review the existing literature on the methods developed to estimate GWW by providing a summary of the advances, limitations and opportunities that the different methods developed on this topic could offer by identifying, categorizing and synthesizing the studies with a focus on developing a systematic guide so that researchers and practitioners conducting GWW studies can be informed of the most popular techniques, and the authors' experiences in recent years. Therefore, a literature search was conducted in the EEE, Google Scholar, SCOPUS, SpringerLink, ScienceDirect, Taylor & Francis Group and Wiley-Blackwell databases, using the following keywords: Groundwater AND (Withdrawal OR Pumping OR Abstraction) AND (Prediction OR Estimation). Thirty-four journal articles published between 1970 and 2021 were chosen based on the selection criteria, characteristics and capabilities of the approaches used for evaluation in GWW extraction. We concluded that the different methods for groundwater pumping estimation that have been reviewed in this work have advantages and disadvantages in their application. Direct approaches are very old and are still working uncertainty in their application is presented with possible human errors or in the measurement system. On the other hand, indirect methods have evolved along with technological advances, which have brought significant improvements and accuracy to these approaches.

Keywords: groundwater withdrawals; pumping well; estimate; extraction methods



Citation: Meza-Gastelum, M.A.; Campos-Gaytán, J.R.; Ramírez-Hernández, J.; Herrera-Oliva, C.S.; Villegas-León, J.J.; Figueroa-Núñez, A. Review of Groundwater Withdrawal Estimation Methods. *Water* 2022, 14, 2762. <https://doi.org/10.3390/w14172762>

Academic Editor: Yeshuang Xu

Received: 11 July 2022

Accepted: 31 August 2022

Published: 5 September 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Water scarcity is among the greatest challenges facing humanity today, a situation that is alarming considering the pressure exerted on water resources in recent decades, due to rapid population growth, intense agricultural and industrial activity, and the high demand for water supply [1]. Groundwater accounts for one-third of the world's water demand and supplies drinking water to a large part of the population; however, in many regions, it is subject to stress both in terms of quantity and quality [2]. Mainly in arid and semi-arid regions, aquifers are subject to stress, which can be defined as a situation in which demand is greater than supply and often leads to overexploitation of aquifers [3]. In terms of groundwater use, agriculture is the main cause of scarcity, accounting for almost 70% of all groundwater withdrawals, and in some developing countries up to 95% [4]. It has been estimated that approximately 98.7% of all freshwater is available as groundwater. This resource provides 42%, 36% and 27% of the world's water used for agriculture, human use and industrial production, respectively [5]. Despite their importance for freshwater supply, groundwater resources are often poorly monitored, making it difficult, and sometimes impossible, to develop a consistent picture of their availability [6]. As a consequence, many

aquifers, particularly in semi-arid and arid regions, are currently overexploited because withdrawals exceed the rate of recharge [7]. This causes groundwater resources to come under pressure due to a number of factors, such as salinization, a critical problem that can contaminate groundwater and affect soil fertility, vegetation and ecological conditions along the coastal zones [8]. In addition, in deltaic areas, groundwater depletion can lead to land subsidence [9]. To avoid this catastrophe, it is necessary to properly manage the exploitation and protection of groundwater [10,11]. Since, if we are able to understand the aquifer's response to pumping before any damage to the aquifer system occurs, undesirable situations could be avoided [12]. Groundwater discharge (GWW) is an extremely important, often under-considered, and generally neglected component of water balance models [13]. Despite these monitoring needs, the follow-up and control of GWW are tasks that are generally perceived negatively by farmers, mainly because of exposing their usage habits [14]. Therefore, an ideal procedure for estimating the volume of groundwater extraction must maintain an acceptable level of accuracy, low (economic) cost and significantly reduce measurement errors [15]. With this in mind, the objective of this systematic review is to gain insight into the methods that have been applied to determine groundwater resources exploitation, providing a summary of the advantages, limitations and opportunities that the different methods developed on this topic can offer, identifying, categorizing and synthesizing the studies with the aim of producing a systematic guide for researchers and practitioners conducting GWW studies. A review such as this will help researchers understand the advances in research, and identify the strengths and weaknesses of each technique, which can help shape the direction of future research in this area. Therefore, first, the methodology used is presented. Next, a brief description of the methods is presented, followed by a citation and review of the studies conducted in this regard. This is followed by the discussion and conclusions.

2. Methodology

2.1. Search Strategy

A bibliographic search was carried out in the EEE, Google Scholar, SCOPUS, Springer-Link, ScienceDirect, Taylor & Francis Group and Wiley-Blackwell databases using the following keywords: (Groundwater [Title/Abstract]) AND (Withdrawal OR Pumping OR Abstraction [Title/Abstract]) AND (Prediction OR Estimation [Title/Abstract]). Articles were related to: hydrology, earth sciences, water resources and hydrogeology. The choice of keywords was intended to be simple and, since "Withdrawal", "Pumping" and "Abstraction" are synonyms generally used to refer to water withdrawals, they were also included in the search, using the Boolean operator OR. This filtering structure was applied to ensure consistency of the search across reference sources. No temporal restriction was imposed. Finally, a duplicate elimination was performed.

2.2. Screening and Eligibility Results

A first screening of titles and abstracts was performed, selecting articles that actually reported the use of methods to estimate groundwater withdrawals. The first eligibility criterion was to keep articles in which water withdrawals were focused in the areas of hydrology, earth sciences, agriculture, water resources, and hydrogeology. A second aspect considered articles related to the environment were not included, because these are based on the environmental impact caused by overexploitation in aquifers, without addressing the methodologies for estimating withdrawals. Once the above aspects were defined, we proceeded to the selection of articles for the review of the full text, dividing them into two categories: direct and indirect approaches to estimate GWW. In this work, direct approaches are considered to be methods or processes in which the volume of aquifer exploitation is measured in each pumping equipment manually or automatically. Whereas indirect methods refer to the process in which, alternative methods are used to estimate the exploitation volume. To perform these processes, the approaches established

by the PRISMA (Preferred Reporting Items for Systematic Reviews) methodology were followed [16]. This systematic review is described in Figure 1.

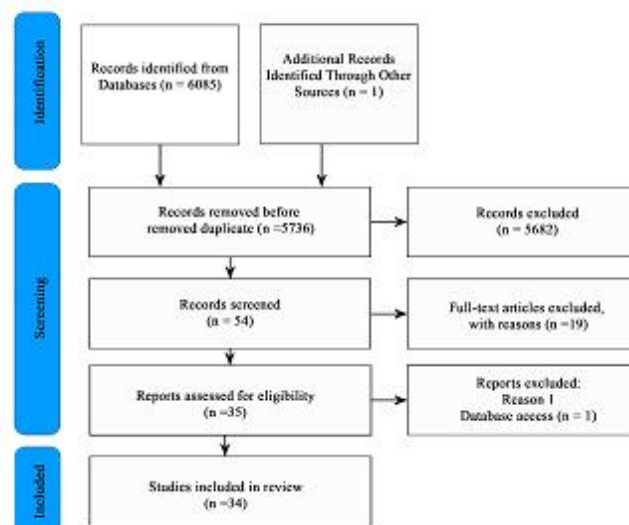


Figure 1. Process of search, selection and identification of studies according to the Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA) 2020 flow diagram for new systematic reviews, which included searches of databases, registers and other sources [16].

3. Results

The databases consulted were EEE, Google Scholar, ScienceDirect, SCOPUS, Springer-Link, Taylor & Francis Group and Wiley-Blackwell, resulting in the identification of 30, 572, 1507, 119, 3429, 100 and 328 articles, respectively, with a total of 6085, in addition to 1 article included through snowball searching. Subsequently, duplicates were eliminated, leaving a total of 5736 articles. A first selection of titles and abstracts was then made, eliminating a total of 5682. The remaining 54 articles were exhaustively reviewed, discarding those that did not use techniques to estimate groundwater pumping, reaching a total of 35, of which 1 was discarded due to limited access to databases. This resulted in a total of 34 articles focused on quantifying GWW. Although no temporal restriction was imposed for the search, the first paper found with this criterion was from 1970.

Figure 2 shows the results of the articles analyzed by year. As can be seen, the highest number of publications is present in the year 2017 with four publications—during this year, direct and indirect methods received the same number of publications (two each)—followed by the year 2009 and the period 2018–2020 with three publications per year—during this period, the methods based on remote sensing and geographic information systems predominated. While the years 2010 and 2012 presented two publications per year focused on indirect methods. In addition, a constant of one publication can be observed for the period 1970–2005, a stage where direct methods and estimation method based on crop water demands were dominant; similarly, the period 2013–2015 only presented one publication per year—during this stage, models based on groundwater flow were the main approaches developed.

Figure 3 shows the publications made by each country. It can be seen that the United States is in first place with a total of 12 published articles, followed by China with 4 publications and in third place is Spain with a total of 3 publications. Despite not being present in other countries in Figure 3, this does not indicate that they do not have problems of

overexploitation; however, most of the research in this area is conducted in the United States and Asian countries with the highest depletion of groundwater worldwide (in terms of volume) [17]. Likewise, the importance of the subject can be observed for the United States, being the country with the highest number of publications and with the first studies carried out in the 1970s, denoting the importance of obtaining an adequate management system for the quantification of groundwater exploitation in their country.

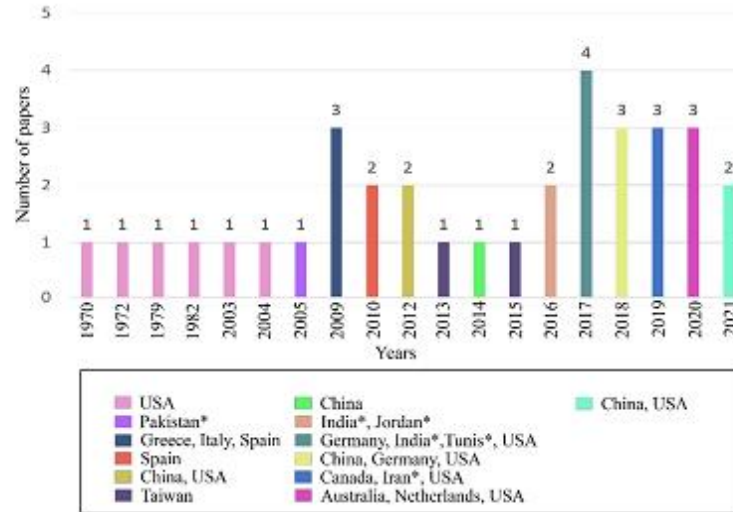


Figure 2. Annual publications of methods for estimating groundwater pumping. * Undeveloped countries.

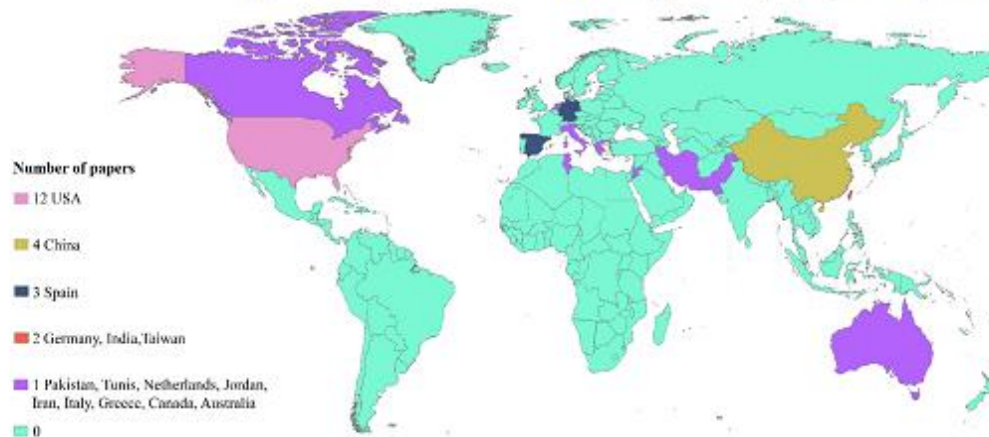


Figure 3. List of publications by country.

Finally, the investigations were classified into two categories according to the factors stipulated for this work: (1) association with direct methods; (2) association with indirect methods. These categories are described in Sections 3.1 and 3.2. At the end of this section, Table 1 shows a summary of the results obtained.

Table 1. Methodologies identified for pumping estimation as a function of the used approach. Root mean square (RMS); coefficient of determination (R^2); mean absolute error (MAE); root mean square error (RMSE); not specified (-).

Study	Approach	Study Aquifer/Study Area	Number of Selected Pumping Wells	Scale of the Study	Accuracy of the Method or Characteristics	Method Classification
Martos-Rosillo et al. [18]	Time series analysis and numerical groundwater modeling	Lora and Mingo aquifers in Seville, Spain	3 observation points	Area of smaller than 5 square kilometers	In the Lora aquifer, the mean annual extraction was estimated at $0.342 \times 10^6 \text{ m}^3$, and that in the Mingo aquifer was estimated at $0.213 \times 10^6 \text{ m}^3$.	Indirect
Forstner and Gleeson [19]	Multi-method sectoral approach	British Columbia, Canada	-	The average size of the aquifers varies, depending on the type, between 4 and 27 km^2	Annual distribution of groundwater by sector: agriculture (38%), finfish aquaculture (21%), industry (16%), municipal water distribution systems (15%) and domestic users of private wells (11%). For the groundwater balance approach, an absolute error of $42.65 \times 10^6 \text{ m}^3$ was calculated, which is equivalent to a relative error of 137% of the estimate. For the land use-based approach, the error estimate was $36.19 \times 10^6 \text{ m}^3$, with a resulting range of $0\text{--}99.90 \times 10^6 \text{ m}^3$.	Indirect
Vu et al. [20]	Two approaches: (1) local knowledge through a qualitative field study (of farmers), and (2) land use data combined with local knowledge on cropping and irrigation practices	La Vi River Basin, Vietnam	77 wells	100 km^2	For the groundwater balance approach, an absolute error of $42.65 \times 10^6 \text{ m}^3$ was calculated, which is equivalent to a relative error of 137% of the estimate. For the land use-based approach, the error estimate was $36.19 \times 10^6 \text{ m}^3$, with a resulting range of $0\text{--}99.90 \times 10^6 \text{ m}^3$.	Indirect
Tsanis et al. [21]	Combining surface-water and groundwater potentials using a conceptual rainfall-runoff model (the Sacramento hydrologic model)	Messara Valley, Crete, Greece	11 climatological stations	400 km^2	The average error for the entire period 1981–2002 is 20%.	Indirect
Yang et al. [22]	Water table fluctuation regression (WTFR) method	Dagu aquifer, coastal area in eastern China	82 wells	430 km^2	The RMS of water level in all wells ranged from 0.05 to 0.49 m, with a mean of 0.22 m (0.22 m).	Indirect
Bhadra et al. [23]	Three methods: (1) Discharge discharge factor (DF); (2) linear groundwater consumption models (LGDM), and (3) irrigation depth	70 villages in Sikar district, Rajasthan state, northwest India	6696 wells to determine the DF and 39 observation wells	620 km^2	The RMSE with the LGDM model in elevation zones: shallow, intermediate, deep and combined vary between 0.43 and 0.34.	Indirect

Table 1. Cont.

Study	Approach	Study Aquifer/Study Area	Number of Selected Pumping Wells	Scale of the Study	Accuracy of the Method or Characteristics	Method Classification
Casa et al. [24]	Based on crop needs, using GIS and remote sensing techniques in combination with water balance	Pontina Plain in Central Italy	•	700 km ²	The results of this study estimated a demand of 70 Mm ³ per year, i.e., 100 Mm ³ per year of irrigation needs if an average irrigation application efficiency of 70% is considered.	Indirect
Li et al. [25]	Two methods: (1) the water balance method, and (2) back-propagation artificial neural network (BPANN)	Tongzhou, southeast Beijing	14 wells	906 km ²	The water balance method R ² = 0.9914 and the BPANN method R ² = 0.9069.	Indirect
Dubois et al. [26]	Approach based on water requirements for crops	Nebhana Plain, northeastern Tunisia	•	1221 km ²	Accuracy crop classification improves by 10% with multitemporal features.	Indirect
Ruud et al. [13]	Water balance model based on geographic information systems (GIS)	Southern San Joaquin Valley, California, USA	•	2300 km ²	The model estimate has an error of 38%.	Indirect
Lin et al. [27]	Groundwater equilibrium model with coupling surface-water (SWAT) and groundwater (MODFLOW) modeling	Multi-aquifer system in an alluvial fan of the Choushui River, Taiwan	The entire aquifer	2500 km ²	MAE = 5.1%.	Indirect
Liu et al. [28]	Two-part approach, Independent Component Analysis (ICA) and groundwater modeling	Aquifer in the Sijhou municipality, in the alluvial fan of the Jhuoshuei River, west-central Taiwan	136 observation wells	2562 km ²	The calibration of the groundwater model had an RMSE of 1.00 m. The total amount of groundwater pumped is 37,565 m ³ /day, of which more than 58% is for agriculture and 42% is for industrial use.	Indirect
Ray et al. [29]	Approach based on spatio-temporal patterns of groundwater consumption for irrigation	Seonath-Kharun, India	43 wells	2867 km ²	Annual estimate of groundwater consumption for irrigation was 212 × 10 ⁶ m ³ .	Indirect
Baker [30]	Statistical approach, agricultural water uses and electrical measurements	Kansas, USA	78 wells equipped with flowmeters	1800 mi ²	Statistical method: the standard deviation was 1.22; estimates of the variance for irrigated area of the total sample was 40.23 and pooled was 0.77. The estimates of the sample variance from energy consumption coefficients was 1.868.	Direct

Table 1. Cont.

Study	Approach	Study Aquifer/Study Area	Number of Selected Pumping Wells	Scale of the Study	Accuracy of the Method or Characteristics	Method Classification
Martínez-Santos and Martínez-Alfaro [31]	Coupling of the water table fluctuation (WTF) method with the groundwater balance equation	Western Mancha Aquifer, Spain	-	5500 km ²	Average error rate of 10%.	Indirect
Castaño et al. [32]	GIS-based method focused on the quantification of withdrawals irrigation	Mancha Oriental, Spain	-	7260 km ²	Accuracies greater than 95% with a cost 60-fold lower than traditional methods.	Indirect
Parizi et al. [33]	This approach called "representative pumping well network" (RPWN)	Three aquifers in Iran: Tehran, Arak and Qazvin	50 pumping wells for each aquifer	Tehran aquifer with an area of 2250 km ² , Arak aquifer with an area of 1945.5 km ² and Qazvin aquifer with an area of 3952.0 km ²	RPWN shows errors between 0.2% and 1.41% with respect to actual RPWN.	Indirect
Su et al. [34]	Numerical model coupled with ModFlow2005: groundwater flow and land subsidence	Multi-aquifer system in Tianjin Plain, China	136, 87, 53, 42, and 4 wells, respectively for each aquifer	10,600 km ²	The average annual exploitation based on the model was estimated of 8.35×10^8 m ³ per year. The average annual exploitation derived from the quota method and statistical data were 9.73×10^8 m ³ and 5.45×10^8 m ³ per year, respectively.	Indirect
Al-Bakri et al. [35]	GIS-based method focused on the quantification of irrigation withdrawals	Three basins in Jordan: Yarmouk, Amman-Zarqa and Azraq	Yarmouk 129 wells, Amman-Zarqa 590 and Azraq 488 wells.	The area of the Yarmouk basin is approximately 1393 km ² , the Amman-Zarqa basin has an area of 3600 km ² , the Azraq basin has an area of 11,742 km ² .	Irrigated crop maps showed good agreement between irrigation maps and soil data, with an overall accuracy of 87%. Groundwater over-extraction was estimated to be between 144% and 360% of the safe yield in the three basins.	Indirect
Moreo et al. [36]	Three-dimensional numerical and transient model	34 study areas in Death Valley region (Nevada and eastern California), USA	9300 wells	19,000 mi ²	Error in extractions estimation was 8.3%.	Indirect

Table 1. Cont.

Study	Approach	Study Aquifer/Study Area	Number of Selected Pumping Wells	Scale of the Study	Accuracy of the Method or Characteristics	Method Classification
Shao et al. [37]	Inversion method based on a numerical model	North China Plain (NCP)	101 observation wells	139,000 km ²	In a synthetic case with an accuracy of 0.1 m, the average error during 10 years was 1.47% and 1.54% in two pumping subareas. Instead, with an accuracy of 0.01 the average error was 0.06% and 0.13%. The average estimate of the groundwater extraction for the NCP was of 24.92×10^9 m ³ per year. The annual estimated volume of groundwater discharge by vegetation was between 1.4 and 1.9 million of m ³ per year, with an annual mean of 1.6 million of m ³ . Correlation coefficients between monthly and annual groundwater discharge by vegetation and precipitation were low, ($r = 0.182$, $p > 0.05$) and ($p > 0.05$), respectively.	Indirect
Tillman et al. [38]	Approach based on crop water requirements	Alluvial basins of southwestern Arizona, USA	•	190,000 km ²	Groundwater pumping was sampled in 15 counties in the region.	Indirect
Wray [39]	Approach based on water requirements for crops	High Plains, USA	•	455,000 km ²	The specific yield method produced 65% lower net groundwater use compared to specific yield.	Indirect
Ahmad et al. [40]	GIS-based water balance model	Rechna Doab, Pakistan	•	Area of approximately 2.97 million hectares	Electricity consumption 4%, 10% for electricity consumption coefficient.	Indirect
Ogilbee & Mitten [41]	Two methods: (1) electrical energy consumption, and (2) electrical consumption coefficient	Santa Clara County and Fresno County, California, USA	200 wells	•	Estimation of the standard error, 14% for random sampling and 10% for regression analysis.	Direct
Luckey [15]	Random sampling combined with regression analysis	Arkansas River Valley in southeastern Colorado, USA	225 wells	•	Pearson correlation coefficient (R), calculated versus measured values of 0.90 and 0.97, for the calibration period.	Direct
Alfaro et al. [42]	Numerical model-based approach and crop water requirements	Eastern part of the Lower Jordan Valley southern part	6 wells	•		Indirect

Table 1. Cont.

Study	Approach	Study Aquifer/Study Area	Number of Selected Pumping Wells	Scale of the Study	Accuracy of the Method or Characteristics	Method Classification
Harris and Diehl [43]	The USGS model is compared to two source data, the EIA (Energy Information Administration) and the USGS compilation	Groundwater-fired power plants in USA	470 plants for the USGS compilation; 742 plants the EIA	•	Error percentage of the estimates was 17% for EIA and 24.6% for USGS compilation.	Direct
Massuel et al. [14]	Direct measurement methods and adaptive methodology that sought to involve the users	Three locations in North Africa (Morocco, Tunisia and Algeria)	Saïss 430 wells; Kairouan 928 wells, and Ziban 1255 wells	•	Water pumping in Saïss has a $\approx 20\%$ of discrepancy compared with the developed method. The average annual pumping time in Kairouan was 4300 h/year corresponding to a calculated average annual volume of 71,000 m ³ /year. At Ghrouss, the annual groundwater abstraction was estimated in 170 hm ³ /year. In a test case, the method predicted groundwater withdrawals with $R^2 \approx 0.23$, MAE ≈ 16.01 mm, RMSE ≈ 31.51 mm and normalized MAE ≈ 0.84 .	Direct
Majumdar et al. [44]	Holistic approach combining water balance components with a machine learning model	The High Plains Aquifer (HPA), located in the central United States	•	•	In a test case, the method predicted groundwater withdrawals with $R^2 \approx 0.23$, MAE ≈ 16.01 mm, RMSE ≈ 31.51 mm and normalized MAE ≈ 0.84 .	Indirect
Kent et al. [45]	Approach based on historical records and data hierarchy to establish the number of wells and their extraction characteristics	Extent of catchments associated with the Great Artesian Basin (GAB) and other regional-scale groundwater basins in Queensland, Australia	96,174 drill holes	•	Current GAB groundwater use in Queensland was estimated at 322 GL/year.	Indirect
Martindill et al. [46]	Ratio-based approach between pump energy consumption and Efficiency Lift Method (ELM)	San Joaquin Valley, California, USA	30 wells studied from 2010 to 2015	•	For individual tests, MAE = 13.5%; per month, MAE = 5%.	Direct

3.1. Direct Approaches to Estimating GWW

Methods in which the withdrawal volume at each pumping station is measured (manually or automatically) or calculated using the time-rate method by multiplying the average pump speed by the cumulative pumping time are known as direct approaches [47]. The most accurate and reliable method of monitoring GWW is to install flowmeters on all groundwater pumping wells [46]. However, flowmeters are generally not applied in all regions; moreover, owners of extraction wells are generally unwilling to install new flowmeters themselves that would allow accurate monitoring of groundwater withdrawals in agricultural wells [14,48]. Currently, groundwater-mining research continues to adopt direct methods for groundwater pumping estimation; however, the application of these methods can be difficult, as direct measurements require data that are often underreported which could pose a challenge for accurate estimates [34,49]. Despite this, estimation of pumping rates can be carried out by transforming electrical energy consumption data acquired from wells performing groundwater withdrawals [47]. Since the relationship between electricity consumption and pumping volume is a reliable relationship, the accuracy of these methods depends on the census of pumping wells coupled with complete and accurate records of pump electricity consumption, more accurate data lead to a more accurate estimation of pumping [28]. For example, Ogilbee and Mitten [41] estimated municipal and agricultural groundwater pumping for the major basins of California in the United States. They developed tables of total annual electricity and natural gas consumption data for groundwater pumping, which were obtained from the major utilities in central California. Data obtained correspond to the volume of groundwater pumped for municipal use in 27 communities ranging in population from 1000 to 145,000. The methodology for determining the annual per capita use factor, which is used to determine the volume of water supplied for municipal use, was done by dividing the volume of water by its population, so that the volume of water pumped can be calculated by multiplying the population of a community by the annual per capita use factor. While to estimate groundwater pumping for agricultural use, pumping as a function of surface area was used, using the power coefficient method. Meanwhile, Martindill et al. (2021) [46] focus on the relationship between the energy consumption produce of the pumps used in the GWW by employing the efficiency lifting method (ELM), due to the availability of electricity data and the operating conditions of the pumps have made the ELM method feasible to estimate the GWW on a large scale.

Furthermore, using this method provides a framework for converting well pumping energy into an estimate of GWW. Specifically, methods based on electrical measurements state that the total amount of pumping for each well is a product of total electricity consumption and pumping time [50,51].

Likewise, traditional statistical methods are often practical and applicable for estimating groundwater withdrawals [25]. For example, Luckey [15] proposes statistical methods to determine annual groundwater withdrawals in areas containing a high number of extraction wells, using regression analysis techniques or random sampling. This methodology was developed in the Arkansas River Valley, USA, where was used a random sample of 100 extraction wells in an area containing approximately 896 wells. Demonstrating that once the population type and the parameters for the year in which the random samples are collected are known, the annual groundwater withdrawals could be calculated using random sampling methods, being a solution applicable to any area with a large number of wells.

On the other hand, Baker Jr. [30] analyzed a small sample of well extraction values, using part of the statistical approach used by Luckey [15], which applied to western Kansas, USA, in an attempt to estimate groundwater extraction with acceptable accuracy over a large area. To evaluate such purpose, the following techniques were used: extrapolation of a groundwater withdrawals sample, crop requirements from rainfall and irrigated areas of various crops types, and withdrawals from a sample of power coefficients.

Harris and Diehl [43] compare three sets of Thermoelectric Water-Withdrawal data, one based on USGS compilation data [52], one based on Energy Information Administration (EIA) data, and one based on estimated USGS model data [53]. The purpose of this comparison is to better understand the uncertainties in the extraction data used in thermoelectric plants, so comparisons were made between subsets of plants with the same cooling system in pairs of datasets: USGS model vs. EIA, USGS model vs. USGS compilation, and EIA vs. USGS compilation. Quantifying the uncertainty in reported extraction data by defining agreed extraction and discrepant extraction. The minimum value is referred to as agreed extraction and is accounted for in each of the three datasets, whereas discrepant extraction is the calculated difference between the highest extraction rate and the agreed extraction rate that was present in all three datasets.

Additionally, seeking to involve users is a task that would facilitate the estimation of groundwater pumping; for example, Massuel et al. [14] did this with a user-oriented methodology, taking them as a starting point by involving them in the study in addition to the implementation of different types of sensors adapted to the conditions of the well or pump used for water extraction. This methodology is supported by a process of shared knowledge through the understanding of the users, who are involved by sharing information through surveys related to the configuration of the irrigation system, the cropping pattern and cropping calendar among others. The interviews were based on personal history in the area, the users' concern about water resources, etc. In this way, the farmers' habits and irrigation practices are related. Likewise, relating pumping to electrical expenditure could present a deficiency in the application of this method since the results obtained in this work indicated that the evaluation of groundwater withdrawals was exposed to the constant changes made by farmers in their equipment and farming systems. Similarly, Kent et al. [45] used an approach based on historical records of groundwater use trends and data hierarchy to establish the number of wells and their withdrawal characteristics. The first part of the model consists of determining the wells that may be extracting groundwater. A two-part approach was used for this first stage: (1) using a hierarchical approach for existing borehole datasets, giving priority to the highest quality/trusted data; and (2) for boreholes or wells where this information is not available, a spatial approach was developed to assign the location of those boreholes or wells. Subsequently, the type of use was established to determine withdrawals according to the purpose of the well or borehole, establishing a different methodology according to the use sector, e.g., livestock supply and domestic uses, discharge from uncontrolled artesian boreholes, water extraction in sectors of oil and gas uses. Estimation of groundwater use for each purpose and aquifer group was presented visually on a 50 km × 50 km mosaic grid, with weighted shading based on extraction volume.

3.2. Indirect Approaches to GWW Estimation

In this work, the estimation of the pumped volume based on the effects produced in the aquifer by the water extracted from the itself aquifer, or by the application of the water to a specific use, is referred to as indirect approaches and could be classified into five groups according to the characteristics and tools of the approach: estimation method based on crop water demands; estimation methods based on satellite data; water table fluctuation (WTF) method; groundwater modeling approach; and artificial intelligence-based methods [33].

Estimation method based on crop water demands: Among the commonly used approaches is to measure the irrigated crop area and multiply it by the water requirements of each crop; this approach is used in aquifers where the main activity is based on agriculture [54,55]. Such as Wray [39], who developed a study to estimate the withdrawal water volume of using techniques that combine multispectral data with groundwater pumping data for different cropping seasons. This method defines the location and extent of the lands that have crops, some of which may have variations of such crops. To define the crop characteristics, a computer analysis of the Landsat satellite data is performed, so that the amount of water used is calculated by accumulating the product of the crop area by

the average pumping for the water needs of each type of crop. Another example of this application is Tillman et al. [38], who estimated groundwater discharge based on natural vegetation for an area of over 190,000 km² using satellite remote sensing data for a watershed in the southwestern of Arizona, USA. Enhanced Vegetation Index (EVI) data from EOS-1 MODIS sensors were used. In addition, a relationship between evapotranspiration, EVI and temperature was established to calculate groundwater discharge from vegetation. The objective of this project was primarily focused on developing a simple method to determine GWW using vegetation in an area where detailed information on soil moisture and water table depth is not available. Bhadra et al. [23] evaluate three approaches—the first one is the discharge factor (DF), which is based on the groundwater consumption volume through wells per unit of crop area. The second approach was developed using linear groundwater consumption models (LGDM), which is based on the empirical relationship between satellite-derived crop area and groundwater consumption with respect to crop demand. The third approach was based on irrigated area, which is estimated by a sample survey of the different crops, water requirements and irrigation method. Of the three methods the LGDM proved to be the most realistic, demonstrating a good application of methods using satellite data in arid regions. Likewise, Dubois et al. [26] determine the water need in agricultural areas, where groundwater consumption is evaluated based on optical data obtained from the Sentinel-2 satellite for each season (summer or winter). The process consists of determining the Normalized Difference Vegetation Index (NDVI). NDVI profiles are created for the different types of crops, whose profiles are used to evaluate the crop surface with greater precision in different seasons of the year. It is possible to estimate the water consumption according to the crop needs and thus estimate the groundwater discharge by multiplying the crop surface by the corresponding water consumption of the vegetation. On the other hand, Casa et al. [24] carried out an estimation of crop water requirements in the Pontine plain, in central Italy, using remote sensing and the application of water balance in a GIS environment. The methodology, based on remote sensing and GIS, used four Landsat ETM+ images and meteorological and geographical vector layers. The study seeks to determine the water needs according to the type of crop, using a methodology based on crop evapotranspiration, monthly precipitation values and the water available in the soil of the plants. For this purpose, a hypothetical evapotranspiration mapping of the study area was developed using temperature and solar radiation records from five meteorological stations distributed within the study area. Crop coefficient maps were then developed based on water requirements, identifying crop classes, assigning each class a crop coefficient value. Finally, GIS techniques were used to develop maps representing crop evapotranspiration under standard conditions (crops under optimal conditions), which is the result of the hypothetical evaporation and crop coefficient maps. To estimate crop water demand, a methodology based on the distribution of water content in the soil was used, assuming that, for each month, if the amount of available water resulting from the sum of monthly rainfall and the water stored in the topsoil is sufficient to meet crop needs, irrigation is not necessary. Otherwise, if rainfall is insufficient and soil storage is depleted, there is a deficit that must be supplied by irrigation. The results of this study estimated a demand of 70 Mm³ per year, that is, 100 Mm³ per year of irrigation needs if an average irrigation application efficiency of 70% is considered. Additionally, this approach can be combined with other tools; for example, Alfaro et al. [42] uses the crop water demand-based method to determine groundwater withdrawals. However, their study is based on a groundwater model developed in MODFLOW, from the U.S. Geological Survey, and the main objective of their work is to present a numerical groundwater model that uses a limited (sparse) dataset that is applied to a real case study in a semi-arid region, adopting alternative methods to cope with data sparsity. Its process consists of developing a model based on GWW values using irrigated areas and crop water requirements, subsequently, these extractions serve as input for the WELL package in MODFLOW. The main steps are: (1) estimation of the total irrigated area (temporally and spatially), and (2) determination of crop water requirements that are input to the groundwater model.

On the other hand, Vu et al. [20] conducted an evaluation of groundwater exploitation by developing two approaches, the first one is based on local knowledge through a qualitative field study of groundwater level fluctuations and extractions. This first approach is based on the groundwater balance, which estimates the extraction with the remaining terms of the water balance equation, considering the knowledge of official sources to establish the variables that compose the equation. The second method is based on combined land use data and local knowledge on cultivation and irrigation practices, with this information and using land use and population maps, the GWW is estimated for each of the following groups: irrigation, domestic use and livestock.

Satellite-based estimation method: Methods based on teledetection and geographic information systems (GIS) can promote accuracy when estimating the exploitation of an aquifer [56]. For example, Ruud et al. [13] developed a GIS-based water balance model to estimate annual groundwater pumping applied in an agricultural area with a semi-arid climate in the southern San Joaquin Valley, California, USA. GIS-based hydrologic modeling gathers and processes available input data to calculate key components of the basin-scale water balance model, estimating and evaluating groundwater pumping and storage changes. Following the same approach, Ahmad et al. [40] propose a technique for estimating net groundwater use in large irrigated areas by combining teledetection and water balance. This methodology is based on the combined use of teledetection information and GIS techniques to estimate the components of the water balance which are: irrigation rate distribution, net precipitation rate, evapotranspiration rate, and change in soil moisture storage in the unsaturated zone. These can be used to estimate the groundwater net use in agriculture.

In the same way, Castaño et al. [32] present a methodology based on teledetection and GIS for the regulation and quantification of groundwater abstractions in regional aquifers for agricultural use in semi-arid climates. Based on the area used for agriculture and knowledge of the water requirements of each crop, the theoretical amount of water needed for those crops to reach the stage of development visible in the satellite images is calculated. Subsequently, when the area of crops dependent on groundwater collection and agricultural practices is known, a correction coefficient is applied to translate the theoretical amount of water to real values applied to each crop in the area. Finally, all the generated information (distributed in space and time) is integrated into a hydrological information system, which makes it possible to see the relationships between all the water balance elements.

On the other hand, Al-Bakri et al. [35] maintains the approach of Castaño et al. [32] by applying this methodology in Jordan, where was used geospatial techniques for auditing water for irrigation uses. The work was based on the evaluation of GWW records in relation to irrigated areas and estimated water consumption for crops in three river basins: Yarmouk, Amman-Zarqa and Azraq. Therefore, the mapping of irrigated areas and crop water requirements was developed using teledetection data from Landsat 8 satellite and meteorological records with daily periodicity. The methodology relied on visual interpretation and unsupervised classification for remote sensing data. Net (NCWR) and gross (GCWR) crop water requirements were calculated by merging crop evapotranspiration calculated from daily weather records. In addition, groundwater withdrawals records used for irrigation were compared against crop water consumption, assessing whether these records were within the safe yield range, which is known as the pumping rate at which groundwater can be withdrawn without causing a long-term decline in water levels.

Technological advances are relevant in approaches using GIS techniques, as they offer new opportunities for the application of teledetection and geographic information systems. For example, estimating GWW rates by constraining a hydrologic model by integrating a parallel flow simulator called ParFlow coupled to a community land model (CLM). ParFlow is a groundwater flow model that simulates spatially distributed surface and subsurface flow as well as land surface processes including evapotranspiration and snowpack developed as a collaborative effort among several institutions: the Juélich

Research Center, Princeton University, Lawrence Livermore National Laboratory, Colorado School of Mines, the University of Bonn, Washington State University, Syracuse University, and the University of Grenoble Alpes [57,58]. On the other hand, the Common Land Model was developed as a multi-institutional code by a grassroots collaboration of scientists who have an interest in making a general land model (Land Model) [59]. In this approach, water storage changes modeled by ParFlow-CLM are fitted to water storage anomaly estimates from NASA's Gravity Recovery and Climate Experiment (GRACE) satellite and historical water table elevation data by dynamically adjusting groundwater pumping rates; likewise, variable irrigation rates based on soil moisture deficits and crop demand are applied in the model [60,61].

For their part, Parizi et al. [33] use an approach called "representative pumping well network" (RPWN). This methodology is based on the superposition of ten important characteristics—(1) type of alluvial deposits; (2) aquifer thickness; (3) pumping well saturation thickness; (4) pumping flow rate; (5) annual pumping time; (6) pump outlet pipe diameter; (7) transmissivity; (8) type of water consumption; (9) land use/land cover; and (10) distance of the well from main roads. All of these characteristics are applied in a GIS environment that classifies into a series of zones in which their withdrawals are statistically different. In this way, the GIS platform incorporates the hydrogeological characteristics of the aquifer and the properties of the pumping wells to estimate the total GWW of the aquifer by pumping wells.

Forstner and Gleeson [19] use a methodology based on the sectoral method to determine the GWW by different sectors and uses, such as fish aquaculture, agricultural, industrial, domestic and private use. In each of the sectors, a methodology is established based on different criteria that facilitate the estimation of the groundwater volume for each sector, in this way, discharges are attributed to a percentage that may well be population, type of product manufactured by the industry or discharge volumes associated with agriculture. In addition, groundwater use was classified under the following criteria: the first by distribution, either through municipal water systems or through private wells, and the second by the main sectors of groundwater use (domestic, industrial, agriculture and fish aquaculture). Thus, this methodology has been successfully approached using GIS techniques to characterize the areas.

On the other hand, Ray et al. [29] seek to estimate groundwater consumption for irrigation at small scales by studying the spatio-temporal patterns of groundwater consumption and using measurements from 43 wells located in different hydrostratigraphic units. Additionally, surveys were used, which included obtaining information from well/borehole owners on monthly pumping hours and other details related to cultivation practices. As a result, the creation of a small-scale GIS-based database of the number of extraction structures and groundwater consumption was obtained.

Groundwater modeling approach: In this approach, the number of pumping wells and the extraction volume are calibrated using a numerical model of the groundwater system [33]. For example, Moreo et al. [36] used a groundwater flow model to estimate GWW in Death Valley, Nevada and California, USA. The extraction locations were estimated using the numerical model. This approach was also applied by Martos-Rosillo et al. [18] in the province of Seville, Spain, using time series analysis and a numerical groundwater model to quantify groundwater exploitation and estimate the mean annual recharge in two carbonate aquifers. Meanwhile, Tsanis and Apostolaki [21] present a method for estimating annual groundwater extraction based on the water balance, considering the discharge of a basin in combination with measurements of the groundwater extracted volume.

On the other hand, Shao et al. [37] used an inversion method of the water balance principle, estimating the GWW by adjusting the simulated groundwater levels with the observed ones based on the concept in which the condition in which groundwater extraction is lower than the actual amount, the simulated groundwater level would be higher than the actual level, and vice versa by establishing an equilibrium equation according to the groundwater extraction in the model. For this purpose, they used a well-calibrated

groundwater model. The principles of the inversion method proposed in this study are based on the water balance and hydrogeological characteristics of the study area. To cope with a large number of pumping wells during the inversion procedure, the study area was divided into pumping subareas. The GWW estimation was raised based on the numerical groundwater model, doing adjustments to groundwater withdrawals based on the inversion method, establishing that the best fit is obtained when the difference between observed and simulated water table levels is lower than those set by the user.

Likewise, Su et al. [34] established a groundwater flow and land subsidence modeling in the flat area of Tianjin, China, where land subsidence is posited as a result of groundwater exploitation. Hydrogeological and geological information, as well as groundwater monitoring data parameters (such as groundwater level and land subsidence value) were used. To better understand the correlation between groundwater exploitation and land subsidence, the groundwater flow simulation program MODFLOW (from the USGS) and the land subsidence simulation package were used. Groundwater flow in the study area was considered as a 3D flow through a porous medium, and land subsidence is considered as a one-dimensional vertical deformation. The annual groundwater exploitation value was estimated by adjusting the calculated water table with the observed water table.

Lin et al. [27] employ the soil and water assessment tool known as SWAT (Soil and Water Assessment Tool) as well as MODFLOW (USGS) to separately run and acquire certain hydrological components such as recharge and storage change. Subsequently, it uses the water balance method to estimate pumping rates with these components. In this methodology SWAT is used to accurately estimate vertical recharge and identify potential recharge zones based on the physical characteristics of the watershed. Subsequently, storage and net infiltration are estimated with MODFLOW according to hydrogeological characteristics, and finally the water balance method is applied to estimate pumping rates.

Liu et al. [28] developed a method for the characterization and quantification of regional groundwater pumping using pumping source identification that combines signal analysis with a groundwater flow simulation model. The method focuses on two parts, the first uses independent component analysis (ICA) to identify the main pumping types and variations in groundwater elevations that generate these signals. This relates a signal to each type of pumping, either for agricultural or industrial use. Second, the groundwater model is used to estimate and quantify the amount of pumping for each type of signal, matching the simulation to variations in the water table.

Water table fluctuation method (WTF): This approach uses the relationship between the change in groundwater storage with fluctuations in water tables (specific yield in the case of unconfined aquifers), which is based on the assumption that the increase in the water table at an observation point during the recharge season is caused by recharge through the water table, and such an increase is multiplied by the specific yield to obtain a direct estimate of recharge [21]. Usually, the water table fluctuation method is combined with the groundwater balance equation and a geostatistical method to estimate the annual GWW pumping [33]. For example, Martínez-Santos and Martínez-Alfaro [31] developed an adaptation of the WTF method to estimate groundwater pumping in agricultural areas of central Spain, coupling the water table fluctuation method with the groundwater equilibrium equation. Similarly, Yang et al. [22] developed a modified WTF method to quantitatively characterize regional groundwater discharge patterns in aquifers under stress caused by intensive agricultural pumping. The study develops the method called water table fluctuation regression (WTFR) and is designed to characterize systems that are driven by both precipitation recharge and net discharge processes, as the basis of the method the water table hydrograph at an observation point is defined by two parameters: infiltration efficiency and discharge modulus. The former is a relationship between the amount of precipitation and the increase in the water table and the latter is a 12-element matrix representing the net discharge pattern, defining the discharge modulus as the net head reduction due to the collective result of pumping discharge and irrigation return.

Artificial intelligence-based methods: The necessity to address groundwater problems using alternative techniques that can be relatively simpler and less expensive has led researchers in different parts of the world to explore machine learning (ML)-based models [62]. Machine learning methods have been widely used in recent years in many fields of water resources (e.g., [63–65]). Some of the models based on artificial intelligence and machine learning techniques are artificial neural networks (ANNs) and adaptive neuro-fuzzy inference systems (ANFIS), which have been developed recently and have demonstrated their effectiveness in hydrological system applications [66,67]. Therefore, the application of artificial intelligence-based methods for GWW determination is a tool that authors resort to; for example, Majumdar et al. [44] approaches the correlations between various water balance measurements and groundwater withdrawals in a machine learning framework, which learns the relationship between different datasets and uses them predictively. The machine learning approach to predict local-scale groundwater withdrawals uses raster and vector files with 5 km spatial resolution, taking information from various satellite, e.g., evapotranspiration (MODIS), precipitation (PRISM), and land use data (USDA-NASS), which are related in different ways to groundwater withdrawals. On the other hand, Li et al. [25] developed an artificial neural network (ANN) model based on the back-propagation algorithm to estimate groundwater discharge. For this purpose, water table, precipitation and groundwater discharge were set as inputs to the ANNs, using 5 hidden layers and 144 data from the groundwater discharge records to train the ANNs. The results are compared with official data and water balance method.

4. Discussions

Establishing an optimal method to quantify groundwater discharge is complicated, thus it could be inferred that direct methods are the oldest and most reliable; however, this is not always the case due to the uncertainty they may present at the time of taking measurements, which could be attributed to human error or failures in the measurement systems themselves, temporary abatement cones, occasional or emergency uses, etc. In addition, the difficulty and high costs at the time of its implementation mean that it becomes a complicated method to execute in areas that have a large number of extraction wells, whose extension and intensive agricultural use means that these methods are not very applicable or when the users have different interests, such as private wells, federal wells and when the sectors are different, such as industrial, agricultural or urban. These are some of the major challenges faced by direct measurements. Some applications face this problem by using electrical measurement records, statistical methods and methodologies based on the participation of farmers, trying to establish greater reliability in direct measurement records, since an advantage of these methods is the security they can provide to obtain accurate measurements, which in some cases serve as a starting point for the development of an indirect method.

On the other hand, indirect methods are a relatively inexpensive solution to address some of the limitations involved in direct methods; however, there are certain considerations among the five groups described above.

Estimation method based on crop water requirements: Among the main characteristics of this method is the possibility of using the vegetation cover of a given area together with the estimation of crop water demands, allowing the estimation of groundwater pumping based on the crop type and its water demands. This approach shares a strong link with advances in teledetection techniques and geographic information systems, allowing spatial and temporal tracking of vegetation cover. However, on its own it has some drawbacks, since crop water demands can vary due to climatic conditions such as rainfall or temperature, and it also involves determining and monitoring agricultural practices, which can be a challenge. Nevertheless, this method is an interesting alternative if the study area is mainly dominated by agriculture.

Methods based on groundwater flow modeling have some advantages since they use groundwater monitoring and time series data, which allows dynamic monitoring

to estimate groundwater exploitation, and are models used to understand an aquifer system, characterize groundwater flow and simulate different management scenarios. A disadvantage of the groundwater modeling approach is the need to know all the elements that describe the aquifer in terms of time and space, and the difficulty increases when the number of pumping wells is large. In addition, the limitation of human resources, materials and technological methods makes it difficult to obtain sufficient and important data—for example, the complexity of the aquifer, such as the presence of clay lenses, the presence of confined or semi-confined aquifers, carbonate aquifers, outcrops, subsidence and compaction. This makes it possible for this approach to be used in areas with a reduced number of extraction wells, and it has a good potential for adaptation with other tools or methods.

The WTF method is mainly designed for natural systems. It has important limitations since it does not take into account water table fluctuations resulting from pumping; therefore, it receives adaptations to determine water withdrawals. In some cases, adaptations of this approach aggregate discharge signals; however, they may not consider some important aspects such as evapotranspiration as a significant factor for water table fluctuations if the aquifer is shallow. This approach benefits when applied for short periods in regions with strong water table fluctuations.

The estimation method based on satellite data is usually a feasible solution that relies on modern tools such as satellite information, which makes it possible to evaluate land and water resources, and the coupling with teledetection methods and geographic information systems is a very good combination, since it is a cost-effective way to obtain large-scale information. However, it may present some difficulties due to the integration of the different spatial and temporal resolutions that can be obtained from satellite data. This approach has a great applicability in large scale areas.

Methods based on artificial intelligence allow the implementation of technological advances in data analysis in a simple way, taking advantage of the correlation between the various datasets that can be both water balance and groundwater withdrawals, creating a learning framework, in addition, it can be used in a predictive way; however, its great disadvantage is the availability of data. Sometimes it is not possible to obtain updated information or there are important gaps in the time series; this could be a disadvantage if the training of the model depends on historical data. This approach has great versatility to be adapted with other tools.

5. Conclusions

A review of direct and indirect methods has been carried out, and the results are summarized and organized in Table 1 so that the trends in recent years can be identified, with partial and general results, which can provide guidelines applicable to researchers who want to perform similar work in this field. Likewise, the different methods for groundwater pumping estimation that have been reviewed in this paper have advantages and disadvantages in their application. Direct approaches are very old and still work; the uncertainty in their application comes from possible human errors or in the measurement system, in addition to the irrigation tendencies by the farmers that also play an important role in the application of direct approaches. Such methods were widely used in the 1970s; however, it is very costly to implement measurement devices in areas with a large number of extraction wells. On the other hand, indirect methods have evolved along with technological advances. The first indirect approaches were based on crop water demands, with remote sensing data and satellite information playing a very important role, which have brought significant improvements and precision to this approach. Additionally, numerical models are of great importance in the estimation of groundwater pumping based on the principle of water balance, the structure of aquifer systems, model boundaries, recharge and discharge conditions. The trend in recent years of this approach is inclined toward coupling with other techniques. The adaptation of the WTF method to estimate groundwater pumping is still available in a few studies; however, it has demonstrated

its applicability to assess the estimation of groundwater pumping. For their part, the methods based on teledetection and GIS for groundwater pumping estimation are those that have shown a significant increase in their applications, with the trend in recent years, via technological advances, making application easy in large areas with access to satellite databases. Finally, artificial intelligence-based approaches have proven to establish a learning framework applicable in the field of groundwater pumping estimation; however, they are just beginning to be applied. Therefore, defining an appropriate model will depend on the purpose of the model and also on other factors such as data availability and computational power.

Author Contributions: M.A.M.-G.: conceptualization; M.A.M.-G.: investigation; M.A.M.-G., J.R.C.-G., J.R.-H., C.S.H.-O., J.J.V.-L. and A.F.-N.: data organization; M.A.M.-G.: writing—original draft; M.A.M.-G., J.R.C.-G., J.R.-H., C.S.H.-O., J.J.V.-L. and A.F.-N.: writing—review and editing; J.R.-H., C.S.H.-O., J.J.V.-L. and A.F.-N.: supervision; J.R.C.-G.: project administration. All authors have read and agreed to the published version of the manuscript.

Funding: Authors appreciate the doctoral scholarship granted to Marco Antonio Meza Gastelum from Mexican National Council for Science and Technology (CONACYT) grant number 4.5 UMA.

Conflicts of Interest: The authors state that they have no conflict of interest to declare.

References

- Petronici, F.; Pujades, E.; Jurado, A.; Marcaccio, M.; Borgatti, L. Numerical Modelling of the Mulino Delle Vene Aquifer (Northern Italy) as a Tool for Predicting the Hydrogeological System Behavior under Different Recharge Conditions. *Water* **2019**, *11*, 2505. [\[CrossRef\]](#)
- Kundzewicz, Z.W.; Döl, P. Will groundwater ease freshwater stress under climate change? *Hydrol. Sci. J.* **2009**, *54*, 665–675. [\[CrossRef\]](#)
- Martínez-Santos, P.; Castaño-Castaño, S.; Hernández-Espriú, A. Revisiting groundwater overdraft based on the experience of the Mancha Occidental Aquifer, Spain. *Appl. Hydrogeol.* **2018**, *26*, 1083–1097. [\[CrossRef\]](#)
- FAO. *Escasez de Agua: Uno de Los Grandes Retos de Nuestro Tiempo*; The Food and Agriculture Organization of the United Nations: Rome, Italy, 2017. Available online: www.fao.org (accessed on 25 September 2021).
- Döll, P.; Hoffmann-Dobrev, H.; Portmann, F.; Siebert, S.; Eicker, A.; Rodell, M.; Strassberg, G.; Scanlon, B. Impact of water withdrawals from groundwater and surface water on continental water storage variations. *J. Geodyn.* **2012**, *59–60*, 143–156. [\[CrossRef\]](#)
- Famiglietti, J.S.; Lo, M.; Ho, S.L.; Bethune, J.; Anderson, K.J.; Syed, T.H.; Rodell, M. Satellites measure recent rates of groundwater depletion in California's Central Valley. *Geophys. Res. Lett.* **2011**, *38*, L03403. [\[CrossRef\]](#)
- Margat, J.; Foster, S.; Droubi, A. Concept and importance of non-renewable resources. In *Non-Renewable Groundwater Resources: A Guidebook on Socially-Sustainable Management for Water-Policy Makers*; UNESCO: London, UK, 2006.
- Amiri, V.; Nakhaei, M.; Lak, R.; Kholghi, M. Assessment of seasonal groundwater quality and potential saltwater intrusion: A study case in Urmia coastal aquifer (NW Iran) using the groundwater quality index (GQI) and hydrochemical facies evolution diagram (HFE-D). *Stoch. Environ. Res. Risk Assess.* **2016**, *30*, 1473–1484. [\[CrossRef\]](#)
- Wada, Y.; Van Beek, L.P.H.; Van Kempen, C.M.; Reckman, J.W.T.M.; Vasak, S.; Bierkens, M.F.P. Global depletion of groundwater resources. *Geophys. Res. Lett.* **2010**, *37*, L20402. [\[CrossRef\]](#)
- Chang, F.-J.; Huang, C.-W.; Cheng, S.-T.; Chang, L.-C. Conservation of groundwater from over-exploitation—Scientific analyses for groundwater resources management. *Sci. Total Environ.* **2017**, *598*, 828–838. [\[CrossRef\]](#)
- Panahi, M.; Sadhasivam, N.; Pourghasemi, H.R.; Rezaie, F.; Lee, S. Spatial prediction of groundwater potential mapping based on convolutional neural network (CNN) and support vector regression (SVR). *J. Hydrol.* **2020**, *588*, 125033. [\[CrossRef\]](#)
- Hera-Portillo, Á.D.; López-Gutiérrez, J.; Mayor, B.; López-Gunn, E.; Henriksen, H.J.; Gejl, R.N.; Martínez-Santos, P. An Initial Framework for Understanding the Resilience of Aquifers to Groundwater Pumping. *Water* **2021**, *13*, 519. [\[CrossRef\]](#)
- Ruud, N.; Harter, T.; Naugle, A. Estimation of groundwater pumping as closure to the water balance of a semi-arid, irrigated agricultural basin. *J. Hydrol.* **2004**, *297*, 51–73. [\[CrossRef\]](#)
- Massuel, S.; Amichi, F.; Ameer, F.; Calvez, R.; Jenhaoui, Z.; Bouarfa, S.; Kuper, M.; Habaieb, H.; Hartani, T.; Hammani, A. Considering groundwater use to improve the assessment of groundwater pumping for irrigation in North Africa. *Appl. Hydrogeol.* **2017**, *25*, 1565–1577. [\[CrossRef\]](#)
- Luckey, R.R. Analyses of selected statistical methods for estimating groundwater withdrawal. *Water Resour. Res.* **1972**, *8*, 205–210. [\[CrossRef\]](#)
- Page, M.J.; McKenzie, J.E.; Bossuyt, P.M.; Boutron, I.; Hoffmann, T.C.; Mulrow, C.D.; Shamseer, L.; Tetzlaff, J.M.; Akl, E.A.; Brennan, S.E.; et al. The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ* **2021**, *372*, n71. [\[CrossRef\]](#) [\[PubMed\]](#)

17. Bierkens, M.F.P.; Reinhard, S.; De Bruijn, J.A.; Veninga, W.; Wada, Y. The Shadow Price of Irrigation Water in Major Groundwater-Depleting Countries. *Water Resour. Res.* **2019**, *55*, 4266–4287. [[CrossRef](#)]
18. Martos-Rosillo, S.; Rodríguez-Rodríguez, M.; Moral, F.; Cruz-Sanjulián, J.J.; Rubio, J.C. Analysis of groundwater mining in two carbonate aquifers in Sierra de Estepa (SE Spain) based on hydrodynamic and hydrochemical data. *Appl. Hydrogeol. J.* **2009**, *17*, 1617–1627. [[CrossRef](#)]
19. Forstner, T.; Gleeson, T. Unseen and overlooked: Methods for quantifying groundwater abstraction from different sectors in a data-scarce region, British Columbia, Canada. *Can. Water Resour. J. Rev. Can. Ressour. Hydr.* **2019**, *44*, 382–400. [[CrossRef](#)]
20. Vu, H.; Shanafield, M.; Nhat, T.; Partington, D.; Batelaan, O. Mapping catchment-scale unmonitored groundwater abstractions: Approaches based on soft data. *J. Hydrol. Reg. Stud.* **2020**, *30*, 100695. [[CrossRef](#)]
21. Tsanis, I.K.; Apostolaki, M.G. Estimating Groundwater Withdrawal in Poorly Gauged Agricultural Basins. *Water Resour. Manag.* **2009**, *23*, 1097–1123. [[CrossRef](#)]
22. Yang, L.; Qi, Y.; Zheng, C.; Andrews, C.B.; Yue, S.; Lin, S.; Li, Y.; Wang, C.; Xu, Y.; Li, H. A Modified Water-Table Fluctuation Method to Characterize Regional Groundwater Discharge. *Water* **2018**, *10*, 503. [[CrossRef](#)]
23. Bhadra, B.K.; Kumar, S.; Paliwal, R.; Jayaseelan, A.T. Modeling of groundwater draft based on satellite-derived crop acreage estimation over an arid region of northwest India. *Appl. Hydrogeol.* **2016**, *24*, 1681–1698. [[CrossRef](#)]
24. Casa, R.; Rossi, M.; Sappa, G.; Trotta, A. Assessing Crop Water Demand by Remote Sensing and GIS for the Pontina Plain, Central Italy. *Water Resour. Manag.* **2009**, *23*, 1685–1712. [[CrossRef](#)]
25. Li, D.; Hu, L.; Zhang, M.; Liu, X. Evaluation of groundwater withdrawals in Tongzhou District, Beijing, China. *Hum. Ecol. Risk Assess. Int. J.* **2019**, *1*–17. [[CrossRef](#)]
26. Dubois, C.; Stoffner, F.; Kalia, A.C.; Sandner, M.; Labiadh, M.; Mimouni, M. Copernicus sentinel-2 data for the determination of groundwater withdrawal in the maghreb region. *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.* **2018**, *4*, 37–44. [[CrossRef](#)]
27. Lin, H.-T.; Ke, K.-Y.; Tan, Y.-C.; Wu, S.-C.; Hsu, G.; Chen, P.-C.; Fang, S.-T. Estimating Pumping Rates and Identifying Potential Recharge Zones for Groundwater Management in Multi-Aquifers System. *Water Resour. Manag.* **2013**, *27*, 3293–3306. [[CrossRef](#)]
28. Liu, H.-J.; Hsu, N.-S.; Yeh, W.W.-G. Independent component analysis for characterization and quantification of regional groundwater pumping. *J. Hydrol.* **2015**, *527*, 505–516. [[CrossRef](#)]
29. Ray, R.K.; Syed, T.H.; Saha, D.; Sarkar, B.C.; Patre, A.K. Assessment of village-wise groundwater draft for irrigation: A field-based study in hard-rock aquifers of central India. *Appl. Hydrogeol.* **2017**, *25*, 2513–2525. [[CrossRef](#)]
30. Baker, C.H., Jr. *Evaluation of Methods for Estimating Groundwater Withdrawals in Western Kansas*; US Geological Survey: Drive Reston, VA, USA, 1979.
31. Martínez-Santos, P.; Martínez-Alfaro, P. Estimating groundwater withdrawals in areas of intensive agricultural pumping in central Spain. *Agric. Water Manag.* **2010**, *98*, 172–181. [[CrossRef](#)]
32. Castaño, S.; Sanz, D.; Gómez-Alday, J.J. Methodology for Quantifying Groundwater Abstractions for Agriculture via Remote Sensing and GIS. *Water Resour. Manag.* **2010**, *24*, 795–814. [[CrossRef](#)]
33. Parizi, E.; Hosseini, S.M.; Ataie-Ashtiani, B.; Simmons, C.T. Representative pumping wells network to estimate groundwater withdrawal from aquifers: Lessons from a developing country, Iran. *J. Hydrol.* **2019**, *578*, 124090. [[CrossRef](#)]
34. Su, C.; Cui, Y.L.; Wang, L.C.; Li, L. Estimation of the Groundwater Exploitation Based on Land Subsidence Numerical Model: A Case Study in the Plain Area of Tianjin. *Adv. Mater. Res.* **2012**, *610–613*, 2734–2739. [[CrossRef](#)]
35. Al-Bakri, J.T.; Shawash, S.; Ghanim, A.; AbdelKhaleq, R. Geospatial Techniques for Improved Water Management in Jordan. *Water* **2016**, *8*, 132. [[CrossRef](#)]
36. Moreo, M.T.; Halford, K.J.; La Camera, R.J.; Laczniak, R.J. Estimated ground-water withdrawals from the Death Valley regional flow system, Nevada and California, 1913–98. *Water Resour. Investig. Rep.* **2003**, 4245.
37. Shao, J.; Cui, Y.; Hao, Q.; Han, Z.; Cheng, T. Study on the estimation of groundwater withdrawals based on groundwater flow modeling and its application in the North China Plain. *J. Earth Sci.* **2014**, *25*, 1033–1042. [[CrossRef](#)]
38. Tillman, F.; Callegary, J.; Nagler, P.; Glenn, E. A simple method for estimating basin-scale groundwater discharge by vegetation in the basin and range province of Arizona using remote sensing information and geographic information systems. *J. Arid Environ.* **2012**, *82*, 44–52. [[CrossRef](#)]
39. Wray, J.R. Estimating irrigation water use and withdrawal of ground water on the High Plains, U.S.A. *Adv. Space Res.* **1982**, *2*, 127–129. [[CrossRef](#)]
40. Ahmad, M.-U.; Bastiaarssen, W.G.M.; Feddes, R.A. A new technique to estimate net groundwater use across large irrigated areas by combining remote sensing and water balance approaches, Rechna Doab, Pakistan. *Appl. Hydrogeol.* **2005**, *13*, 653–664. [[CrossRef](#)]
41. Ogilbee, W.; Mitten, H.T. *A Continuing Program for Estimating Ground-Water Pumpage in California—Methods*; US Geological Survey: Drive Reston, VA, USA, 1970. [[CrossRef](#)]
42. Alfaro, P.; Liesch, T.; Goldscheider, N. Modelling groundwater over-extraction in the southern Jordan Valley with scarce data. *Appl. Hydrogeol.* **2017**, *25*, 1319–1340. [[CrossRef](#)]
43. Harris, M.A.; Diehl, T.H. A Comparison of Three Federal Datasets for Thermoelectric Water Withdrawals in the United States for 2010. *JAWRA J. Am. Water Resour. Assoc.* **2017**, *53*, 1062–1080. [[CrossRef](#)]
44. Majumdar, S.; Smith, R.; Butler, J.J.; Lakshmi, V.J., Jr. Groundwater Withdrawal Prediction Using Integrated Multitemporal Remote Sensing Data Sets and Machine Learning. *Water Resour. Res.* **2020**, *56*, e2020WR028059. [[CrossRef](#)]

45. Kent, C.R.; Pandey, S.; Turner, N.; Dickinson, C.G.; Jamieson, M. Estimating current and historical groundwater abstraction from the Great Artesian Basin and other regional-scale aquifers in Queensland, Australia. *Appl. Hydrogeol.* **2020**, *28*, 393–412. [CrossRef]
46. Martindill, J.R.; Good, R.T.; Loge, F.J. Estimating Agricultural Groundwater Withdrawals with Energy Data. *J. Water Resour. Plan. Manag.* **2021**, *147*, 04021018. [CrossRef]
47. Hurr, R.; Litke, D. *Estimating Pumping Time and Ground-Water Withdrawals Using Energy-Consumption Data*; Department of the Interior, US Geological Survey: Drive Reston, VA, USA, 1989. [CrossRef]
48. Austin, C. Reactions: Legislators and Organizations Respond to the Passage of Groundwater Legislation. 2014. Available online: <https://mavensnotebook.com/2014/08/30/reactions-legislators-and-organizations-respond-to-the-passage-of-groundwater-legislation/> (accessed on 13 October 2021).
49. Richey, A.S.; Thomas, B.F.; Lo, M.-H.; Reager, J.T.; Famiglietti, J.S.; Voss, K.; Swenson, S.; Rodell, M. Quantifying renewable groundwater stress with GRACE. *Water Resour. Res.* **2015**, *51*, 5217–5238. [CrossRef]
50. Haiduk, A.; Ishemo, A.A. Energy Demand Considerations for the Supply of Domestic Water in Jamaica. *Int. J. Water Resour. Dev.* **2011**, *27*, 759–768.
51. Karimi, P.; Qureshi, A.S.; Bahramloo, R.; Molden, D. Reducing carbon emissions through improved irrigation and groundwater management: A case study from Iran. *Agric. Water Manag.* **2012**, *108*, 52–60. [CrossRef]
52. Maupin, M.A.; Kenny, J.F.; Hutson, S.S.; Lovelace, J.K.; Barber, N.L.; Linsey, K.S. *Estimated Use of Water in the United States in 2010*; US Geological Survey: Drive Reston, VA, USA, 2014.
53. Diehl, T.H.; Harris, M.A. Withdrawal and Consumption of Water by Thermoelectric Power Plants in the United States, 2010. In *Scientific Investigations Report*; US Geological Survey: Reston, VA, USA, 2014; p. 38.
54. Belmonte, A.C.; Jochum, A.M.; Garcia, A.C.; Rodriguez, A.M.; Fuster, P.L. Irrigation management from space: Towards user-friendly products. *Irrig. Drain. Syst.* **2005**, *19*, 337–353. [CrossRef]
55. Zhang, Y.; Gong, H.; Gu, Z.; Wang, R.; Li, X.; Zhao, W. Characterization of land subsidence induced by groundwater withdrawals in the plain of Beijing city, China. *Appl. Hydrogeol.* **2014**, *22*, 397–409. [CrossRef]
56. Joodaki, G.; Wahr, J.; Swenson, S. Estimating the human contribution to groundwater depletion in the Middle East, from GRACE data, land surface models, and well observations. *Water Resour. Res.* **2014**, *50*, 2679–2692. [CrossRef]
57. Jones, J.E.; Woodward, C.S. Newton–Krylov-multigrid solvers for large-scale, highly heterogeneous, variably saturated flow problems. *Adv. Water Resour.* **2001**, *24*, 763–774. [CrossRef]
58. Kollet, S.J.; Maxwell, R.M. Capturing the influence of groundwater dynamics on land surface processes using an integrated, distributed watershed model. *Water Resour. Res.* **2008**, *44*, W02402. [CrossRef]
59. Dai, Y.; Zeng, X.; Dickinson, R.E.; Baker, I.; Bonan, G.B.; Bosilovich, M.G.; Yang, Z.L. The common land model (CLM). *Bull. Am. Meteorol. Soc.* **2003**, *84*, 1013–1023. [CrossRef]
60. Thatcher, L.M.; Maxwell, R.M.; Gilbert, J.M.; Condon, L.E. Evaluating Groundwater Use and Sustainability in the California Central Valley: Using Remote Sensing Data to Dynamically Constrain Groundwater Extraction Rates in an Integrated Hydrologic Model. In *AGU Fall Meeting Abstracts*; AGU: Washington, DC, USA, 2018; p. H21H-1731.
61. Thatcher, L.M.; Gilbert, J.M.; Maxwell, R.M. Remotely estimating groundwater pumping and irrigation: A synthesis approach using GRACE and advances in integrated hydrologic modeling. In *AGU Fall Meeting Abstracts*; AGU: Washington, DC, USA, 2019; p. H43M-2225.
62. Di Salvo, C. Improving Results of Existing Groundwater Numerical Models Using Machine Learning Techniques: A Review. *Water* **2022**, *14*, 2307. [CrossRef]
63. Ch, A.; Ch, R.; Gadamsetty, S.; Iwendi, C.; Gadekallu, T.R.; Ben Dhaou, I. ECDSA-Based Water Bodies Prediction from Satellite Images with UNet. *Water* **2022**, *14*, 2234. [CrossRef]
64. Fienen, M.N.; Nolan, B.T.; Kauffman, L.J.; Feinstein, D.T. Metamodeling for Groundwater Age Forecasting in the Lake Michigan Basin. *Water Resour. Res.* **2018**, *54*, 4750–4766. [CrossRef]
65. Arsene, D.; Predescu, A.; Pahonțu, B.; Chiru, C.G.; Apostol, E.-S.; Truică, C.-O. Advanced Strategies for Monitoring Water Consumption Patterns in Households Based on IoT and Machine Learning. *Water* **2022**, *14*, 2187. [CrossRef]
66. Emamgholizadeh, S.; Moslemi, K.; Karami, G. Prediction the Groundwater Level of Bastam Plain (Iran) by Artificial Neural Network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS). *Water Resour. Manag.* **2014**, *28*, 5433–5446. [CrossRef]
67. Güldal, V.; Tongal, H. Comparison of Recurrent Neural Network, Adaptive Neuro-Fuzzy Inference System and Stochastic Models in Eğirdir Lake Level Forecasting. *Water Resour. Manag.* **2010**, *24*, 105–128. [CrossRef]

APÉNDICE B

En la Tabla B1 se presenta una muestra de las distintas arquitecturas exploradas en este trabajo, cuya diversidad se denota como $(ExCOxC_i)$, donde E indica el número de elementos en la capa de entrada, CO el número de capas ocultas y C_i el número de neuronas en su capa oculta (el subíndice i puede tomar valores de 1 a 3). Para todos los modelos se evaluaron con una salida la cual representa la descarga.

Tabla B1. Muestra de los modelos neuronales explorados en este trabajo

E	CO	Número de neuronas			Función de Activación			Épocas promedio	RMSE		
		C ₁	C ₂	C ₃	C ₁	C ₂	C ₃		1989	1995	1997
4	1	4	-	-	ReLU	-	Lineal	548	14.32	-	-
4	2	11	11	-	ReLU	-	Lineal	500	5.83	5.23	-
4	2	13	13	-	ReLU	-	Lineal	500	5.96	5.10	5.79
4	2	15	15	-	ReLU	-	Lineal	528	3.06	3.38	3.05
4	3	4	4	4	ReLU	ReLU	Lineal	506	3.32	3.07	3.03
4	3	5	5	5	ReLU	ReLU	Lineal	427	2.60	2.56	2.24
4	3	7	7	7	ReLU	ReLU	Lineal	459	3.28	3.16	3.30
4	3	9	9	9	ReLU	ReLU	Lineal	450	3.22	3.25	3.10
4	3	11	11	11	ReLU	ReLU	Lineal	462	3.35	3.18	3.23
4	3	13	13	13	ReLU	ReLU	Lineal	465	3.15	3.47	3.35
4	3	15	15	15	ReLU	ReLU	Lineal	466	3.11	3.45	3.38
5	1	4	-	-	ReLU	-	Lineal	510	8.33	-	-
5	2	15	15	-	ReLU	-	Lineal	418	3.91	3.94	3.92
5	3	5	5	5	ReLU	ReLU	Lineal	407	3.49	3.31	3.40
5	3	7	7	7	ReLU	ReLU	Lineal	414	3.30	3.50	3.38
5	3	9	9	9	ReLU	ReLU	Lineal	411	3.31	3.47	3.31
5	3	11	11	11	ReLU	ReLU	Lineal	414	3.10	3.09	3.10
5	3	13	13	13	ReLU	ReLU	Lineal	414	2.86	2.71	2.82
5	3	15	15	15	ReLU	ReLU	Lineal	415	2.55	2.52	2.44
6	1	4	-	-	ReLU	-	Lineal	503	7.88	-	-
6	3	5	5	5	ReLU	ReLU	Lineal	425	3.26	-	-
6	3	7	7	7	ReLU	ReLU	Lineal	420	3.04	-	-

Tabla B1 (Continuación). Muestra de los modelos neuronales explorados en este trabajo

E	CO	Número de neuronas			Función de Activación			Épocas promedio	RMSE		
		C ₁	C ₂	C ₃	C ₁	C ₂	C ₃		1989	1995	1997
6	3	9	9	9	ReLU	ReLU	Lineal	420	3.03	3.02	3.01
6	3	11	11	11	ReLU	ReLU	Lineal	425	2.97	2.94	2.97
6	3	13	13	13	ReLU	ReLU	Lineal	414	2.89	2.92	2.86
6	3	15	15	15	ReLU	ReLU	Lineal	397	2.70	2.50	2.55
4	1	4	-	-	Sigmoide	-	Lineal	623	14.68	-	-
4	2	15	15	-	Sigmoide	-	Lineal	637	11.66	-	-
4	3	4	4	4	Sigmoide	Sigmoide	Lineal	638	8.24	-	-
4	3	5	5	5	Sigmoide	Sigmoide	Lineal	635	7.32	-	-
4	3	15	15	15	Sigmoide	Sigmoide	Lineal	658	7.36	-	-
5	3	4	4	4	Sigmoide	Sigmoide	Lineal	603	5.09	5.02	-
5	3	5	5	5	Sigmoide	Sigmoide	Lineal	607	5.02	5.14	-
5	3	7	7	7	Sigmoide	Sigmoide	Lineal	605	5.12	5.15	-
5	3	9	9	9	Sigmoide	Sigmoide	Lineal	609	5.03	5.08	-
5	3	11	11	11	Sigmoide	Sigmoide	Lineal	603	5.14	5.18	-
5	3	13	13	13	Sigmoide	Sigmoide	Lineal	601	5.12	5.04	-
5	3	15	15	15	Sigmoide	Sigmoide	Lineal	607	5.13	5.05	-
6	1	4	-	-	Sigmoide	-	Lineal	610	10.87	-	-
6	3	4	4	4	Sigmoide	Sigmoide	Lineal	604	9.83	-	-
5	3	5	5	5	Tangencial	Sigmoide	Lineal	605	5.44	-	-
5	3	7	7	7	Tangencial	Sigmoide	Lineal	606	5.17	-	-
5	3	9	9	9	Tangencial	Sigmoide	Lineal	604	5.36	-	-
5	3	11	11	11	Tangencial	Sigmoide	Lineal	605	5.62	-	-
5	3	13	13	13	Tangencial	Sigmoide	Lineal	604	5.71	5.70	5.10
5	3	15	15	15	Tangencial	Sigmoide	Lineal	601	5.28	5.55	5.15
6	3	15	15	15	Tangencial	Sigmoide	Lineal	610	5.29	5.03	5.04

APÉNDICE C

En este apéndice se presentan los registros de elevaciones freáticas utilizados en el proceso de interpolación y validación del modelo de flujo y de la RNA. Los datos recopilados provienen de los registros obtenidos de CONAGUA. Las coordenadas de los puntos de observación se muestran en la tabla C1. Mientras que los registros de nivel freático se presentan en las tablas C2, C3 y C4.

Tabla C1. Ubicación de Puntos de observación en el VON.

Nombre	U.T.M. (WGS84)		Nombre	U.T.M. (WGS84)	
	X	Y		X	Y
P1	573060	3530671	CNA-55-08	567784	3525899
P2	570369	3530755	CNA-56-08	569966	3527995
P12	571309	3531097	CNA-58-08 / ON-4	575123	3530572
P13	569557	3531524	CNA-60-08	575848	3530485
P16	568660	3532528	CNA-61-08	577763	3530515
P18	567165	3532249	CNA-64-08	574087	3527886
P20	571779	3531268	CNA-A1	567697	3530265
P24	569428	3533339	CNA-A16	568243	3531149
P26	574640	3533640	CNA-A19	567267	3531315
P27	570368	3533681	CNA-67-08	568993	3531241
P29	570027	3531695	CNA-C-1	568981	3529867
P30	570967	3532037	CNA-C-15	572725	3525385
P31	568489	3532997	CNA-C-16	568228	3526983
P34	569130	3532699	CNA-C2	566326	3533557
P37	572761	3532956	P-022A / CNA-B8	572362	3533262
P39	571180	3532913	P-015A	571696	3531173
P42	569898	3533510	P-026A	569684	3534231
P44	569727	3533980	P-029A	570406	3533827
P54	567721	3529259	P-02A	574308	3532885
P55	566610	3529387	P-030A	569571	3533501
P56	568191	3529430	P-035A	570428	3530699
P57	566909	3530028	P-039AR	570047	3531552
P62	568446	3531652	P-045A	566771	3534172
P63	567549	3532655	P-61	572633	3527552
P66	566993	3535645	11A	572105	3531296
P80	566608	3538166	P-152	571061	3527664
P81	569213	3538316	P-168	571957	3531806
P95	567078	3538337	P-169A / ON-3	570255	3534482
P97	564215	3538891	P-172A	567492	3532282
P123	566950	3537226	P-17B	568744	3533967
P235	568202	3529397	P-19R	570720	3532979
P248	566920	3529994	P-20B	568432	3533047
127-TMI	572987	3533226	P-211 / ON-2	565787	3533960
CNA-A5 / P-05B / ON-5	567820	3529468	P-214	566908	3532042
CNA-001	566548	3526802	P-215B	567154	3529490
CNA-15 / P-06B	568230	3529942	P-22	565665	3534664
CNA-29	569141	3530379	P-220	569282	3527326

Tabla C1 (Continuación). Ubicación de Puntos de observación en el VON.

Nombre	U.T.M. (WGS84)	
	X	Y
CNA-2B / P-02B	566682	3530012
CNA-3	567839	3533373
CNA-35-08	571773	3530684
CNA-40-08	568876	3532237
CNA-46-08	573071	3525421
CNA-52-08	568161	3528448
P-218	572189	3530240
P-170 / 55	567377	3528600
CNA-B1 / P-020A	573182	3532732
P-018A	572458	3531954
POP-1 / ON-7	570705	3532068
POP-2 / ON-9	572946	3533839
POP-3 / ON-8	573774	3532598
POP-4 / ON-6	567913	3532635
CNA-A2 / P-04B / ON-1	567611	3529753
P 63R CNA	568825	3537838
P 67	567811	3536769
CNA 80	566846	3536208
P 82 (381)	566432	3538539
P 160	565639	3536222
P 99-A	566126	3538069
P 066 AC CNA	568132	3537559
P 186	565768	3538640
P 199 CNA	566235	3536558
P 201	566492	3535870
P 204 A	568462	3536102
P 01 BB	569199	3536507
CNA 48-04 (339)	566171	3536798
CNA 8	565455	3539081
P 12	563143	3536545
P 155 CNA	566428	3537539

Nombre	U.T.M. (WGS84)	
	X	Y
P 95	565134	3538057
P 98	564545	3538660
P 101	564755	3540312
P 110	562650	3538115
P 190	562868	3539434
P 189	563049	3539516
NO 92	562047	3540298
CNA 48 09	563220	3538876
P 11	565207	3539769
P 9	564245	3539572
P 175	564822	3539958
P 164	565040	3538823
P 165	565290	3538640
CNA 48 06	564106	3540021
P 132	561772	3540081
N 131	561457	3540959
CNA 48 07	564728	3536564
P 69 CNA	566974	3536840
P 107	562145	3539695
P 194	563373	3536223
N 16	561609	3540582
P 142 CNA	564779	3537617
P 09-1	563883	3537005
CNA 10 (292)	571606	3537275
CNA 48-01 (619)	569356	3538537
CNA 48-02 (376)	568934	3538094
CNA 48-03	567849	3539069
P 70 (439)	566754	3537147
P 024 A	570482	3536199
P 107	562145	3539695

Tabla C2. Registro de NF elaborado por la CONAGUA para el periodo 1989-1999 distribuidos en el VON.

Nombre	NF			
	Jul 1989	Nov 1995	Feb 1997	Feb 1999
P1	685	675	680	-
P2	685	675	680	-
P12	683	679	-	-
P13	682	670	-	-
P16	679	670	665	-
P18	679	677	665	-
P20	682	680	683	-
P24	683	670	673	-
P26	-	-	679	-
P27	682	674	675	-
P29	682	672	-	-
P30	682	679	675	-
P31	683	-	674	-
P34	681	672	-	-
P37	-	-	672	-
P39	682	679	679	-
P42	683	672	675	-
P44	682	-	678	-
P54	684	665	-	-
P55	682	670	675	-
P56	686	665	-	-
P57	682	665	670	-
P62	681	670	-	-
P63	683	670	-	-
P66	682	-	-	-
P80	667	-	-	675
P81	-	-	-	677
P95	670	-	-	670
P97	662	-	-	662
P123	676	-	670	673
P235	-	-	665	-
P248	-	-	670	-

Tabla C3.-Registro de NF elaborado por la CONAGUA para el AON durante el periodo 2008-2018

Nombre	NF (msnm)																				
	Nov 2008	May 2009	Nov 2009	Abr 2010	Nov 2010	Abr 2011	Nov 2011	Abr 2012	Nov 2012	Abr 2013	Ago 2013	Nov 2013	Abr 2014	Nov 2014	Abr 2015	Nov 2015	Abr 2016	Nov 2016	May 2017	Nov 2017	Abr 2018
127-TMI	681	-	-	682	688	689	690	690	687	686	-	684	683	680	678	676	675	672	674	-	-
CNA-A5 / P-05B / ON-5	646	646	-	646	646	646	644	644	643	642	-	642	642	651	641	641	640	-	641	641	640
CNA-001	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CNA-15 / P-06B	645	646	-	645	644	645	643	643	642	642	-	641	640	640	639	638	636	636	636	634	635
CNA-29	645	645	-	644	644	644	642	642	640	-	-	639	638	636	637	634	-	637	640	640	631
CNA-2B / P-02B	-	-	-	660	660	660	659	658	658	658	-	657	657	656	656	655	656	-	657	-	657
CNA-3	651	651	-	646	644	647	644	643	642	-	-	645	644	640	639	637	635	635	-	-	-
CNA-35-08	671	673	-	672	670	672	671	673	670	673	-	670	671	667	668	666	-	-	-	-	-
CNA-40-08	646	646	-	645	644	645	642	643	640	-	-	639	642	637	637	635	634	632	634	-	-
CNA-46-08	703	705	-	703	702	703	703	703	702	702	-	696	702	703	702	700	701	-	698	688	-
CNA-52-08	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	673
CNA-55-08	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CNA-56-08	687	687	-	687	687	687	686	686	686	686	-	686	685	685	685	685	685	684	685	-	678
CNA-58-08 / ON-4	710	710	-	710	709	709	710	-	-	-	-	718	709	699	709	708	708	-	709	709	709
CNA-60-08	729	-	-	-	729	729	728	728	727	-	-	728	728	-	728	727	727	726	727	-	727
CNA-61-08	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CNA-64-08	699	700	-	700	700	700	700	700	700	700	-	700	700	700	700	699	700	700	695	700	700
CNA-A1	644	645	-	645	644	645	641	643	641	641	-	641	-	-	-	-	-	635	-	-	-
CNA-A16	645	645	-	645	648	644	642	642	640	-	-	639	642	641	638	636	-	-	634	-	-
CNA-A19	646	647	-	645	644	645	643	643	642	-	-	641	640	642	-	637	635	-	-	-	-
CNA-67-08	647	647	-	647	645	646	644	645	642	-	-	641	641	639	639	636	636	634	635	-	635
CNA-C-1	645	646	-	645	644	644	641	643	640	641	-	639	639	636	636	634	634	633	632	-	631
CNA-C-15	697	697	-	696	696	695	695	695	695	695	-	694	695	695	694	694	693	693	-	693	684
CNA-C-16	-	-	-	673	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CNA-C2	654	650	-	652	652	652	650	650	649	-	-	649	650	-	636	646	646	644	643	642	642
P-022A / CNA-B8	-	656	-	654	652	655	654	655	653	652	-	648	-	-	-	-	637	-	-	-	-
P-015A	669	671	-	671	669	672	670	668	668	672	-	670	671	667	666	664	664	662	662	-	-

Tabla C3 (Continuación). Registro de NF elaborado por la CONAGUA para el AON durante el periodo 2008-2018

Nombre	NF (msnm)																				
	Nov 2008	May 2009	Nov 2009	Abr 2010	Nov 2010	Abr 2011	Nov 2011	Abr 2012	Nov 2012	Abr 2013	Ago 2013	Nov 2013	Abr 2014	Nov 2014	Abr 2015	Nov 2015	Abr 2016	Nov 2016	May 2017	Nov 2017	Abr 2018
P-026A	649	647	-	-	643	644	642	642	641	643	-	-	-	-	-	-	-	-	-	-	629
P-029A	651	651	-	648	648	650	647	648	646	647	-	-	644	641	641	638	638	634	635	633	-
P-02A	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
P-030A	646	646	-	646	644	645	644	643	640	-	-	-	-	-	-	-	-	-	-	-	-
P-035A	664	664	-	664	661	663	661	662	660	-	-	660	-	-	-	-	648	-	645	644	644
P-039AR	647	647	-	-	644	645	641	646	641	-	-	639	642	-	637	-	-	633	-	-	-
P-045A	656	660	-	649	649	649	649	649	648	-	-	647	649	648	645	644	643	643	-	646	650
P-61	695	695	-	695	694	695	693	695	693	693	-	693	692	693	694	692	693	693	697	692	694
11A	671	672	-	672	670	673	673	675	672	674	-	671	672	668	668	-	666	664	664	-	-
P-152	690	656	-	-	690	689	689	689	689	689	-	689	688	688	688	688	688	687	687	687	687
P-168	-	-	-	-	-	-	-	-	-	-	-	-	-	669	669	667	667	-	664	-	-
P-169A / ON-3	651	650	-	649	649	650	648	648	648	648	-	648	648	647	647	649	647	-	647	-	647
P-172A	646	645	-	645	643	644	642	643	640	-	-	-	642	-	638	635	632	634	-	633	631
P-17B	647	646	-	646	646	646	643	643	642	-	-	640	-	-	-	-	636	-	-	-	-
P-19R	652	652	-	650	649	651	649	649	648	649	-	646	646	642	-	639	-	-	-	-	-
P-20B	646	646	-	645	644	645	642	643	642	-	-	639	642	640	637	-	637	633	-	632	632
P-211 / ON-2	659	658	-	660	660	659	658	658	657	-	-	656	656	657	654	652	-	-	645	-	-
P-214	655	652	-	645	652	651	651	651	650	-	-	649	641	646	647	648	642	647	645	-	-
P-215B	646	647	-	647	647	647	645	645	642	644	-	640	644	643	640	642	642	-	635	-	642
P-22	650	651	-	652	654	652	650	651	649	-	-	648	648	649	645	643	650	640	643	-	638
P-220	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	683	683
P-23R	651	648	-	648	647	649	645	648	644	645	-	642	643	-	637	637	635	-	632	-	-
P-250	689	689	-	689	689	689	689	689	688	688	-	688	688	688	688	687	686	681	687	687	687
P-33A / P-22	651	651	-	649	648	650	645	648	644	647	-	642	643	638	637	-	-	-	630	-	-

Tabla C3 (Continuación). Registro de NF elaborado por la CONAGUA para el AON durante el periodo 2008-2018

Nombre	NF (msnm)																				
	Nov 2008	May 2009	Nov 2009	Abr 2010	Nov 2010	Abr 2011	Nov 2011	Abr 2012	Nov 2012	Abr 2013	Ago 2013	Nov 2013	Abr 2014	Nov 2014	Abr 2015	Nov 2015	Abr 2016	Nov 2016	May 2017	Nov 2017	Abr 2018
P-44R	655	654	-	651	651	651	651	651	649	-	-	649	640	646	646	647	642	646	-	644	642
P-59	-	667	-	-	-	-	-	666	-	-	-	-	-	-	-	-	-	-	-	-	-
P-8	673	674	-	675	672	674	673	676	672	675	-	673	674	671	672	-	671	665	669	666	668
P-218	675	675	-	675	674	676	674	672	674	675	-	674	674	674	673	675	673	-	673	673	673
P-170 / 55	652	652	-	652	652	651	651	651	650	650	-	650	650	649	649	647	646	645	644	644	643
CNA-B1 / P-020A	679	680	-	679	684	687	688	689	686	685	-	-	685	681	680	-	-	673	675	670	671
P-018A	673	676	-	675	-	-	-	-	-	-	-	-	-	-	673	-	-	-	666	663	665
POP-1 / ON-7	-	-	-	650	648	643	646	648	644	647	-	643	643	637	637	-	633	-	629	628	628
POP-2 / ON-9	-	-	-	-	-	678	680	678	675	673	-	-	667	-	-	-	659	-	-	660	660
POP-3 / ON-8	-	-	-	-	691	693	694	693	692	691	-	-	690	690	690	689	689	-	690	690	690
POP-4 / ON-6	-	-	-	-	642	643	641	641	640	-	-	638	638	637	637	634	-	-	633	631	631
CNA-A2 / P-04B / ON-1	-	-	-	-	645	645	643	644	643	642	-	642	642	641	641	639	639	-	-	638	636

APÉNDICE D

Registro de pozos utilizados en el modelo sintético durante los 31 días de simulación propuestos. En este caso se muestran únicamente los valores utilizados en el modelo sintético, los cuales presentan la misma estructura que fue utilizada con las fechas de simulación de los AVON.

Tabla D1. Parámetros de entrada utilizados en el modelo sintético. NF representa nivel freático. K representa conductividad hidráulica. Los puntos suspensivos (...) indican la secuencia continua de los datos.

Fecha	Pozo	Precipitación	Temperatura	Topografía	NF	K	Objetivo
12/02/2001	POZO_1	0.992	2.057	0.182	1.762	1	-2398.333
12/02/2001	POZO_2	0.992	2.057	0.546	1.760	1	-34074.276
12/02/2001	POZOS_4	0.992	2.057	1.275	0.617	0.25	-29102.267
12/02/2001	POZOS_5	0.992	2.057	1.639	0.378	0.25	-33488.486
12/02/2001	POZOS_3	0.992	2.057	0.182	0.367	0.25	-32178.890
12/02/2001	POZOS_6	0.992	2.057	1.275	0.157	0.25	-32052.271
12/02/2001	POZOS_8	0.992	2.057	1.275	0.500	1	-32052.271
12/02/2001	POZOS_7	0.992	2.057	0.182	0.511	1	-33952.595
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
12/11/2001	POZO_1	1.393	0.278	0.182	1.568	1	-6178.333
12/11/2001	POZO_2	1.393	0.278	0.546	1.565	1	-37854.276
12/11/2001	POZOS_4	1.393	0.278	1.275	0.934	0.25	-32882.267
12/11/2001	POZOS_5	1.393	0.278	1.639	0.718	0.25	-37268.486
12/11/2001	POZOS_3	1.393	0.278	0.182	0.676	0.25	-35958.890
12/11/2001	POZOS_6	1.393	0.278	1.275	0.449	0.25	-35832.271
12/11/2001	POZOS_8	1.393	0.278	1.275	0.286	1	-35832.271
12/11/2001	POZOS_7	1.393	0.278	0.182	0.293	1	-37732.595
12/21/2001	POZO_1	0.019	0.507	0.182	1.384	1	-10378.333
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
12/21/2001	POZO_2	0.019	0.507	0.546	1.379	1	-42054.276
12/21/2001	POZOS_4	0.019	0.507	1.275	1.257	0.25	-37082.267
12/21/2001	POZOS_5	0.019	0.507	1.639	1.065	0.25	-41468.486
12/21/2001	POZOS_3	0.019	0.507	0.182	0.989	0.25	-40158.890
12/21/2001	POZOS_6	0.019	0.507	1.275	0.742	0.25	-40032.271
12/21/2001	POZOS_8	0.019	0.507	1.275	0.078	1	-40032.271
12/21/2001	POZOS_7	0.019	0.507	0.182	0.081	1	-41932.595
12/31/2001	POZO_1	0.855	1.250	0.182	1.190	1	-14578.333
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
12/31/2001	POZO_2	0.855	1.250	0.546	1.183	1	-46254.276
12/31/2001	POZOS_4	0.855	1.250	1.275	1.589	0.25	-41282.267
12/31/2001	POZOS_5	0.855	1.250	1.639	1.421	0.25	-45668.486
12/31/2001	POZOS_3	0.855	1.250	0.182	1.312	0.25	-44358.890
12/31/2001	POZOS_6	0.855	1.250	1.275	1.045	0.25	-44232.271
12/31/2001	POZOS_8	0.855	1.250	1.275	0.139	1	-44232.271
12/31/2001	POZOS_7	0.855	1.250	0.182	0.141	1	-46132.595

APÉNDICE E

En el presente apéndice, se detallan las estimaciones de descargas mensuales generadas mediante la RNA para las fechas específicas en las cuales se disponía de registros de NF. Estos resultados se fundamentan en la aplicación de modelos descritos en este documento de aprendizaje profundo, los cuales han sido entrenados y validados con datos históricos de descargas y niveles freáticos para garantizar la precisión y fiabilidad de las predicciones.

Tabla E1. Descargas mensuales estimadas por la RNA para todas las fechas de simulación disponibles

Número	Acuífero	Descarga		
	Modelo	Reportada	Estimada	Diferencia (en %)
	Período analizado			
1	Julio de 1989	5,019,481	6,146,982	-22.46
2	Noviembre de 1995	7,721,268	7,830,392	-1.41
3	Febrero de 1997	7,721,268	7,955,904	-3.04
4	Febrero de 1999	7,721,268	7,256,445	6.02
5	Abril del 2005	7,721,268	8,165,186	-5.75
6	Diciembre del 2007	7,721,268	7,291,395	5.57
7	Noviembre de 2008	7,721,268	8,746,438	-13.28
8	Mayo del 2009	7,721,268	13,290,839	-72.13
9	Noviembre del 2009	7,721,268	7,387,521	4.32
11	Noviembre del 2010	7,721,268	7,617,143	1.35
13	Noviembre del 2011	7,721,268	9,014,749	-16.75
15	Noviembre del 2012	7,721,268	8,685,105	-12.48
17	Agosto del 2013	7,721,268	7,105,668	7.97
18	Noviembre del 2013	7,721,268	7,100,668	8.04
20	Noviembre del 2014	7,721,268	7,122,684	7.75
22	Noviembre del 2015	7,721,268	6,880,186	10.89
24	Noviembre del 2016	7,721,268	6,741,630	12.69
25	Mayo del 2017	7,721,268	4,171,667	45.97
26	Noviembre del 2017	7,721,268	7,718,273	0.04
	Promedio	7,579,068	7,696,257	-1.93

APÉNDICE F

En este apéndice se presentan las elevaciones de NF y residuales obtenidos de la aplicación del modelo de flujo y la implementación de la RNA para ajustar las descargas en las fechas que se analizaron en este trabajo.

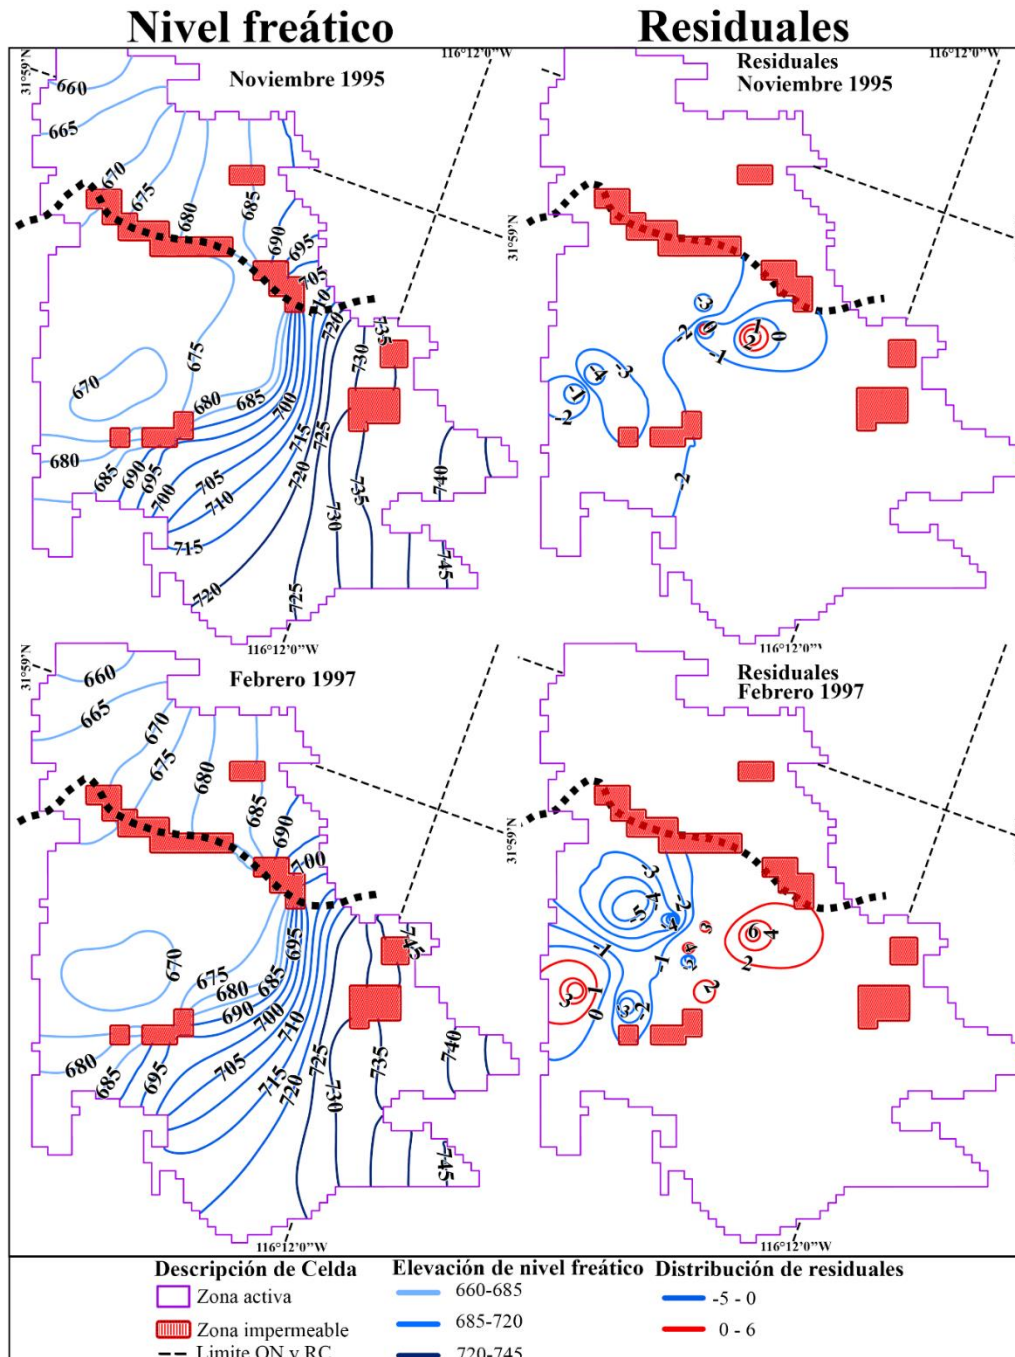


Figura F1. Resultados de NF y Residuales. Noviembre 1995 y Febrero 1999

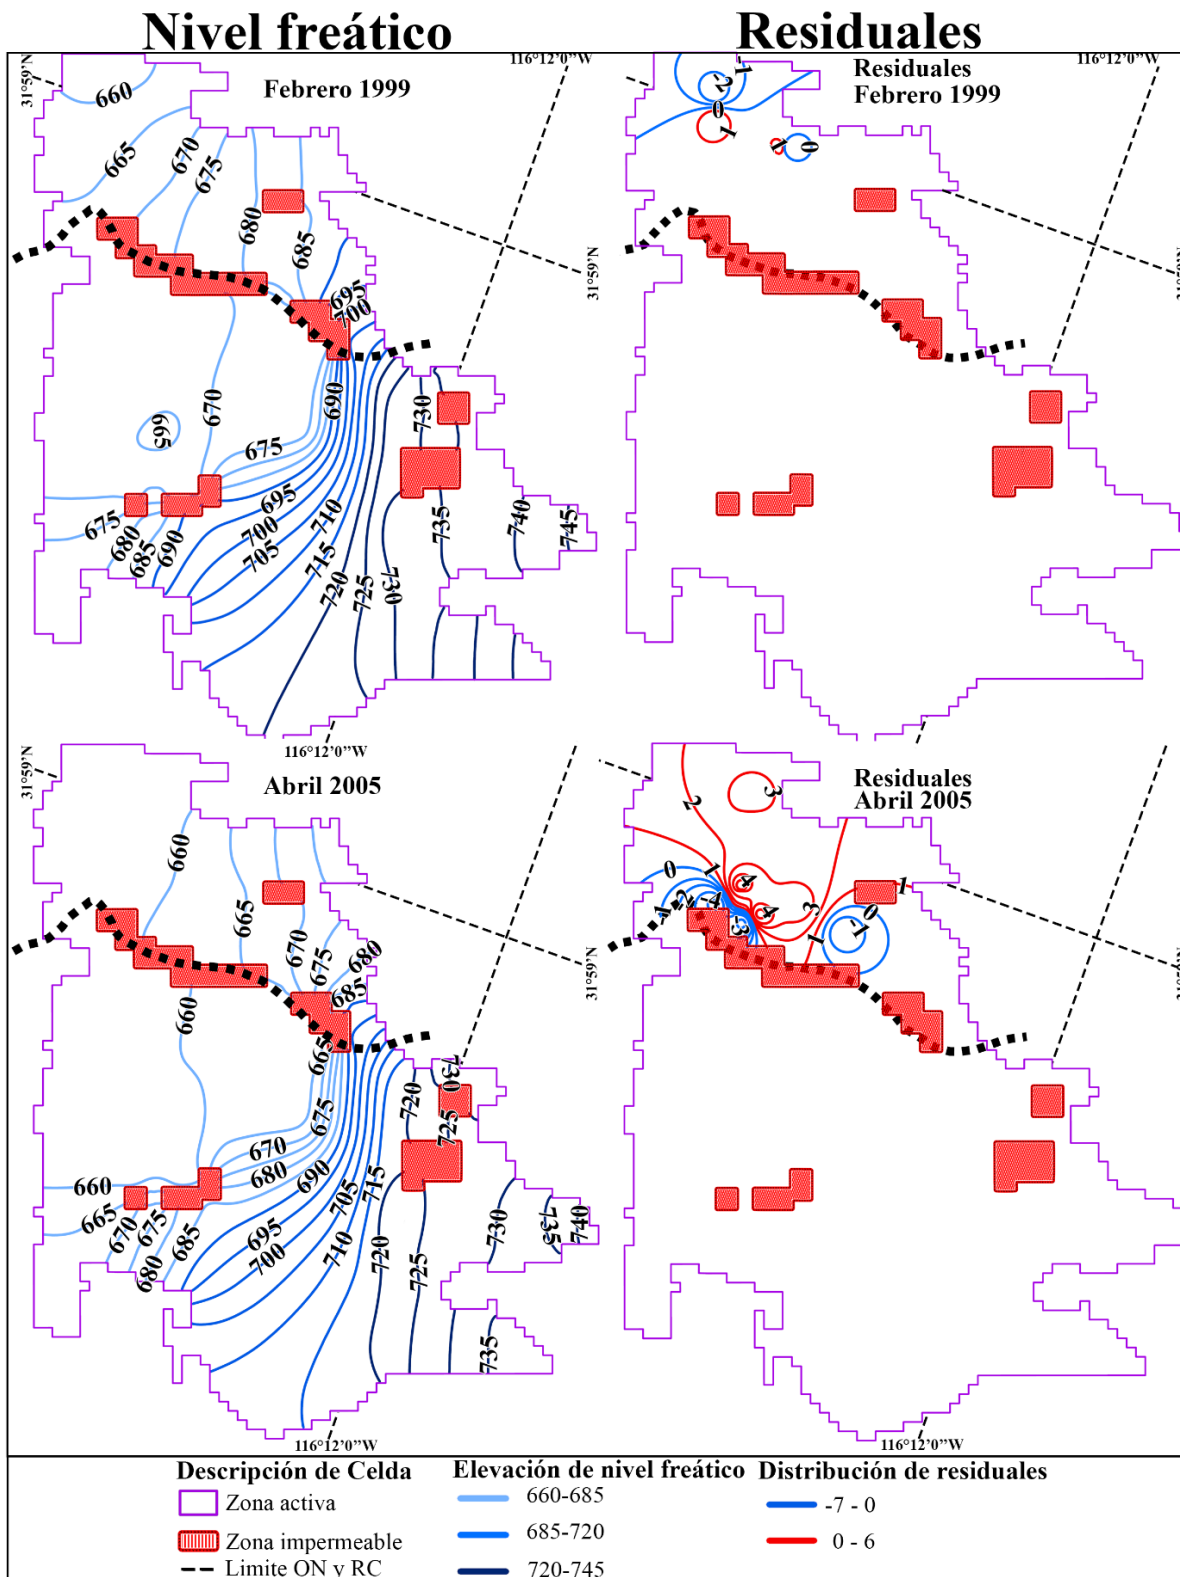


Figura F2.-Resultados de NF y Residuales. Febrero 1999 y Abril 2005

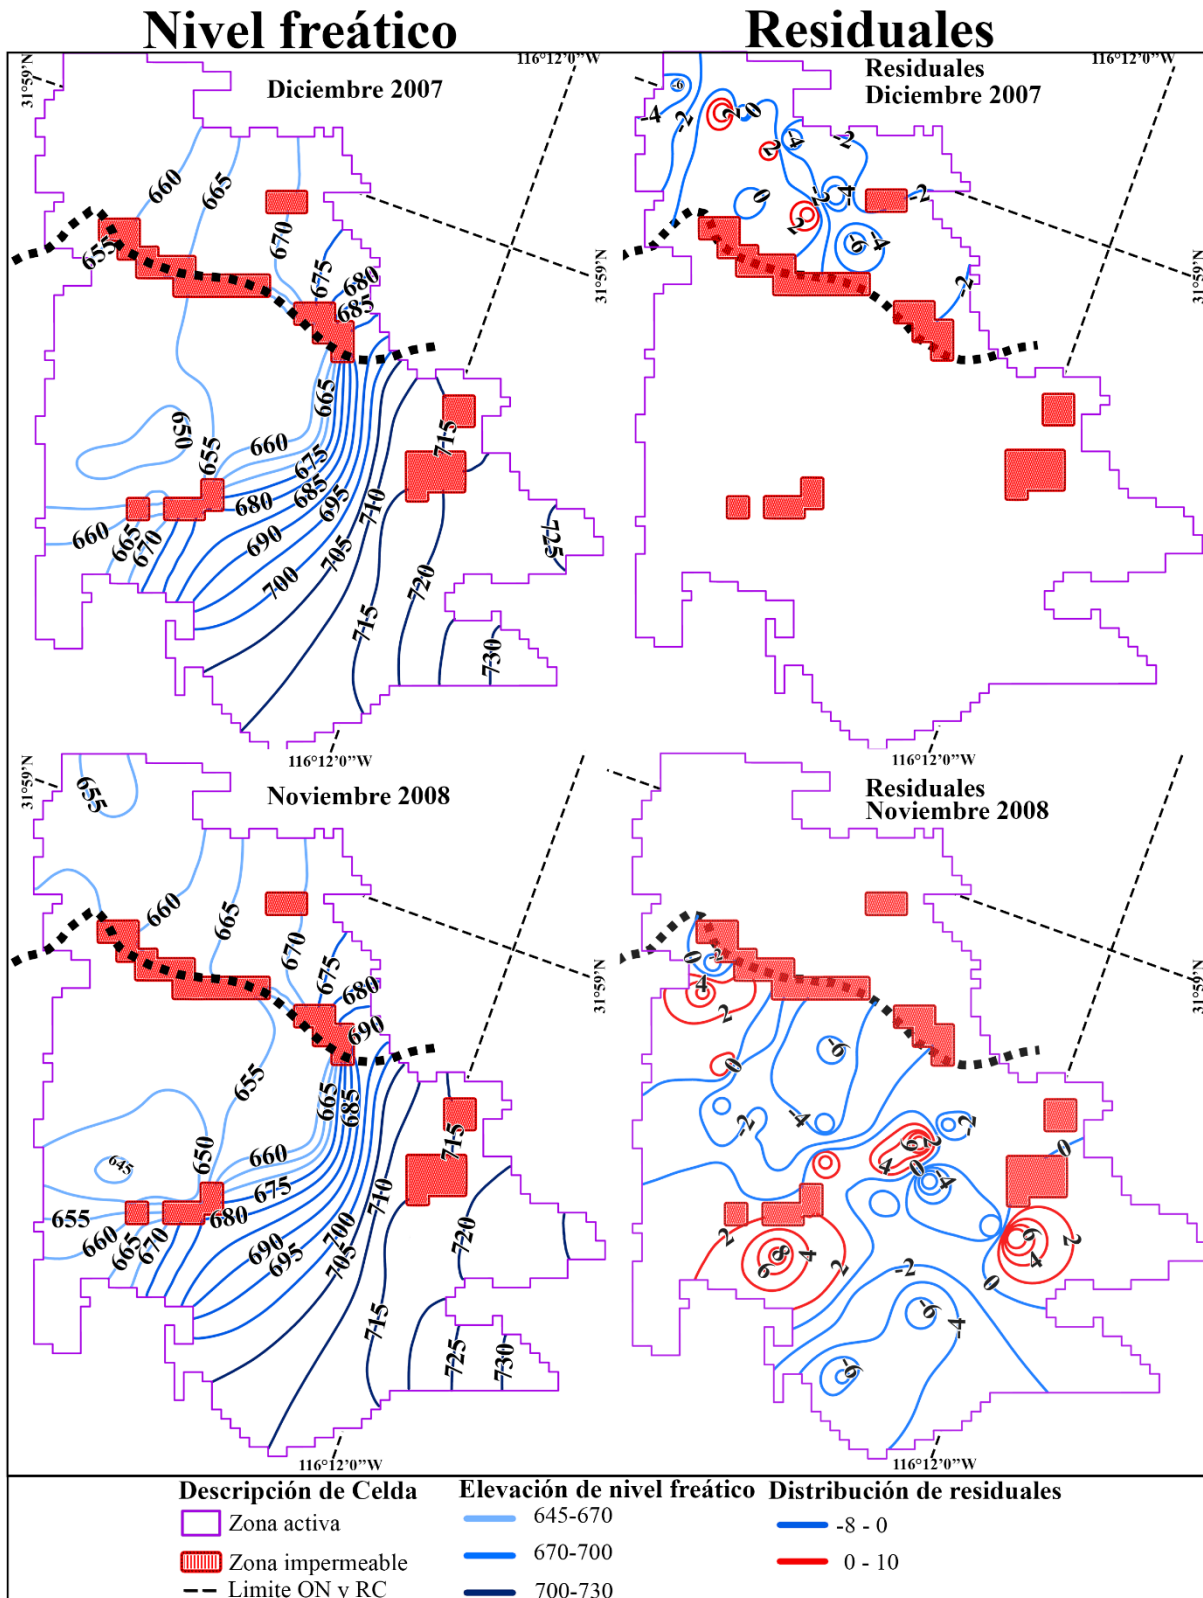


Figura F3. Resultados de NF y Residuales. Diciembre 2007 y Noviembre 2008

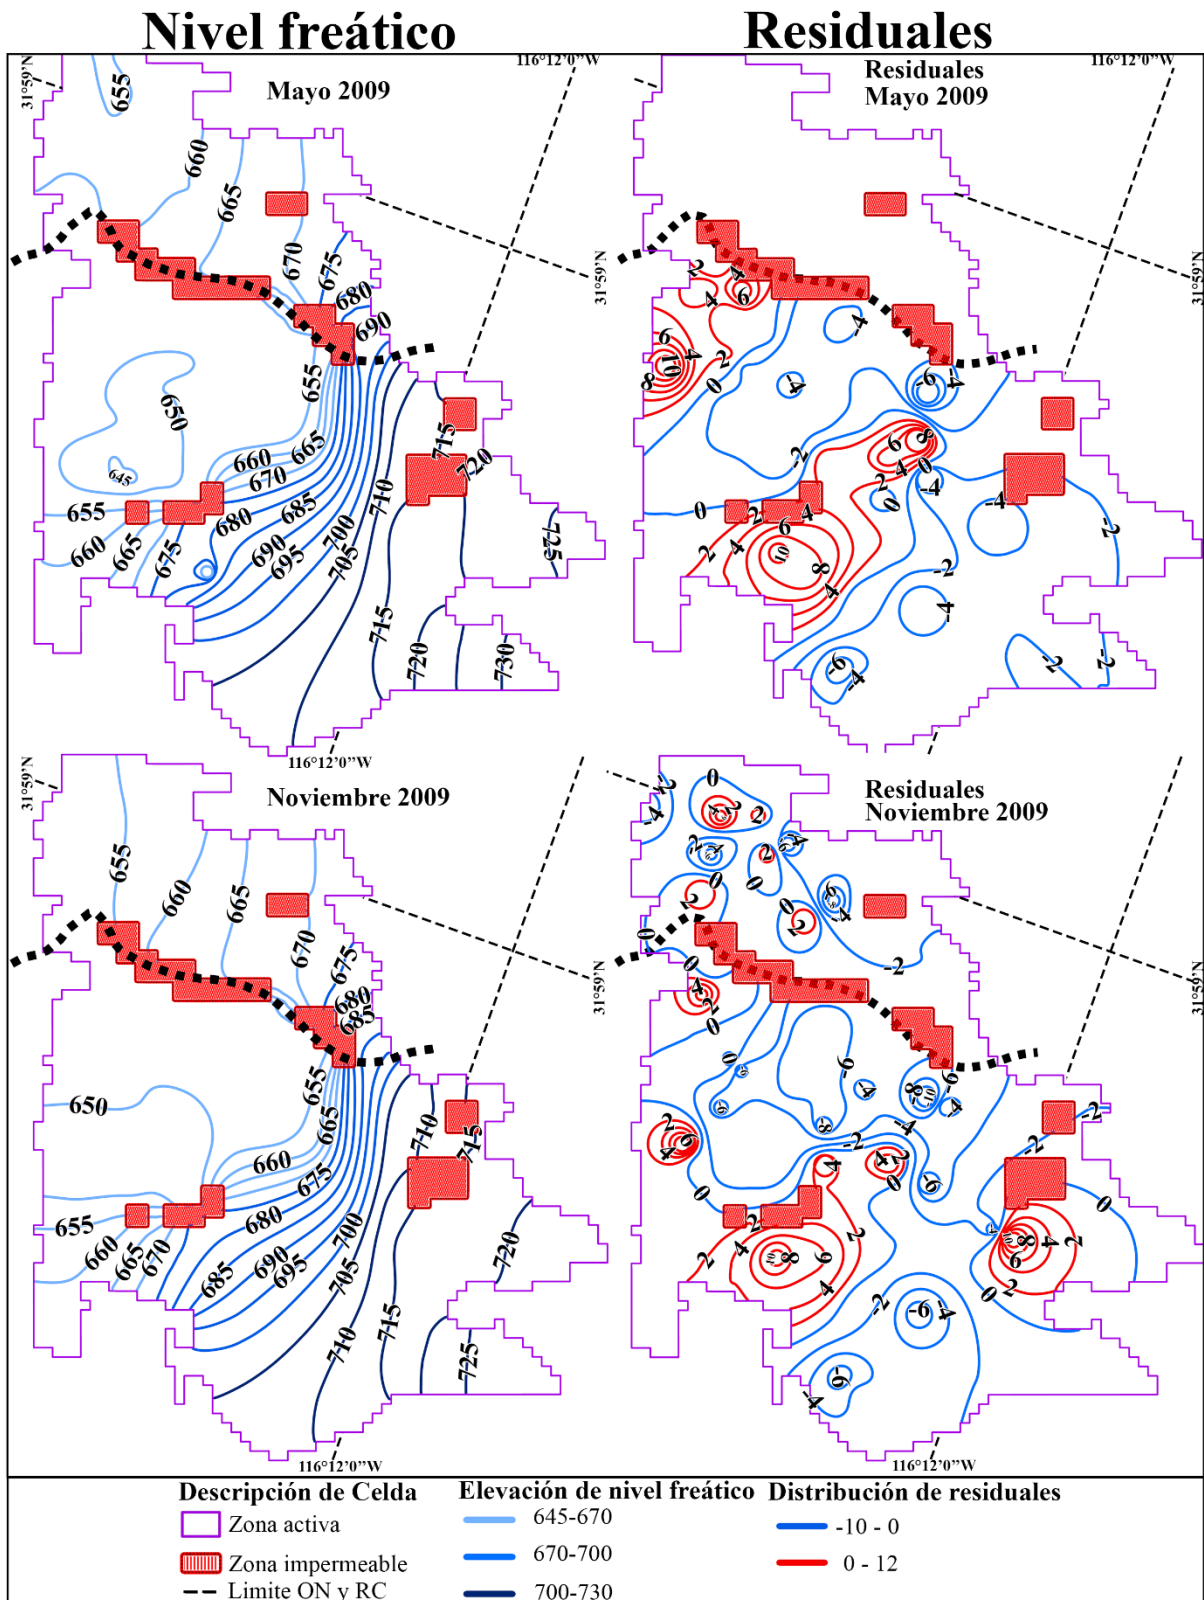


Figura F4. Resultados de NF y Residuales. Mayo 2009 y Noviembre 2009

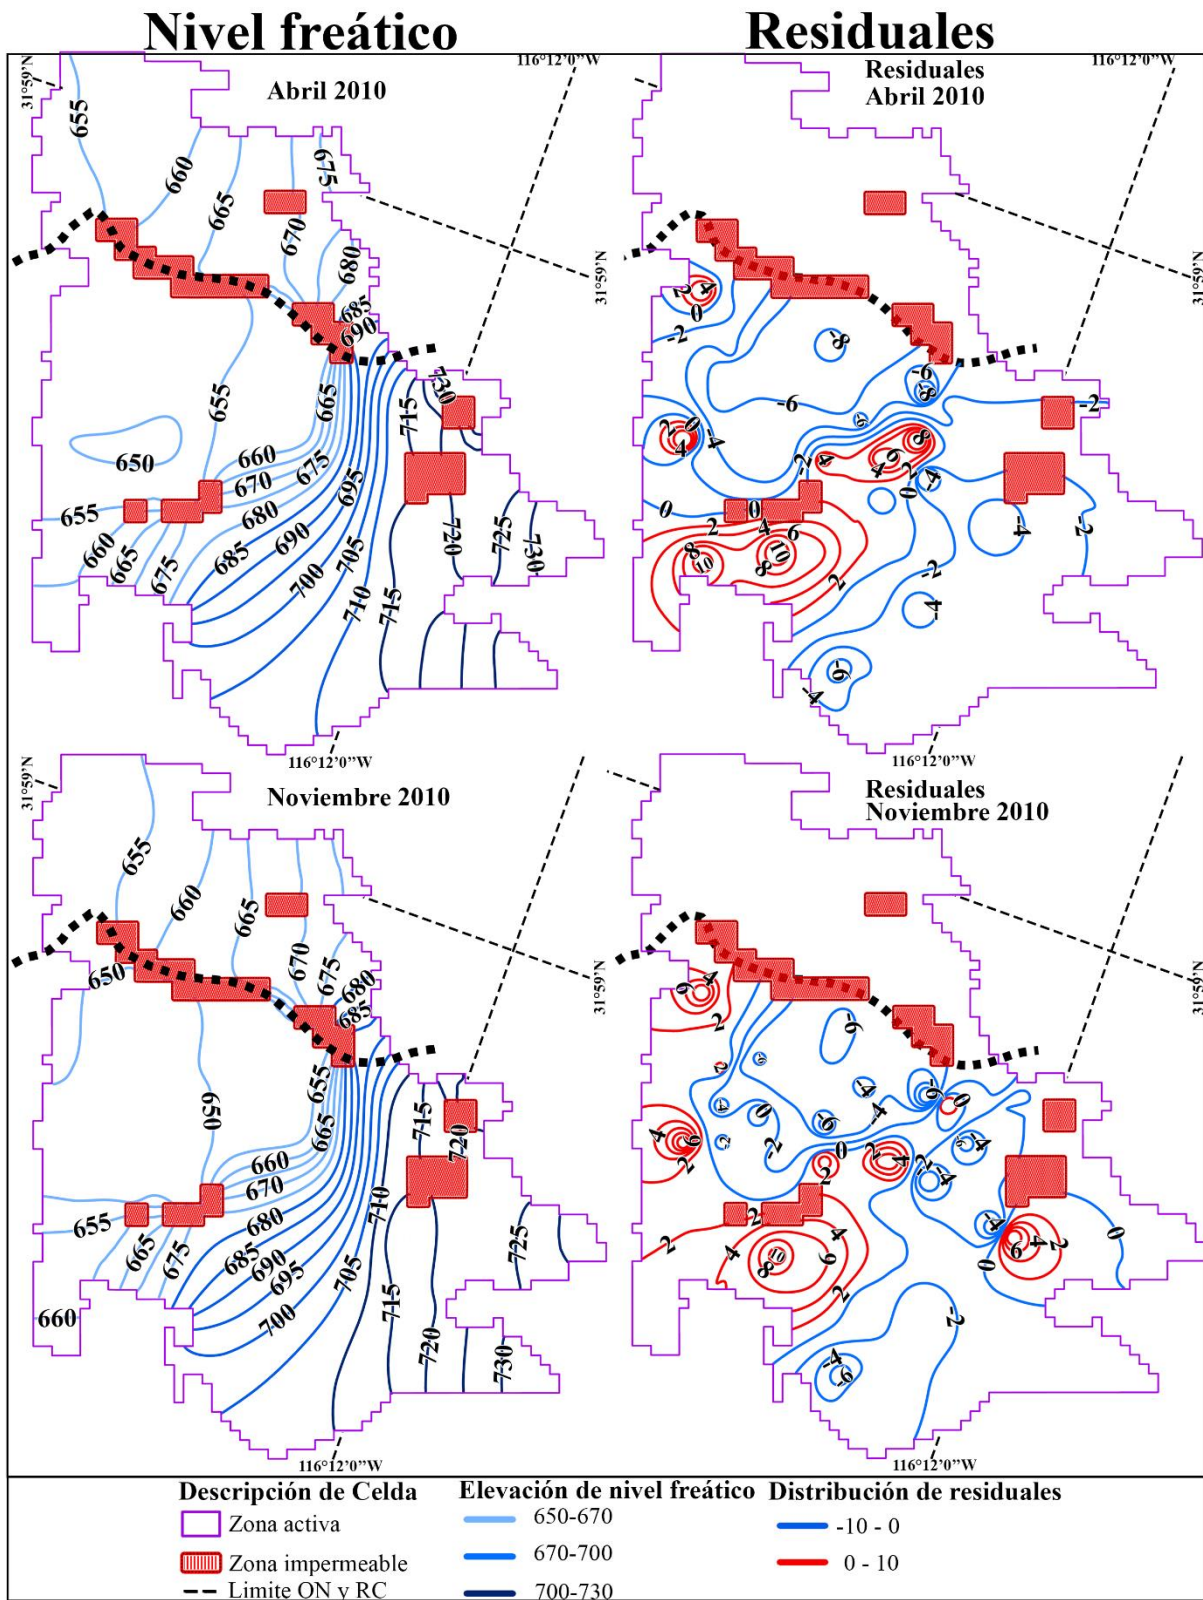


Figura F5. Resultados de NF y Residuales. Abril 2010 y Noviembre 2010

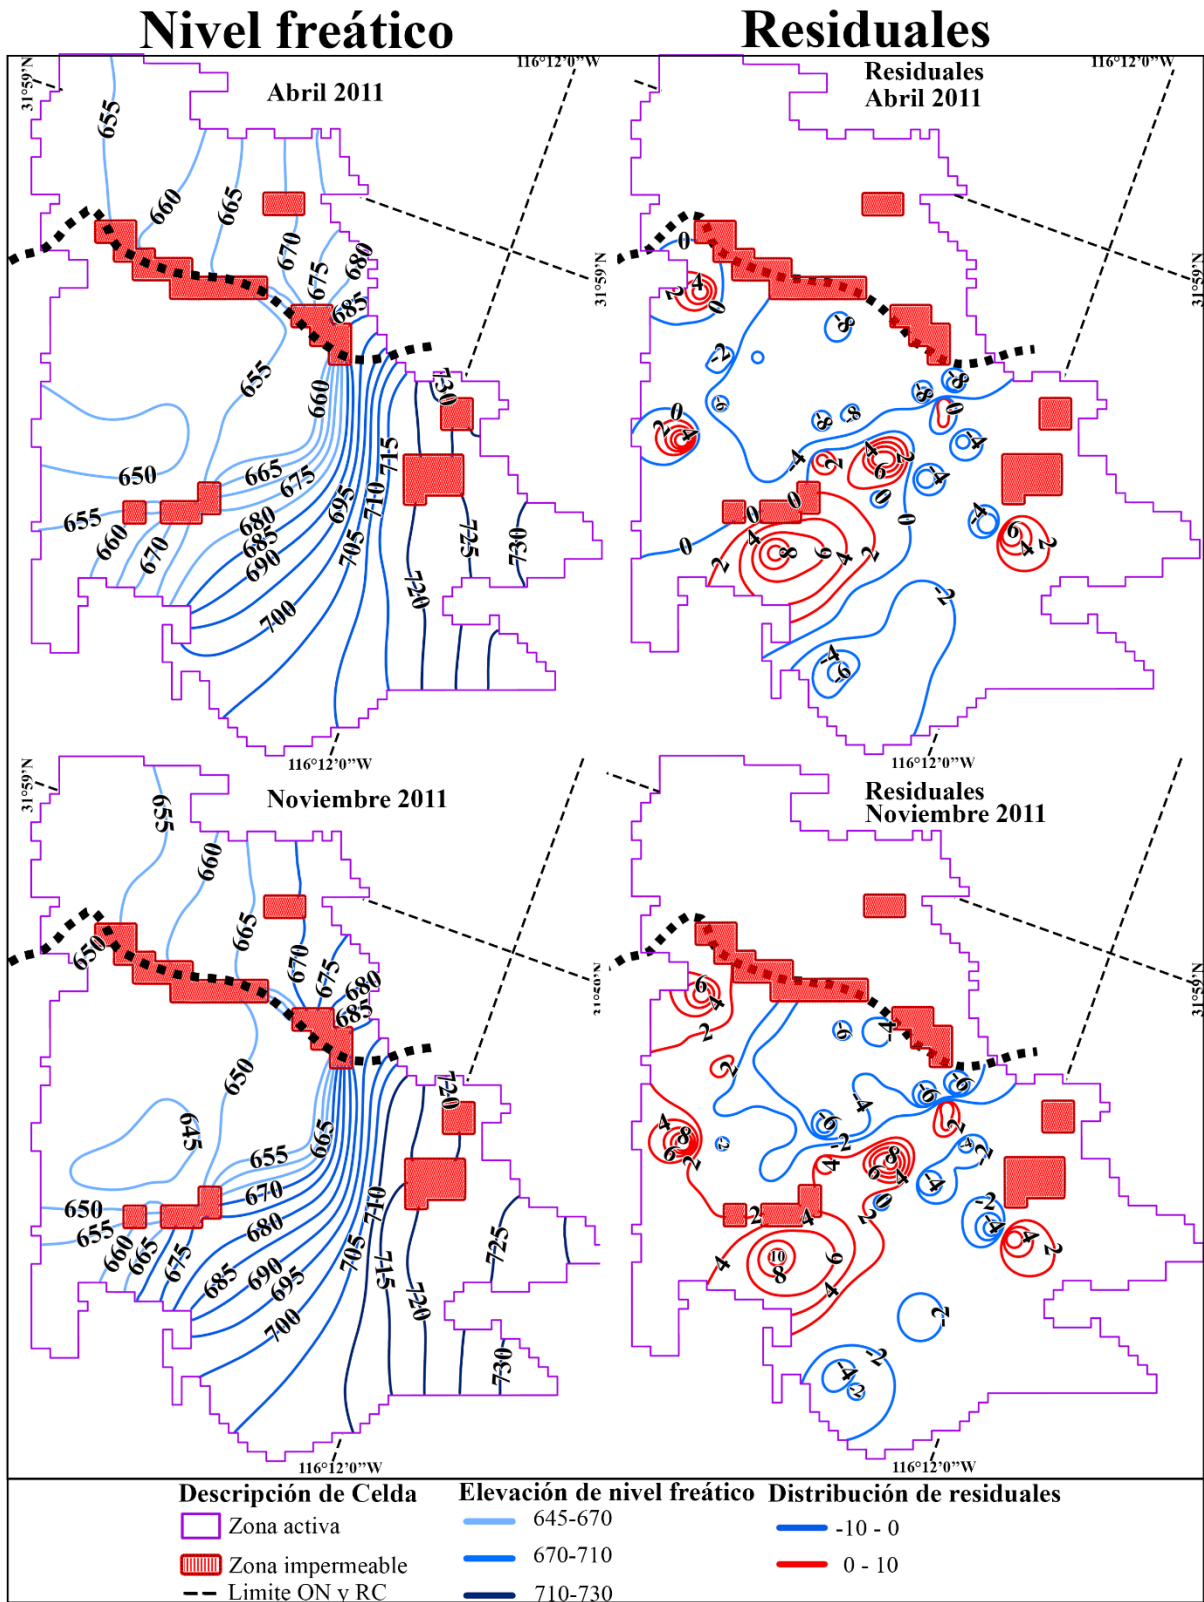


Figura F6. Resultados de NF y Residuales. Abril 2011 y Noviembre 2011

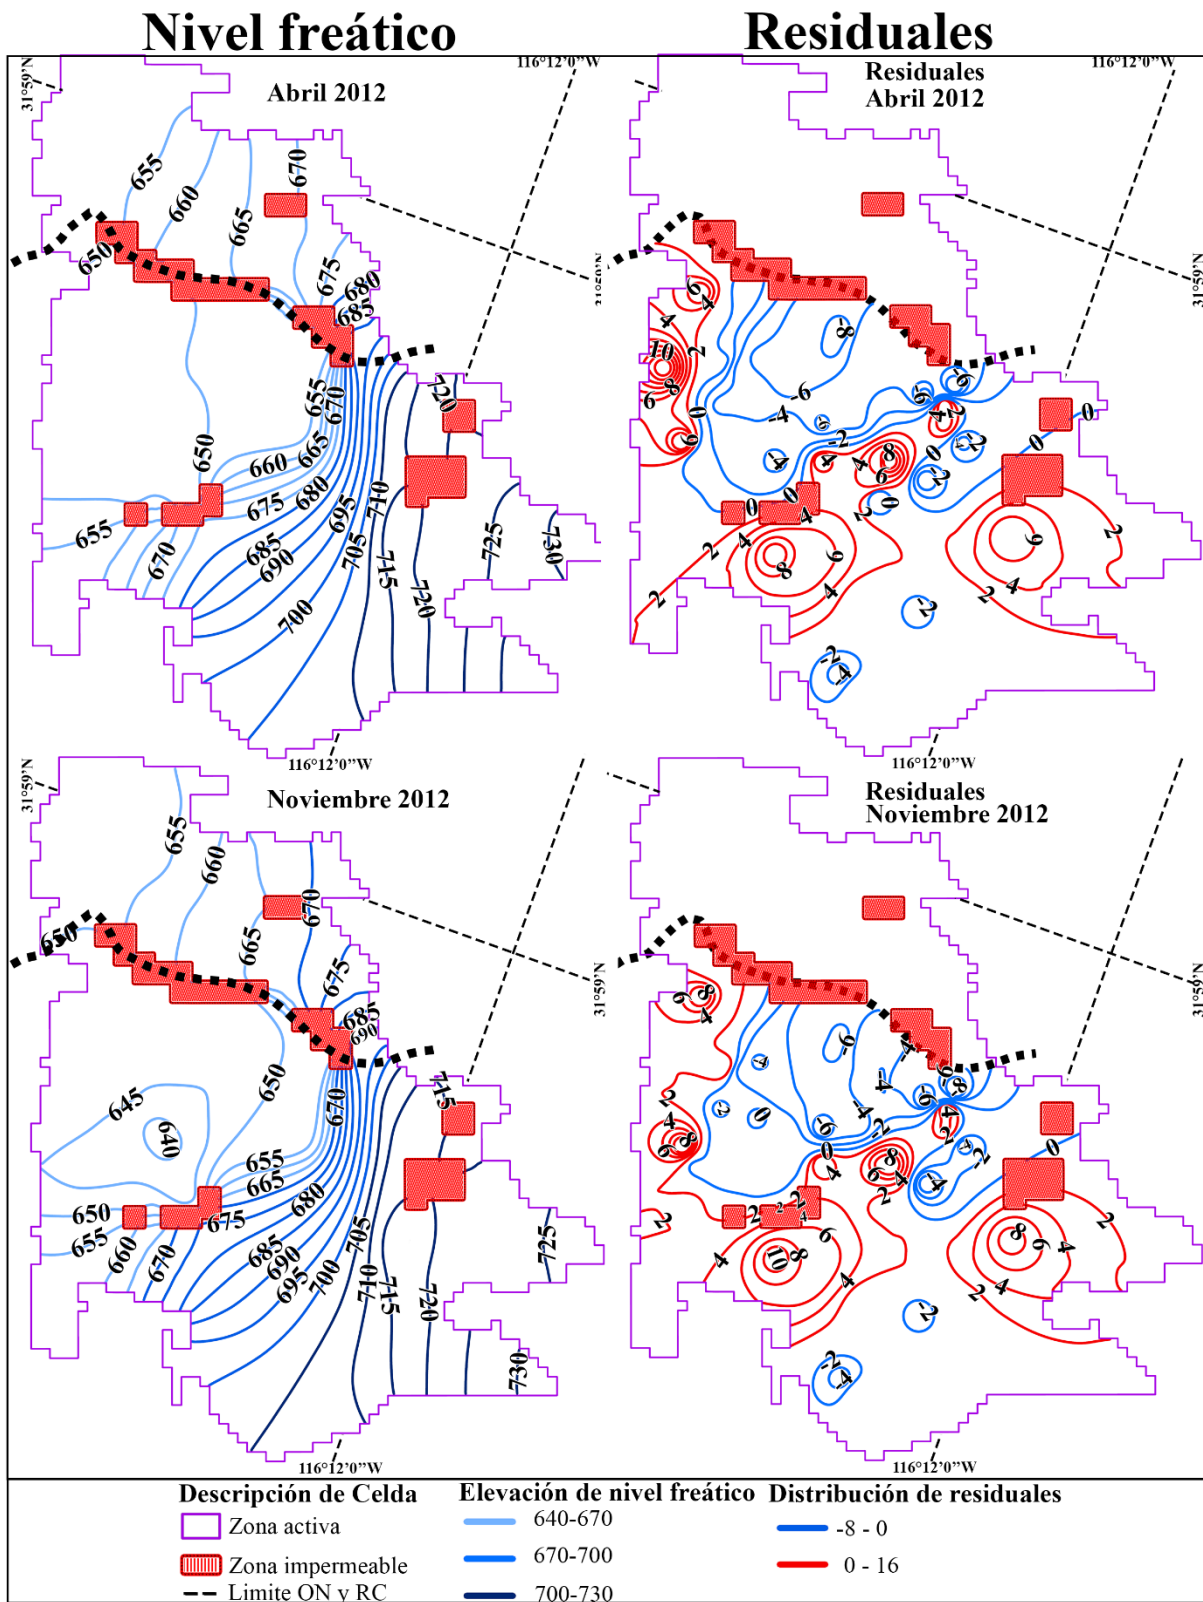


Figura F7. Resultados de NF y Residuales. Abril 2012 y Noviembre 2012

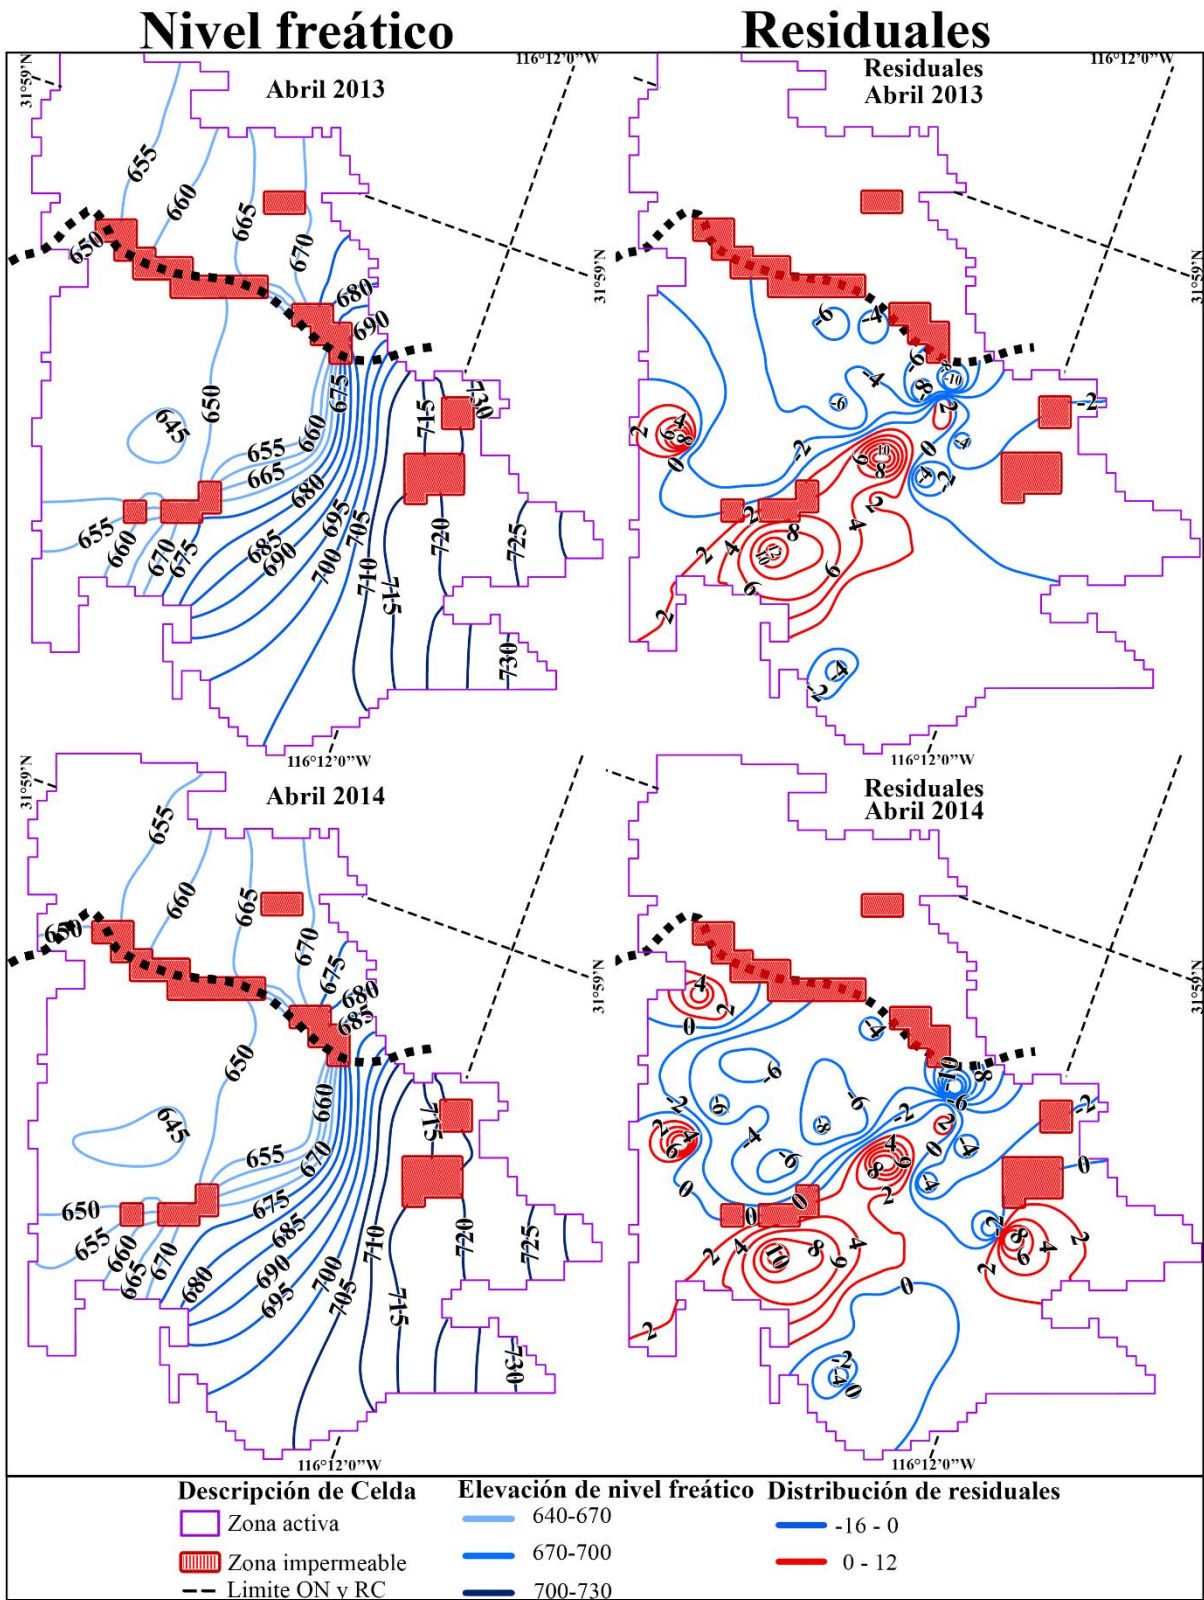


Figura F8. Resultados de NF y Residuales. Abril; 2013 y 2014

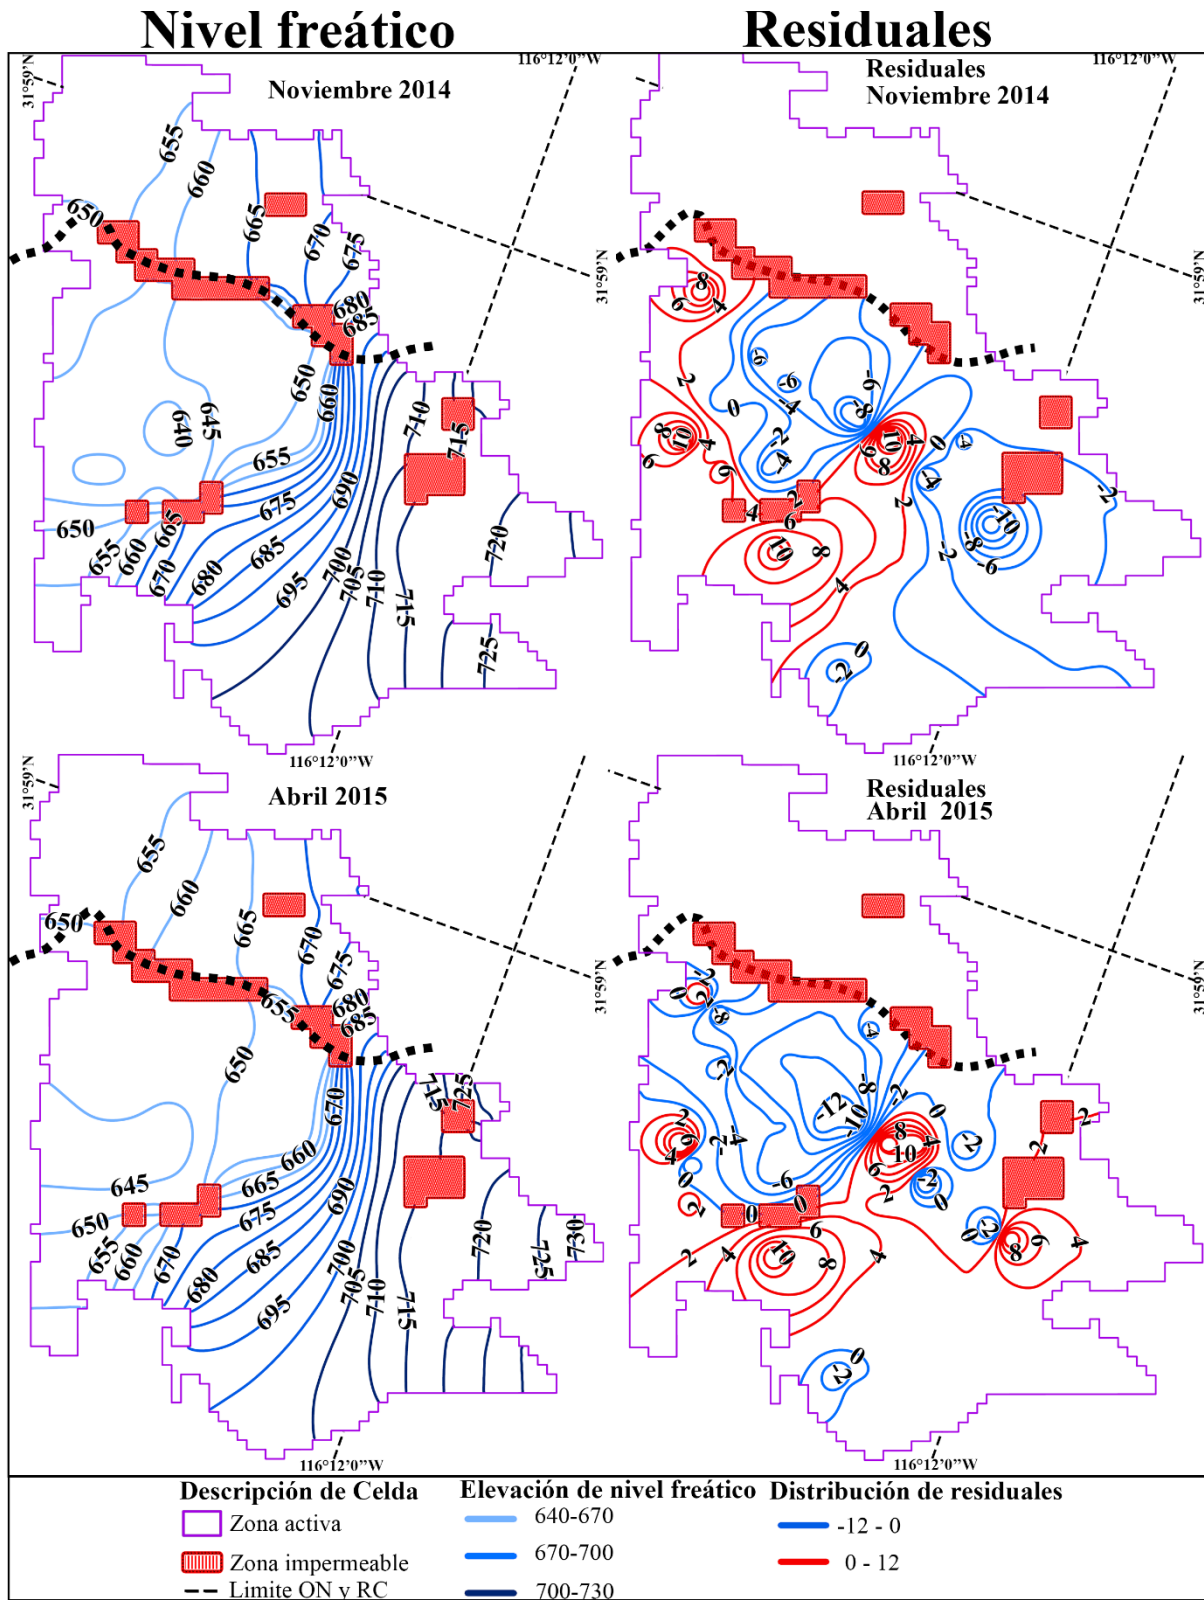


Figura F9. Resultados de NF y Residuales. Noviembre 2014 y Abril 2015

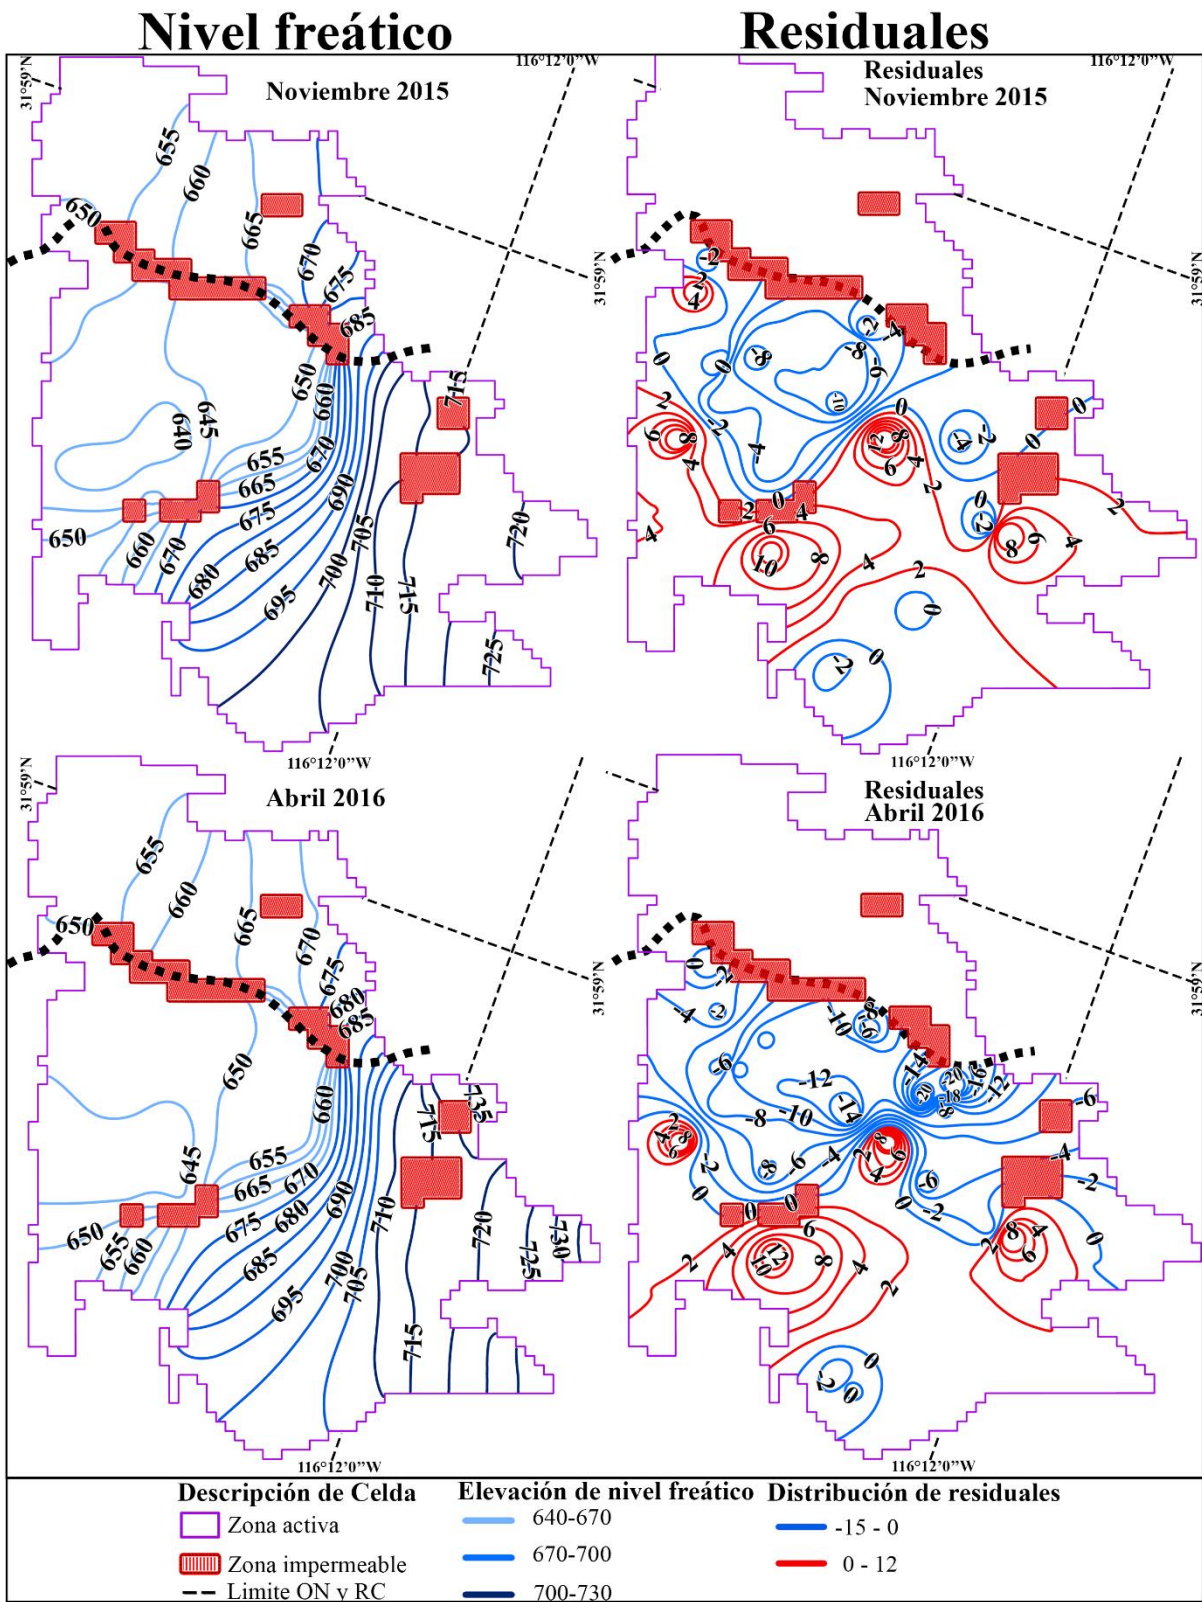


Figura F10. Resultados de NF y Residuales. Noviembre 2015 y Abril 2016

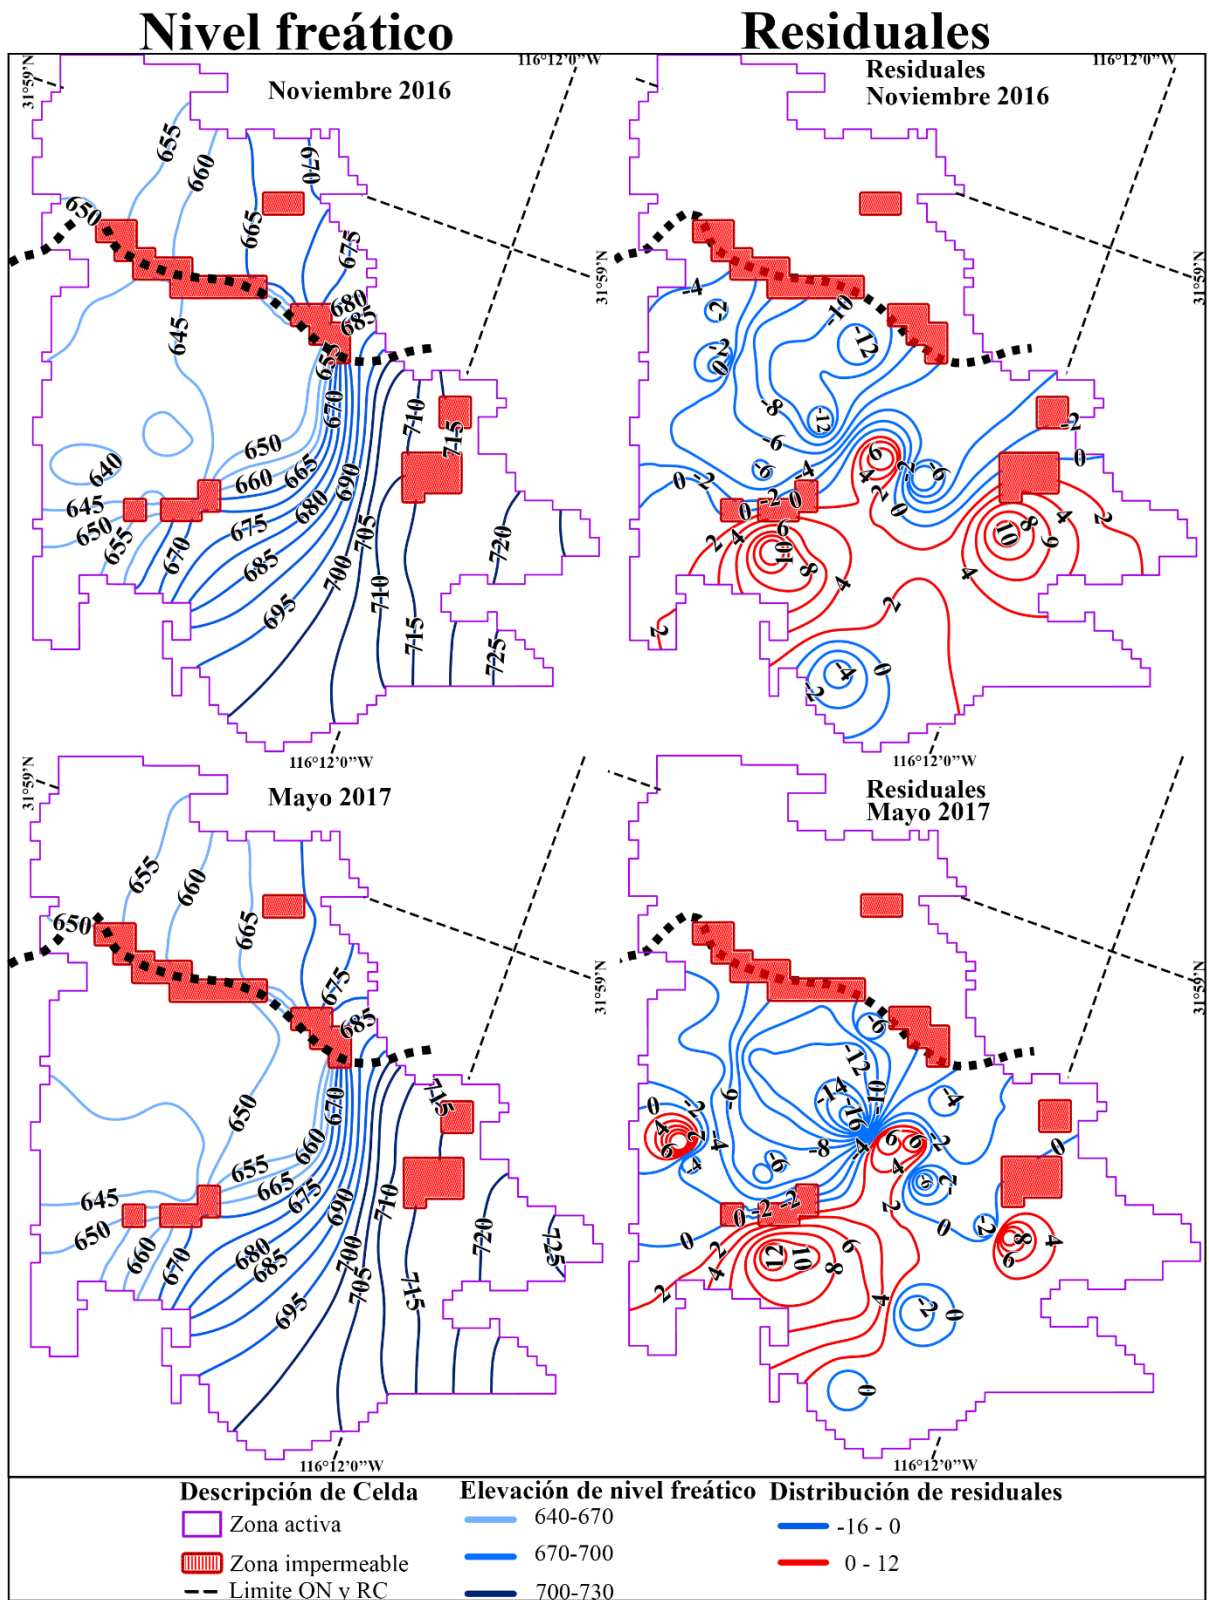


Figura F11. Resultados de NF y Residuales. Noviembre 2016 y Mayo 2017

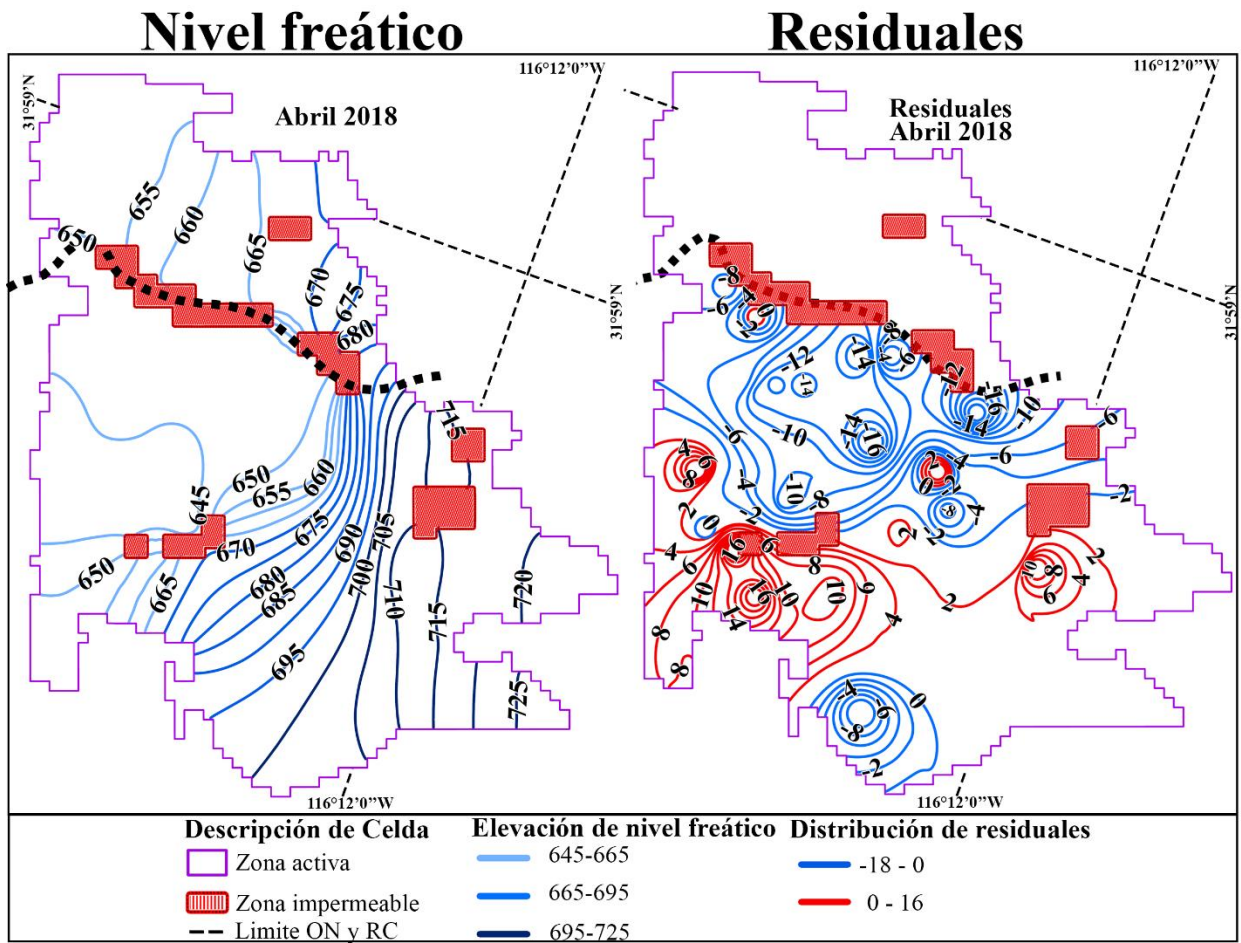


Figura F12. Resultados de NF y Residuales. Abril 2018