



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO  
PROGRAMA DE MAESTRÍA EN CIENCIAS DE LA TIERRA  
INSTITUTO DE GEOLOGÍA**

APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE  
MÉXICO

TESIS  
PARA OPTAR POR EL GRADO DE  
MAESTRO EN CIENCIAS DE LA TIERRA

PRESENTA:  
MIGUEL ANGEL CUBILLOS FAJARDO

TUTOR PRINCIPAL:  
DR. ERIC MORALES CASIQUE  
INSTITUTO DE GEOLOGÍA

CIUDAD UNIVESITARIA, CD. MX., AGOSTO 2023



Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



## **DEDICATORIA**

Dedico este trabajo a mis familiares y amigos que me apoyaron a lo largo de estos años, sobre todo a mi madre, Adriana Fajardo y a mi novia, Melissa Morales, por su amor y compañía.

## AGRADECIMIENTOS

Expreso mis agradecimientos:

A los miembros del Posgrado en Ciencias de la Tierra y del Instituto de Geología por toda su colaboración a lo largo de esta etapa.

Al Dr. Eric Morales Casique por su invaluable asesoría durante la realización de esta investigación, que con su conocimiento y su siempre presta disposición a orientarme y a resolver las necesidades que surgían, permitieron culminar exitosamente este trabajo.

A la Dra. Graciela Herrera, al Dr. Enrique Cabral y al Dr. Antonio Espriu por contribuir con su conocimiento a enfocar este proyecto, quienes además proporcionaron amablemente algunas de las bases de datos utilizadas.

Al Dr. Abelardo Rodríguez Pretelín, a la M. en C. Priscila Medina, a la Ing. Ysamar Pino y la empresa Sísmica de Suelos S.A. de C.V., y al Ing. Octavio Castro y su empresa Geotest por asesorarme y facilitarme insumos esenciales para la creación del modelo.

A los miembros del comité revisor el Dr. Oscar Escolero y el Dr. Efraín Ovando por aportar con sus importantes comentarios a mejorar este trabajo.

Al M. en C. José Miguel Jiménez, Katy Ángel, Yuly Torres, Jennifer Enciso, Ingrid Llanos, John Ortiz y Juan Sebastián por su amistad y apoyo.

# CONTENIDO

	Página
<u>RESUMEN</u> .....	8
1. <u>INTRODUCCIÓN</u> .....	10
1.1. <u>Antecedentes</u> .....	10
1.2. <u>Planteamiento</u> .....	13
1.3. <u>Objetivos</u> .....	14
1.4. <u>Justificación</u> .....	15
2. <u>ÁREA DE ESTUDIO</u> .....	16
2.1. <u>Descripción de la zona</u> .....	16
2.2. <u>Marco geográfico</u> .....	17
2.3. <u>Marco geológico</u> .....	21
2.4. <u>Marco hidrogeológico</u> .....	26
2.5. <u>Información geotécnica</u> .....	28
3. <u>METODOLOGÍA</u> .....	35
4. <u>MARCO TEÓRICO</u> .....	39
4.1. <u>Teoría de la consolidación</u> .....	39
4.2. <u>Subsidencia</u> .....	45
4.3. <u>Redes neuronales</u> .....	51
4.4. <u>Hipótesis</u> .....	62
5. <u>BASES DE DATOS</u> .....	69
5.1. <u>Escalamiento</u> .....	69
5.2. <u>Datos manejados</u> .....	70
5.2.1. <u>Espesor</u> .....	70
5.2.1.1. <u>Espesor Hidrofacies A</u> .....	70
5.2.1.2. <u>Espesor Hidrofacies A mejorado</u> .....	79
5.2.1.3. <u>Espesor acuitardo superior</u> .....	82

5.2.2.	<u>Compresibilidad de las rocas</u> .....	84
5.2.2.1.	<u>Coeficiente de compresibilidad</u> .....	84
5.2.2.2.	<u>Contenido de agua</u> .....	88
5.2.2.3.	<u>Límite plástico y límite líquido</u> .....	89
5.2.2.4.	<u>Índice de compresión</u> .....	90
5.2.3.	<u>Carga de preconsolidación</u> .....	93
5.2.3.1.	<u>Unidades socio económicas por localidad</u> .....	97
5.2.3.2.	<u>Número de viviendas por localidad</u> .....	100
5.2.3.3.	<u>Población por localidad</u> .....	101
5.2.3.4.	<u>Áreas verdes por localidad</u> .....	102
5.2.3.5.	<u>Intensidad de la lluvia por localidad</u> .....	103
5.2.3.6.	<u>Caudal de extracción puntual</u> .....	104
5.2.3.7.	<u>Correlaciones</u> .....	106
5.2.4.	<u>Litología</u> .....	107
5.2.5.	<u>Abatimiento</u> .....	108
5.2.6.	<u>Tasa de hundimiento</u> .....	110
5.2.6.1.	<u>Usando INSAR</u> .....	111
5.2.6.2.	<u>Usando la red de bancos</u> .....	112
5.2.7.	<u>Retardo</u> .....	114
5.2.7.1.	<u>Usando tasa de hundimiento promedio</u> ..	115
5.2.7.2.	<u>Usando tasa de hundimiento por intervalos</u> .....	116
6.	<u>RESULTADOS</u> .....	118
6.1.	<u>ETAPA 1</u> .....	118
6.2.	<u>ETAPA 2</u> .....	128
7.	<u>DISCUSIONES Y RECOMENDACIONES</u> .....	148
8.	<u>CONCLUSIONES</u> .....	151
9.	<u>REFERENCIAS</u> .....	153
10.	<u>ANEXOS</u> .....	157

## RESUMEN

El estudio de la subsidencia en el mundo, así como en la Ciudad de México, ha sido analizado bajo diferentes metodologías. Las técnicas utilizadas combinan una serie de relaciones teóricas junto con la calibración de un conjunto de parámetros; los modelos resultantes tendrán una composición diferente entre las proporciones teóricas y los parámetros a calibrar, generando pronósticos con distintos márgenes de precisión.

Los modelos basados en relaciones puramente teóricas, donde no se requiere establecer el valor de parámetros que no tienen una razón física visible, sino que más bien son construcciones matemáticas que se obtienen del análisis de datos medidos, son por construcción, esquemas aptos para usarse en diversas variaciones del fenómeno estudiado, mientras se mantengan las condiciones mínimas de simplificación teórica del modelo, reproduciendo con una buena precisión el suceso. No obstante, los modelos mencionados pueden no contar con toda la variedad de variables que se quiere analizar, en tal caso, se necesitará recurrir a ecuaciones complementarias, algunas probablemente no conocidas hasta ahora, para finalmente, configurar la importancia que tendrá todo un conjunto de datos de predictores, variables, sobre la manifestación natural estudiada.

Para construir modelos, quizás con una menor precisión, pero con la versatilidad para componer relaciones usando una gran diversidad de predictores sobre una o múltiples variables de salida, están las redes neuronales.

En esta investigación se avanzó en el estudio de la subsidencia de la Ciudad de México bajo el enfoque de las redes neuronales. Como bien se mencionó, estos modelos tienen una menor precisión que los modelos basados en un análisis físico y matemático más profundo, sin embargo, los modelos de redes neuronales en este trabajo permitieron conocer la importancia cuantitativa que tiene una serie de características y propiedades, algunas medidas en diferentes unidades geológicas del sistema, sobre el análisis de la subsidencia que sufre la ciudad; este insumo básico es importante para hacer una efectiva gestión del riesgo. Un diagnóstico de esta envergadura que, admite propiedades tan distintas, y que han sido ajustadas en diversas partes del acuífero o del acuitardo del sistema de la ciudad, puede dificultarse bajo el uso de modelos convencionales.

El modelo determinado en esta tesis para la Ciudad de México permite separar en orden de importancia las variables estudiadas para predecir subsidencia en tres grupos que son:

- Importancia alta: Las propiedades de la Arcilla Superior, y queda en duda, si las propiedades de la Arcilla Inferior también podrían estar en este grupo de existir un catálogo de datos más robusto.
- Importancia media: Las propiedades de la Capa Dura, el espesor del acuitardo y el abatimiento en el acuífero.
- Importancia baja: densidad de viviendas, densidad de unidades comerciales, industriales y de servicio, y densidad de áreas verdes.

Este modelo también nos permitió descartar la relevancia que tiene la intensidad de lluvia y el caudal de extracción puntual sobre las predicciones de hundimiento. Finalmente, se obtiene un valor de retardo homogéneo para toda la zona con magnitud de 4 años aproximadamente, el retardo representa el tiempo que debe transcurrir luego de extraer agua subterránea, una perturbación, para evidenciar la disminución en el espesor del acuífero, la consecuencia. Adicional, se pudo calcular el volumen de almacenamiento perdido en los años para los que se calibró el modelo y se obtuvo un modelo con una precisión tal vez menor a lo logrado con otros modelos, pero que permite predecir subsidencia dentro de un margen de error aceptable.

## 1. INTRODUCCIÓN

### 1.1. Antecedentes

En los últimos años ha aumentado el uso de algoritmos de inteligencia artificial para el modelado de fenómenos en ciencias de la tierra, la particularidad que presentan estos métodos, y que ha impulsado su auge, es su capacidad para modelar conjuntos de datos no lineales y de gran dimensión, incluidas interacciones complejas y valores faltantes (Rahmati, y otros, 2018).

El mapeo y modelado de fenómenos que conllevan un peligro para la humanidad es de gran interés en este campo, centrandose los trabajos en estudiar cada peligro por separado, e incluyen aplicaciones en inundaciones (Darabi, y otros, 2018), subsidencia (Chen, y otros, 2020) (Smith & Majumdar, 2020), contaminación (Barzegar, Asghari, Adamowski, & Fijani, 2017) (Rahmati, y otros, 2019), avalanchas e incendios, entre otros; o recientemente, estableciendo marcos de trabajo para múltiples peligros (Yousefi, y otros, 2020).

La técnica, sin importar el algoritmo que se escoja para modelar, parte de la búsqueda de una gran variedad de variables independientes que estén relacionadas con nuestro fenómeno, este último, representando la variable dependiente (Yousefi, y otros, 2020). Escoger solo variables características es una tarea que puede influir en el rendimiento y precisión del modelo (Bui, y otros, 2018), sin embargo, los modelos de inteligencia artificial, y sobre todo los modelos de machine learning, permiten estimar la contribución que cada variable aporta. Esta cualidad es una directriz a la hora de enfocar nuestro modelo hacia una disminución, o, por el contrario, hacia una búsqueda de nuevas variables que mejoren el poder predictivo del algoritmo.

Por último, al aplicar técnicas de inteligencia artificial se debe seleccionar el algoritmo o algoritmos que mejor desempeño pueden llegar a tener dada la aplicación en la que se emplean, para el modelado de peligros naturales se ha demostrado que SVM, BLR, BRT y GAM son algoritmos que obtienen gran precisión al modelar distribuciones espaciales (Ebrahimi, Feizizadeh, Salmani, & Azadi, 2020) (Rahmati, y otros, 2019) (Zamanirad, Sarraf, Sedghi, Saremi, & Rezaee, 2020), no obstante, algoritmos más complejos, como redes neuronales profundas o redes de grafos, han sido poco o nada usados en este campo. Junto con el algoritmo es requerido escoger las estadísticas idóneas para estimar la validación y evaluación del modelo,

la revisión bibliográfica indica que los valores AUC y los valores de precisión de predicción sobre los datos de entrenamiento y validación, son los mejores estimadores y los más usados (Abdollahi, Pourghasemi, Ghanbarian, & Safaeian, 2019) (Zamanirad, Sarraf, Sedghi, Saremi, & Rezaee, 2020).

Los mapas obtenidos hasta el momento para los modelos de estos fenómenos naturales solo consideran las variaciones espaciales, más no las temporales, las razones principales están enmarcadas por la indisponibilidad de datos a través del tiempo (Rahmati, y otros, 2018), por la complejidad temporal de los fenómenos o por el tipo de algoritmo usado. Los recientes avances en deep Learning, como las redes neuronales de grafos, pueden ser la base para un primer acercamiento temporal en este campo. También se puede usar una red neuronal profunda para llevar a cabo esta tarea, pero considerando el fenómeno como uno con un comportamiento temporal discreto, no como un continuo, esto conlleva un error en la modelación del suceso, pero que, en principio, puede ser un buen comienzo para estudios temporales, y con un grado de complejidad mucho menor que al implementar una red neuronal de grafos.

Al centrarnos en el estudio de la subsidencia encontramos en la literatura varias publicaciones recientes que, aplican una metodología muy similar entre ellos basada en algoritmos de machine learning. Los resultados de estos artículos se enfocan en construir mapas uni-temporales de probabilidad de subsidencia, o lo que muchos de ellos denominan “Mapas de Susceptibilidad de Subsidencia” (Ebrahimy, Feizizadeh, Salmani, & Azadi, 2020), sin embargo, estos mapas reducen significativamente el poder predictivo de sus modelos al limitar sus investigaciones al estudio espacial de probabilidades, cuando se podría llegar a cuantificar la razón del hundimiento en alguna unidad de tiempo; este último camino es tomado por un único autor, (Smith & Majumdar, 2020), en la literatura considerada. Otro de los propósitos expuestos en los artículos consultados es la aplicación de gráficos de dependencia para establecer cuantitativamente la importancia que tiene cada una de las variables predictoras sobre la predicción de la variable de interés, variable predicha, dicho objetivo es compartido por todas las referencias leídas y se identifica claramente, como el interés principal en el artículo de (Chen, y otros, 2020). Para cumplir estas metas, los autores requieren partir de la selección de un conjunto relevante de predictores, en la mayoría de las investigaciones es tomado de manera muy general y amplia (Ebrahimy, Feizizadeh, Salmani, & Azadi, 2020), abarcando no solo propiedades del sistema hidrogeológico, sino que adicionan algunas propiedades ambientales, antropogénicas y topográficas. Es el caso del trabajo de (Zhi-xiang, Pei-xian, Li-li, & Ka-zhong, 2009) donde usan 8 variables distintas, todas con una orientación topográfico, o el estudio de (Ebrahimy, Feizizadeh, Salmani, & Azadi, 2020) con alrededor de 12 variables distintas englobando

ámbitos muy diversos. Al final, muchos estudios terminan reflejando la poca relevancia que suscitan muchos de los predictores escogidos, no obstante, la investigación de (Chen, y otros, 2020), donde se analiza el peso que aporta cada uno de los cambios en el nivel piezométrico de cada uno de los tres acuíferos que conforman un territorio de Beijing sobre la subsidencia en la zona, aplica de manera muy selectiva la elección de predictores; o más destacado aún, el artículo de (Smith & Majumdar, 2020) donde se parte de una relación teórica simplificada del fenómeno para proponer las variables necesarias para entrenar un algoritmo predictivo de machine learning.

Como es posible observar, la aplicación en masa de inteligencia artificial para estudiar subsidencia es de reciente florecimiento, por lo que no es posible encontrar un artículo que contenga una metodología estandarizada que contemple todo el estudio del fenómeno de hundimientos en una región, debido a la extracción de agua bajo una mirada de las redes neuronales, aun así, por lo que ya se ha visibilizado, el trabajo realizado por (Smith & Majumdar, 2020) es un buen punto de partida.

Ahora bien, hay varios interrogantes enmarcados en lo realizado por los dos anteriores autores, la principal duda es con respecto a la simplificación hecha sobre los predictores escogidos, aun cuando la investigación parte de una relación teórica de subsidencia para proponerlos, los autores requirieron tomar algunas propiedades afines y no las que indica la ecuación teórica, debido a la dificultad para obtener bases de datos con los valores de dichas variables en la gran zona de estudio que se escogió. La otra gran duda es respecto a la simplificación temporal que todas las investigaciones han decidido fijar hasta el momento, y es que, aunque la relación teórica considerada por (Smith & Majumdar, 2020) tampoco hace uso de consideraciones temporales, varios estudios sobre subsidencia muestran la trascendencia que tienen los parámetros temporales para modelar con precisión esta manifestación física. Por ejemplo, en la investigación de (Wang, Keming, Wei, Shi, & Yao, 2022) se estudia la función que describe el comportamiento del hundimiento en el tiempo dada una perturbación en las condiciones normales del terreno, esta función revela como la perturbación genera un efecto que perdura en un intervalo temporal extenso, por lo que no considerar los aportes en la subsidencia de perturbaciones previas al rango de años trabajado en cada uno de los estudios, en especial el llevado a cabo por (Smith & Majumdar, 2020), puede acarrear un valor elevado de incertidumbre en el modelo obtenido.

Es importante anotar, que aunque la función propuesta por (Wang, Keming, Wei, Shi, & Yao, 2022) contiene un parámetro que involucra los cambios temporales, es difícil partir de esta ecuación para

proponer los predictores necesarios para un modelo de machine learning, por lo que el término temporal no parte de una variable física medible sino de un factor matemático a calcular, y aunque los autores identifican dependencias de este con algunas variables físicas medibles, su forma más precisa de averiguarlo es mediante un proceso de calibración con datos, razón por la cual se tendría que añadir como una variable a predecir en el algoritmo de redes neuronales, aumentando enormemente la complejidad del modelo, y requiriendo seguramente una base de datos mucho más grande para entrenarlo debido a que se tendrían dos valores a calibrar, el hundimiento y un factor temporal.

## **1.2. Planteamiento**

El trabajo se centró en aplicar algoritmos de machine learning al estudio espacial, primeramente, de la subsidencia en la Ciudad de México, para, finalmente, aplicar los modelos a una primera aproximación temporal del fenómeno. La motivación por aplicar este tipo de estrategias nace de la necesidad de diseñar marcos de trabajos para la gestión del riesgo, ante desastres causados por efectos originados por la actividad humana. Cabe anotar que estos modelos no explican el fenómeno como si lo realiza un análisis físico de las ecuaciones que rigen su comportamiento, sin embargo, la complejidad que representa establecer un análisis de este estilo, en un sistema tan complejo como el que se esquematiza para el subsuelo de la Ciudad de México, nos insta a resaltar el gran aporte que podría hacerse con un enfoque predictivo, moderadamente preciso y basado en los datos, como lo es el uso de estrategias apoyadas en inteligencia artificial.

Ahora bien, como ya se mencionó previamente, los algoritmos que se proponen no son actos para deducir las funciones que describen físicamente el fenómeno, aun así, es posible determinar el peso que cada variable tiene sobre la predicción. Con este resultado, y aún sin tener un conocimiento completo de las interacciones del sistema, es posible construir directrices para la gestión del riesgo con un grado importante de confiabilidad.

Un segundo producto, y no menos importante, es la creación de un modelo para generar pronósticos del hundimiento en la ciudad. Y si bien, este tiene un grado de incertidumbre no tan bajo como el obtenido con otros enfoques, puede convertirse en un insumo importante para la toma de decisiones futuras.

El área de estudio, que, en principio, se pretendía fuera todo el Valle de México, tuvo que ser reducido a la Ciudad de México por la falta de bases de datos de múltiples fenómenos en el resto de la zona de interés. La metodología aplicada parte de emplear las bases recogidas en el trabajo de (Smith & Majumdar, 2020). Sin embargo, la estrategia se modificó a lo largo de este trabajo a fin de mejorar las simplificaciones que se manejan, y extender su alcance a un estudio no solo espacial sino temporal de la subsidencia.

La segunda parte del estudio, como ya se mencionó, que también se restringió por la calidad de los datos, proporcionó un acercamiento al modelado temporal de la subsidencia. En esta primera aproximación se aprovechó la misma red neuronal profunda, no obstante, por las propiedades y ventajas que tiene cada algoritmo de machine learning, una red neuronal de grafos, un algoritmo de síntesis de fotogramas de video como Deep Voxel Flow, o una red neuronal recurrente podrían proporcionar resultados más fiables, ya que permiten incorporar más hechos físicos del sistema.

### **1.3. Objetivos**

- Construir un modelo basado en machine learning que permita estimar la distribución espacial y/o temporal de la subsidencia, por medio de una serie de variables topográficas, geológicas e hidrológicas.
- Estimar el retardo homogéneo que experimenta la Ciudad de México, este valor hace referencia al tiempo que le toma al terreno disminuir su espesor después de una perturbación en el nivel piezométrico del agua.
- Evaluar la contribución que cada variable del modelo, tanto variables geológicas, como ambientales y antropogénicas, sostienen sobre el modelo de subsidencia propuesto.
- Calcular el volumen de almacenamiento de agua perdido por el acuífero durante el periodo de tiempo con los mejores valores de calibración.
- Se requiere comprobar el supuesto que establece que la capa con la mayor capacidad de subsidencia en el terreno es la hidrofacies A, esto con base en el material y las propiedades que la componen. No obstante, debido a la falta de precisión que tiene el algoritmo diseñado para pronosticar la hidrofacies A en las zonas donde no se tienen bases de datos de esta propiedad, lo que ocurre en una extensa región del modelo, será necesario trabajar con el espesor completo del acuitardo que integra a dicha hidrofacies. Al asumir el espesor completo del acuitardo superior en

lugar de la hidrofacies A, una consideración más general, en principio se esperaría un mejor ajuste en los modelos al abarcar la mayoría de los estratos de arcilla, material con un potencial de consolidación superior. Sin embargo, al hacer uso del acuitardo en su totalidad, también se introducen algunos espesores de capas más duras con un potencial muy bajo de consolidación, añadiendo ruido al modelo.

#### **1.4. Justificación**

Modelos que describan fenómenos como la subsidencia ya existen, no obstante, se tienen algunas limitaciones, por ejemplo los modelos basados en InSAR pueden llegar a ser computacionalmente costosos de estimar a escala, y están sujetos a errores ionosféricos y troposféricos, o modelos basados en GPS pueden dejar vacíos espaciales y/o temporales (Smith & Majumdar, 2020).

Es por ello, que un modelo apoyado en técnicas de inteligencia puede ser una gran alternativa para subsanar muchas de las actuales dificultades. En Latinoamérica, según la revisión bibliográfica, aún no existe un trabajo que aplique algoritmos de machine learning para modelar espacialmente la subsidencia. Finalmente, un acercamiento al modelo temporal de la subsidencia usando inteligencia artificial aún no se ha considerado.

Otro tipo de modelos basados en ecuaciones físicas, que requieran la calibración de parámetros, es posible que ya se hayan desarrollado para predecir subsidencia en la Ciudad de México. Estos modelos muy seguramente, y dependiendo del grado de simplificación introducido, pueden generar pronósticos con un grado de fiabilidad mayor, aun así, es complejo establecer el grado de importancia que tendrán una serie de propiedades hidrogeológicas, topográficas y antropogénicas que están ligadas a las variables que aparecen en las relaciones físicas, pero que no se muestran de manera explícita en las ecuaciones, sino que es necesario aplicar relaciones alternas, quizás aun no estudiadas, para evaluar su importancia en la predicción. Es la necesidad de conocer los pesos de estas propiedades para hacer una buena gestión del riesgo, lo que motiva el uso alternativo de las redes neuronales.

## 2. ÁREA DE ESTUDIO

### 2.1. Descripción de la Zona

El área de estudio inicial comprende una subregión de la Zona Metropolitana del Valle de México, principalmente, lo concerniente a la Ciudad de México y una pequeña porción del Estado de México, que hicieron parte del antiguo lago de Texcoco; este origen en común le confiere a la superficie una característica propia, la capacidad para comprimirse, que es la base para motivar este estudio. Las latitudes 19.2°N y 19.56°N, y las longitudes 99.23°W y 98.94°W delimitan la zona de investigación que consta de 488 Km<sup>2</sup>.

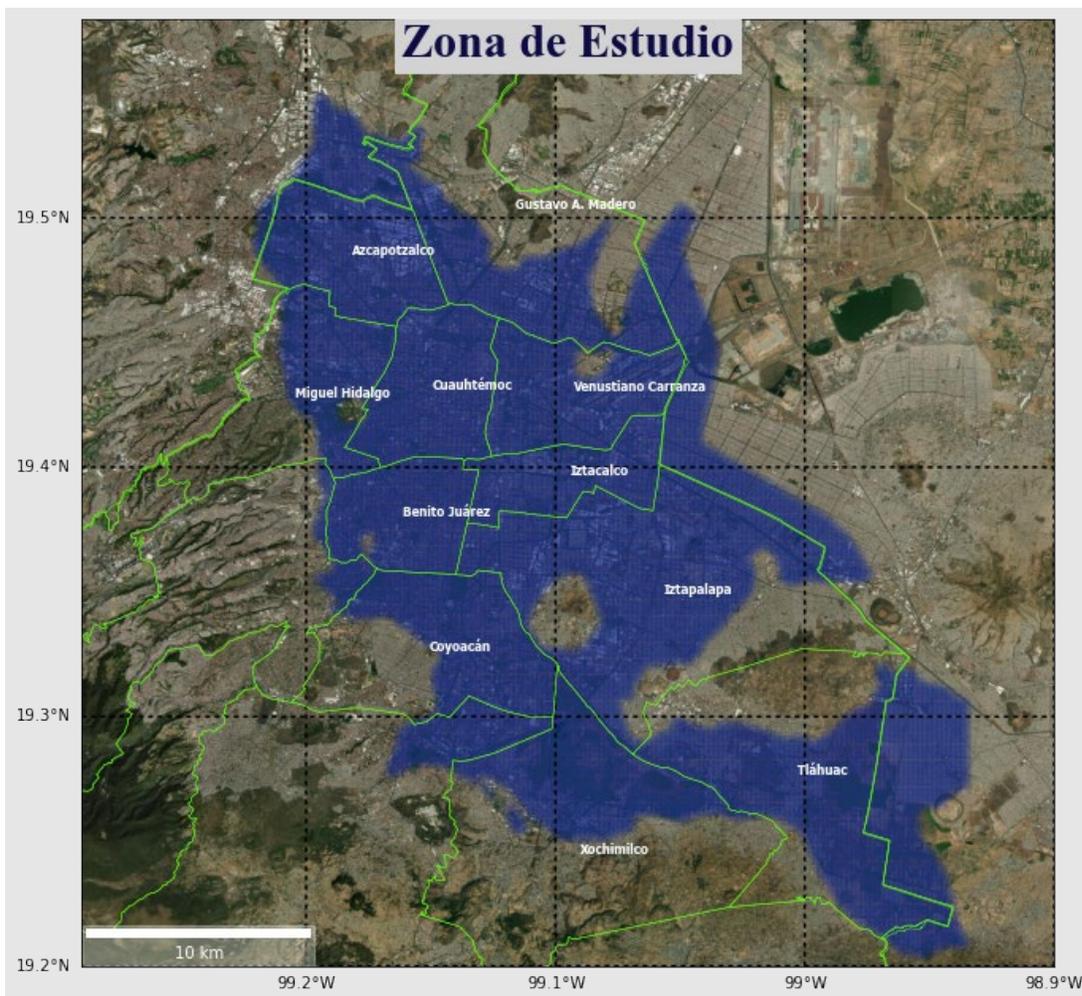


Figura 2-1: Ubicación del área de estudio, en azul. Con líneas verdes se referencia a la Ciudad de México y su división en delegaciones.

No obstante, la falta de datos para estimar la carga de preconsolidación en todo el dominio, requirió buscar fuentes alternativas de información que permitieran estimar esta variable, resultando de esta manera, en la propuesta de una serie de medidas antropogénicas, hidrológicas e hidrogeológicas que sólo son fáciles de encontrar, en escala de alta precisión, sobre la Ciudad de México. La consecuencia anterior encaminó el trabajo a restringir su alcance a solo el área azul de la Figura 2-1, que se encuentra dentro de los límites de la Ciudad de México (denotado por las líneas verdes).

## 2.2. Marco geográfico

En la zona se destacan varios rasgos topográficos con un origen volcánico, y que en conjunto forman parte de una cuenca endorreica. Al norte y noroeste se encuentra la Sierra de Guadalupe y la Sierra de Montealto junto con el Cerro de Chapultepec y el Cerro del Chiquihuite; al occidente delimitan la Sierra de Las Cruces y la Sierra del Ajusco conformadas por algunas topoformas como el Cerro la Cruz del Marqués, Cerro El Charco y el Volcán Pelado; al sur está presente la Sierra Chichinautzin donde se resaltan algunos picos como el Volcán Tláloc, Volcán Chichinautzin, Volcán Acopiaco, Volcán Cuautzin y el Cerro Cilcuayo; al este sobresale la Sierra Nevada y la Sierra de Río Frío con el Volcán Guadalupe (El Borrego) como una topoforma notable; finalmente, en el centro predomina la Sierra de Santa Catarina con el Volcán Teuhtli además del Cerro de La Estrella.

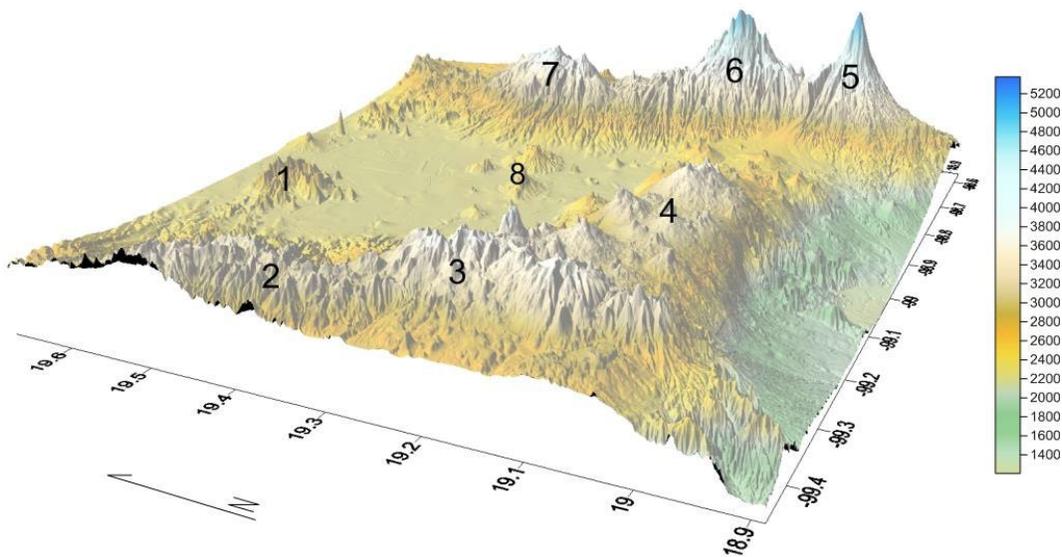


Figura 2-2: Topoformas del sector de estudio. (1) S. de Guadalupe. (2) S. de Montealto. (3) S. de las Cruces y S. del Ajusco. (4) S. de Chichinautzin. (5) Volcán Popocatepetl. (6) S. Nevada. (7) S. de Río Frío. (8) S. de Santa Catarina. Tomado de (Pescador, 2016)

En cuanto a la Población, la Zona Metropolitana del Valle de México (ZMVM) experimentó un aumento en casi tres veces su número durante 1950 a 1980, gran parte del crecimiento se explica por la llegada de inmigrantes provenientes de otras regiones del país en búsqueda de mejores oportunidades laborales (Espejel, 2019). La explicación de estos flujos migratorios se da por las políticas económicas manejadas en la época, concentrando casi el 46.6% del Producto Interno Bruto (PIB) del país en la ZMVM y unos pocos Estados aledaños. Aunque un cambio hacia políticas descentralizadas y orientadas al exterior se orquestó en la década de los ochenta, lo que redujo la concentración del PIB en la zona a casi el 30.3% para 1993, combinado con el efecto de una diseconomía de escala, es decir, un aumento en los costos de construcción de infraestructura, transporte de bienes y de adquisición de la tierra; y una caída de la oferta de bienes y servicios públicos causado por crecimiento demográfico (Espejel, 2019), terminaron desescalando el incremento de los flujos migratorios y por lo mismo, la tasa a la que la población crecía. Para 1998 la ZMVM si se considerará una ciudad, hubiese sido la segunda ciudad más poblada del mundo con 18.1 millones de personas, solo por debajo de Tokio, Japón que contaba en su momento con 26.8 millones de residentes (IGECEM, 1999). Actualmente, la población sigue su crecimiento lentamente, con un continuo desplazamiento desde las áreas centrales hacia los municipios conurbados de la periferia, en donde se concentran las mayores tasas de ampliación a causa de mayores áreas rurales, y una directiva hacia la creación de viviendas pequeñas e inadecuadas (Pradilla, 2005).



Figura 2-3: Crecimiento de la población en la CDMX, la ZMVM y en todo el país durante los últimos años (Pradilla, 2005).

La distribución de la población en la zona ha marcado el punto de desarrollo del tejido empresarial, enmarcando así los sectores en donde se concentra la mayor densidad de construcciones. La ZMVM como ya se mencionó, empieza a sufrir un proceso de desindustrialización desde 1982, especialmente sobre la CDMX, afectando entre otras a las industrias manufactureras y automotriz, desplazándose a otros lugares del país, como las zonas aledañas a los Estados Unidos, impulsadas por los tratados de libre comercio con Estados Unidos y Canadá (Pradilla, 2005). De esta manera, se configura el único centro metropolitano en el país que da un giro a su patrón de desarrollo, de una economía industrial basada en la manufactura a una nueva economía basada en los servicios (Espejel, 2019).

Las antiguas construcciones sufrieron un proceso de transformación, por lo que no todas terminaron demolidas, muchas se convirtieron en bodegas, centros comerciales, oficinas o viviendas, mientras que otras aún continúan abandonadas. En el auge del sector comercial y de servicio se resaltan en toda la ZMVM el sector financiero, seguros y bienes inmuebles; los servicios comunales, sociales y personales, además de los centros de investigación; y en una menor escala, el comercio, restaurantes y hoteles (Pradilla, 2005). Por su parte, en la CDMX las principales actividades son los servicios privados no financieros, comercio y transporte, correos y almacenamiento (Espejel, 2019). En vista de este panorama, se aprecia cómo aunque la región sufre un cambio de modelo económico desde hace varias décadas, el crecimiento de la infraestructura se ha mantenido a lo largo del tiempo, lo que introduce un fuerte impacto en las condiciones del terreno, y es que solo en la CDMX a 2017, se reportaban entre unidades comerciales y de servicios gubernamentales, 210.621 comercios, 87 unidades político-administrativas del poder ejecutivo, 10.040 unidades del poder judicial y 121 unidades de transparencia (Espejel, 2019). En cierta medida la explicación a este aumento en las construcciones que prestan servicios se debe a la demanda que genera la población que vive en sectores colindantes a la CDMX, y a pesar de que no viven en ella, recorren día a día distancias considerables para abastecerse en la ciudad de sus necesidades, lo que ejerce gran presión sobre la infraestructura de la zona (Pradilla, 2005).

Por su parte, la densidad de viviendas, y no solo la densidad de unidades económicas es un factor que condiciona la calidad del subsuelo, sobre todo del acuífero subyacen, por lo que determinar su aumento nos permitirá analizar el impacto que tiene sobre la calidad del recurso hídrico.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

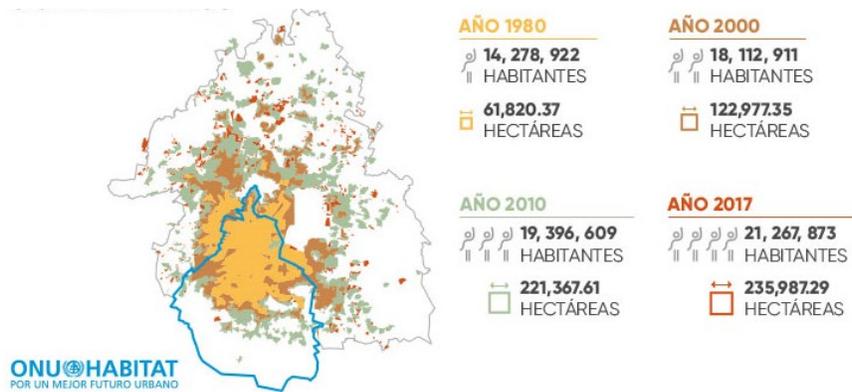


Figura 2-4: Evolución de la huella urbana en la ZMVM. Tomado de (ONU, 2018).

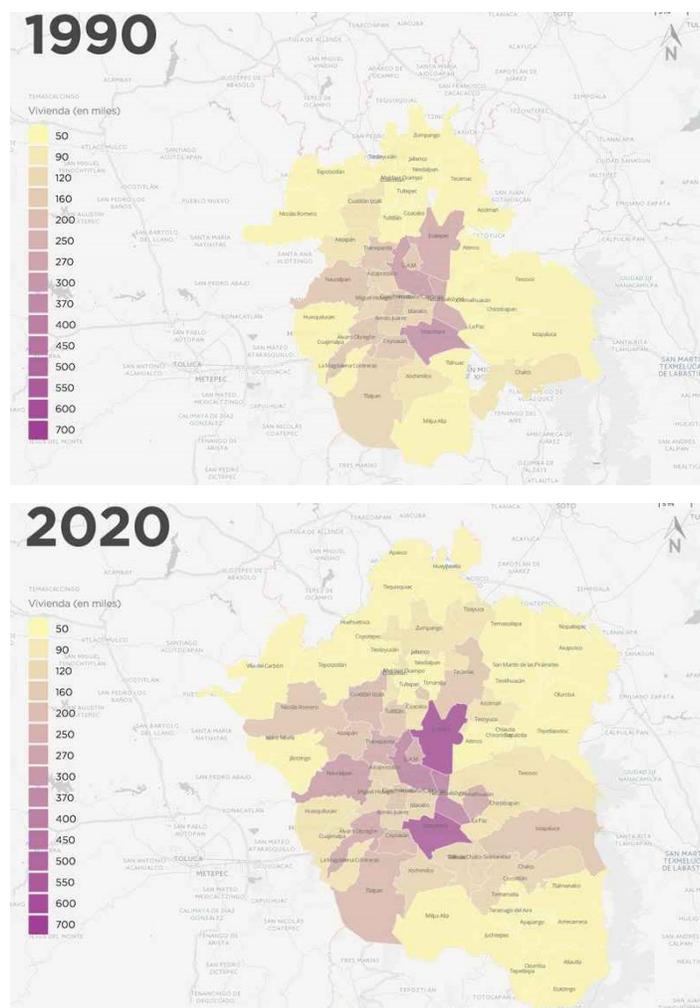


Figura 2-5: Evolución de la densidad de viviendas en la ZMVM. Datos para el año 1990 (parte superior). Datos para el año 2020 (parte inferior). Tomado de (Heisinger & González, 2015)

El proceso de urbanización de la ZMVM ha si orientado por los procesos de producción (extracción y transformación de la materia, pesca, agricultura, flora), intercambio (comercio, transporte, finanzas, telecomunicaciones y manejo de residuos), servicios básicos (vivienda, salud, educación, recreación y deportes, cultura, culto), servicios jurídicos y administrativos (instituciones públicas, ministerios, gubernaturas y tribunales de justicia, instituciones de defensa y seguridad, fuerzas armadas, policiales y defensa civil y seguridad ciudadana e instituciones privadas sin fines de lucro) (Espejel, 2019).

### **2.3. Marco geológico**

Para entender las características del suelo lacustre del Valle de México es necesario describir los procesos que lo generaron. En especial, (Mooser, 1975) menciona 7 fases que estructuran la configuración actual de la geología de la zona.

En la primera fase en el Terciario Inferior se producen rocas volcánicas que no afloran en superficie, intrusivas. En la segunda fase se tiene la presencia de coladas de lava de composición ácida e intermedia de edad Oligoceno Medio. En la tercera fase se producen pequeñas elevaciones aisladas de terreno formadas por depósitos de dacitas y riolitas, la edad los data del Oligoceno Superior. En la siguiente etapa, sucedida en el Mioceno, se conforma un complejo volcánico constituido por lavas intermedias y ácidas, y posteriormente, se le concede el nombre de Sierra de Guadalupe. Para la quinta fase, el volcanismo de composición intermedia - ácida forma las Sierras Mayores, la Sierra Monte Alto y Monte Bajo, La Sierra Río Frío entre otras, su edad corresponde al fin del Mioceno. El volcanismo andesítico-basáltico que conforma los Cerros de La Estrella, Chimalhuacan, Chinonautla, el cerro Gordo y el Peñón del Marqués en el Pleistoceno, instaure la sexta fase. La última fase termina en el Cuaternario Superior con la creación de múltiples derrames lávicos, expulsión de material piroclástico y la formación de centenares de conos, un rasgo predominante de esta etapa es la aparición de la Sierra de Chichinautzin, que cierra la cuenta por el sur.

La conformación de una cuenca cerrada por los continuos levantamientos que sufre la corteza permite la acumulación de agua en este recién formado Valle. Enseguida, los procesos de meteorización y sedimentación fueron acumulando capaz de material aluvial (limos y áreas), y lacustre (arcillas y limos), al igual que material piroclástico (cenizas volcánicas), que luego de someterse a intemperización confiere a las arcillas una alta compresibilidad. Los espesores de este material lacustre tienen variaciones

considerables, en cuanto a que se asentaron sobre un relieve irregular. De manera general se observa un aumento en el espesor de norte a sur (Juárez, 2015).

Para analizar la estratigrafía a detalle, (Vazqu ez & Jaimes, 1989) realizaron una recopilaci n de la geolog a de lo que corresponder a a la ZMVM, las siguientes son las unidades estratigr ficas que ellos describen.

#### **Formaci n Xochicalco (Kx)**

Formaci n descrita por (Fries, 1960) para rese ar a rocas de un ambiente de dep sito de cuenca relativamente profundo, la secuencia la forman calizas con contenido de carb n variable, laminaci n, vetillas y/o n dulos de pedernal. Se data para el Aptiano, y su espesor m ximo m nimo es de 500 m.

#### **Formaci n Morelos (Km)**

Definida por (Fries, 1960). Se propuso para una sucesi n de calizas y dolomitas que afloran en Morelos y en los Estados contiguos del Estado M xico y Guerrero. Su espesor se estima entre 250 a 1000 m. La presencia de foramin feros y algunos macrof siles permitieron establecer el rango estratigr fico de esta unidad entre Albiano hasta comienzos del Cenomaniano. La formaci n Morelos est  formada por una intercalaci n de capas gruesas de calizas y dolom as diagen ticas, concordantes a anhidritas laminadas.

#### **Formaci n Doctor (Kid)**

Definida por (Wilson, Hernandez, & Meave, 1955), es una secuencia de capas de calizas delgadas de tipo mudstone con presencia de n dulos y lentes de pedernal. Presenta intercalaciones de lutitas. Su espesor aproximado es de 200 m, y de edad Albiano Medio a Cenomaniano Temprano.

#### **Formaci n Cautla (Kc)**

Propuesta por (Fries, 1960), su nombre proviene de la ciudad de Cautla y se propone para las calizas ubicadas al poniente de esta ciudad. La presencia de rudistas, gaster podos y entre otros permite datar la formaci n entre el Cenomaniano Tard o y Turoniano Tard o. Est  constituida por tres facies principales: la primera es una sucesi n de capas de calizas con estratificaci n de media a gruesa; la segunda es una sucesi n m s delgada de capas de caliza laminadas con estratificaci n de delgada a mediana; y la  ltima, una sucesi n muy delgada de calizas cl sticas. El color var a entre gris claro a oscuro, y cerca al tope de la capa toma tonalidades rojizas y amarillentas en ciertos sectores; su espesor var a entre 200 y 750 m.

### **Formación Mezcala (Kmx)**

Propuesta por (Fries, 1960). Se establece para referirse a la sucesión de capas interestratificadas de areniscas, limolitas y lutitas calcáreas con algunos lentes de calizas clásticas en cercanías al pueblo Mezcala. Con ammonoideos y pelecípodos se determina una edad de Coniaciano a Campaniano. Espesor máximo de 1500 m.

### **Grupo Balsas (Teob)**

Definido por (Fries, 1960), comprende una gran variedad de rocas a lo largo de la cuenca hidrológica del río Mezcala – Balsas, este grupo comprende varias formaciones y litológicamente consta de: calizas lacustres, yeso, caliza con conglomerados, conglomerados volcánicos, areniscas tobáceas, limolitas tobáceas y arcillolitas. Se asigna una edad de Eoceno Tardío al Oligoceno Temprano

### **Rocas volcánicas del Oligoceno Tardío – Mioceno Temprano (Tomv)**

Es una serie de rocas volcánicas que varía entre andesita a riolacita, tobas líticas, brechas tobáceas y aglomerados con derrames intercalados con espesores de capas aluviales de 6 m.

### **Rocas extrusivas del Mioceno Medio y Tardío (Tmv)**

Se evidencian pequeños afloramientos en los cerros El Judío, Los Remedios y El Peñón de los Baños entre otros. Consta de una sucesión de tobas, brechas volcánicas e intercalaciones de derrames de composición andesítica, dacítica y andesitas de hiperstena. Se ha reportado un espesor máximo de 810 m y se fija una edad del Mioceno Medio al Mioceno Tardío.

### **Depósitos volcánicos del Plioceno Temprano (Tpv)**

Es un segundo ciclo magmático que aflora en las Sierras de Guadalupe y Zempoala. Se encuentra interdigitada con los depósitos piroclásticos y clásticos del Plioceno. La composición de las rocas varía de andesita a dacita. Su edad estimada es del Plioceno Temprano.

### **Formación Otomí (Tpo)**

Esta unidad en su mayoría está formada por depósitos piroclásticos que se presentan como flujos lobulados, su espesor es de 1300 m aproximadamente. Se le asigna una edad del Plioceno Tardío.

### **Formación Las Cruces (Tpc)**

Es una secuencia de rocas volcánicas y sucesiones piroclásticas que forman a las sierras de Las Cruces y Monte Alto. Su espesor máximo es de 900 m, y su datación con K/Ar da una edad de Plioceno Tardío.

### **Formación Zempoala (Tpz)**

Consta de lavas andesíticas, flujos de cenizas y brechas volcánicas (Schlaepfer, 1968). Su espesor máximo es de 1000 m en el cerro de Zempoala y su registro data a la formación contemporánea con la anterior, esto es, Plioceno Tardío.

### **Depósitos piroclásticos y clásticos aluviales del Plioceno (Tppc)**

Nombre utilizado por (Fries, 1962) para designar a los depósitos no diferenciados con un espesor máximo de 400 m, relacionados con la actividad fluvial y piroclástica de todo el Plioceno.

### **Formación Llano Grande (Qlg)**

Designa a las secuencias eruptivas andesíticas a riodacíticas que forman el volcán del mismo nombre. La datación la ubica en el Pleistoceno Temprano.

### **Formación El Pino (Qpp)**

Se utiliza para designar las rocas volcánicas máficas, que forman los cerros La Estrella, Los Pinos, Chinonautla entre otros. Su edad corresponde al Pleistoceno Temprano. Su espesor máximo es de 750 m.

### **Formación Tláloc (Qt)**

Establecida por (Schlaepfer, 1968), aludiendo a las coladas lávicas que forman una parte de la sierra de Río Frío. Su composición intercala capas de tefra y flujos piroclásticos lobulados andesíticos, latíticos y dacíticos, con varias secuencias de Pómez. Se propone una edad correspondiente al Pleistoceno.

### **Formación Iztaccíhuatl (Qi)**

También formulada por (Schlaepfer, 1968) con relación a las rocas volcánicas de los volcanes Llano Grande, Iztaccíhuatl y Nexpayantla. Las rocas tienen una composición que varía de andesita basáltica a dacita. Así mismo, comparte la misma edad que la anterior formación, Pleistoceno, y su espesor máximo registrado es de 2500 m.

### **Formación Popocatepetl (Qp)**

Definida por (Carrasco, 1985), para referirse a las secuencias eruptivas que formaron el estrato volcán Popocatepetl. Se presentan 4 secuencias que se componen de bloques laicos con imbricación y con capas laminares; andesitas ricas en olivino, andesitas y dacitas; andesitas con episodios explosivos ricos en pómez, ceniza y productos piroclásticos; y etapas efusivas y explosivas que construyen el cono. Su edad es del Pleistoceno Tardío. Su espesor máximo reconocido es de 3500 m.

### **Formación Chichinautzin (Qc)**

Definida por (Fries, 1960), para referirse a todo el volcanismo monogenético en la región de la Cuenca de México y sus alrededores, las lavas son de composición andesítica-basáltica y andesítica. Su edad es del Pleistoceno Tardío y el Holoceno. Su espesor máximo registrado es de 1800 m.

### **Depósitos aluviales (Qal)**

Son materiales poco consolidados compuestos de fragmentos de tamaño grava, arena, limos y arcillas de la edad Pleistoceno Tardío. Alcanzan espesores de 300 a 400 m, siendo mayores en el sur y acuñándose en el norte de la cuenca. Sus propiedades hidráulicas los clasifican como un buen acuífero debido a su alta permeabilidad y capacidad de almacenamiento.

### **Depósitos lacustres (Qla)**

Son depósitos clásticos y productos piroclásticos derivados de los volcanes Popocatepetl y de la Sierra de Chichinautzin durante el Pleistoceno Tardío al Holoceno y depositados en una cuenca endorreica. Estos depósitos cubren un total del 23.3% de la superficie de la subcuenca. Se evidencian espesores menores hacia la parte norte y van aumentando hacia la zona sur. En la zona central de la Ciudad de México se reconoció por primera vez un estrato en el interior de la arcilla llamado Capa Dura (CD), y que durante muchos años ha servido para cimentar edificios grandes. Esta capa exhibe una permeabilidad suficiente para funcionar como acuífero. Los espesores reportados pueden variar entre 30 a 300 m.

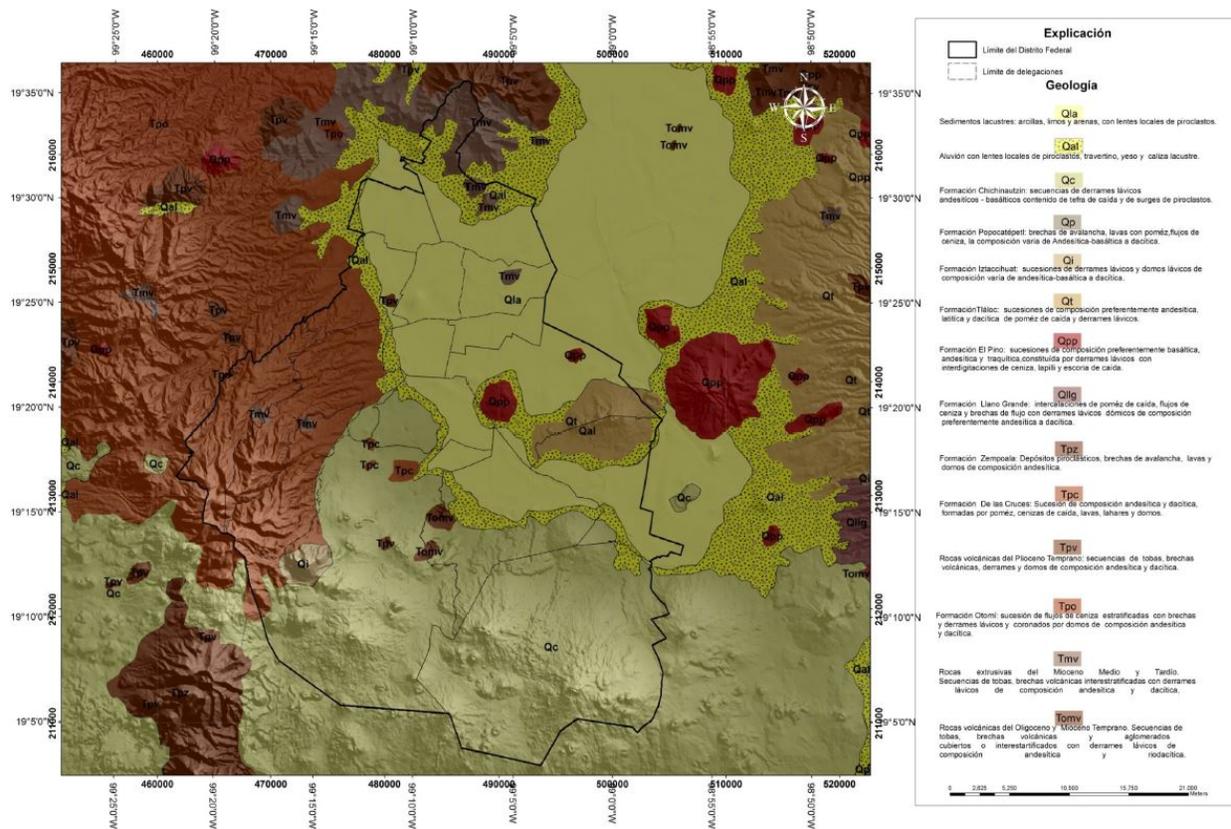


Figura 2-6: Mapa geológico de la zona correspondiente a la ZMVM. Tomado de (Medina, 2016).

## 2.4. Marco hidrogeológico

En el estudio realizado por (Medina, 2016) se hace una recopilación de registros litológicos de pozos, con el fin de catalogar las nuevas categorías litológicas, que en el trabajo se describen, en 4 diferentes hidrofacies. Una hidrofacies se plantea en el estudio como la unión de una o varias litofacies con propiedades hidráulicas similares. Por lo tanto, a cada categoría litológica le asignaron una de las cuatro hidrofacies debido a su conductividad hidráulica estimada y su tipo de porosidad.

### Hidrofacies A

Esta hidrofacies corresponde a la capa de arcillas lacustres que a su vez constituye el acuitarado superior. El espesor varía de 6 a 70 m. Se considera una hidrofacies de baja permeabilidad. Es esta hidrofacies la que se considera tiene la mayor capacidad para comprimirse, y a la que se hará énfasis en este estudio.

### **Hidrofacies B**

Se relaciona con los depósitos aluviales de baja permeabilidad. Consiste en la combinación de rocas con cuatro tamaños: arcilla-arena, conglomerados, arena-arcilla y toba.

### **Hidrofacies C**

Hace parte de las rocas volcánicas del cuaternario. Aunque su origen es ígneo, estos depósitos representan una fuente importante de agua para la ciudad gracias a su alto fracturamiento, lo que permite almacenar y conducir el agua a través de las fisuras. Se compone de Basaltos, Basalto-escoria y escoria con una alta conductividad hidráulica. La hidrofacies C se restringió a la zona cercana al cerro de La Estrella por consideraciones sobre su origen.

### **Hidrofacies D**

Comprende la otra parte de los depósitos aluviales pero que ostentan una alta conductividad. Se compone de arena, grava y arena-grava.

Por otra parte, en la investigación realizada por (Luna, 2014), así como en muchos trabajos en donde se aplican herramientas geofísicas al estudio del agua subterránea en la CDMX, se discriminan varias unidades hidrogeológicas, entre ellas encontramos:

### **Acuitardo superior**

Conformado por el aluvión Cuaternario y depósitos fluviales y lacustres provenientes principalmente del ex lago de Texcoco. Entre las rocas se encuentran intercalaciones de sedimentos arcillosos compresibles y sobresaturados, limos, arenas, lentes pumíticos y escasas gravas.

### **Acuífero granular superior**

Se denomina Unidad Volcánica Superior en medio granular. Lo compone el aluvión Cuaternario, rocas piroclásticas - volcanoclásticas y basaltos andesíticos Plio-Cuaternarios. Es el acuífero explotable más importante en la zona y está relacionado con la Formación Tarango. La recarga al acuífero sucede en las Sierras que encierran la cuenca, sobre todo en la Sierra del Chichinautzin.

### Acuífero inferior fracturado

Este acuífero se compone de rocas andesíticas del Mioceno Superior y basaltos y riolitas que pertenecen a un evento volcánico del Oligoceno Superior, que sucede en zonas separadas. También hacen parte depósitos lacustres del Plioceno Inferior que consisten en arcillas y limos, tobas, brechas y aglomerados.

### Basamento hidrogeológico calcáreo

Unidad calcárea conformada por depósitos marinos de las Formaciones Morelos y Cuautla. Su composición consta de calizas masivas, plegadas y fracturadas, areniscas y en menor medida, de lutitas. Se establece como el basamento impermeable del acuífero, aunque se percibe la existencia de un acuífero en esta unidad, que puede provenir de la karstificación de la roca calcárea.

Los dos tipos de unidades hidrogeológicas mencionados, uno que se desprende del análisis geofísico del sistema, y el otro al establecimiento de una serie de hidrofacies, junto con la clasificación en unidades litológicas, es diagramado con el fin de entender sus correlaciones.

Hidrofacies		Unidades geofísicas	
Nombre	Descripción	Nombre	Descripción
A	Arcillas lacustres que constituyen el acuitardo superior	Acuitardo superior	Conformado por aluvión cuaternario y depósitos fluviales y lacustres.
B	Sedimentos considerados como los depósitos aluviales	Acuífero granular superior	aluvión cuaternario, rocas piroclásticas - volcánicas y basaltos andesíticos.
C	Basalto, basalto escoria y escoria. Hidrofacies de alta conductividad hidráulica	Acuífero inferior fracturado	Rocas andesíticas y basaltos y riolitas fracturadas, así como depósitos lacustres del Plioceno Inferior
D	Arena, grava y arena-grava. Son los depósitos aluviales de alta conductividad	Basamento hidrogeológico	Depósitos marinos que consisten en calizas masivas, plegadas, fracturadas y afalladas.

Figura 2-7: Relación entre las unidades hidrogeológicas usando herramientas geofísicas e hidrofacies, junto con la descripción correspondiente a la unidad litológica a la que pertenecen.

## 2.5. Información geotécnica

Durante la investigación realizada por (Marshal & Mazari, 1959) sobre la distribución de los materiales del subsuelo y sus propiedades mecánicas en la CDMX, se propuso una clasificación estratigráfica del subsuelo en varios niveles, que varios autores después de ellos han incluido en sus trabajos. Las divisiones propuestas son las siguientes:

**Manto Superficial (MS):** Constituido por restos de construcciones, rellenos arqueológicos y depósitos aluviales, con lentes de material eólico intercalados (Juárez, 2015). Su espesor varía según el sector, en algunos lugares incluso puede desaparecer; su valor máximo es cercano a los 10 m.

**Formación Arcilla Superior (FAS):** Contiene arcillas de origen lacustre, preconsolidadas o normalmente consolidadas debido a la sobrecarga superficial y al bombeo profundo. Se presentan intercalaciones de materiales endurecidos por secado solar y lentes de arena y vidrio volcánico (Juárez, 2015).

**Capa Dura (CD):** Formada por limos arenosos cementados con poca arcilla y, en ocasiones gravas. En las orillas del ex lago tiende a aumentar el espesor de esta capa, mientras en su centro disminuye apreciablemente a valor por debajo de un metro de espesor, hasta prácticamente, desaparecer. Su composición es muy heterogénea (Juárez, 2015).

**Formación Arcilla Inferior (FAI):** Arcillas de origen lacustre intercaladas con lentes duros, que se encuentra debajo de la CD. Su espesor es menor que el de la FAS. En el centro del ex lago se encuentran sus mayores valores de espesor, por el orden de los 15 m, y en los extremos, periferia en contacto con los cerros, su valor desaparece (Juárez, 2015).

**Depósitos Profundos (DP):** Formados por arenas y gravas limosas de origen aluvial contenidas dentro de una matriz arcillosa (Juárez, 2015); se pueden encontrar carbonatos de calcio como matriz de estas rocas, variando su grado de cementación.

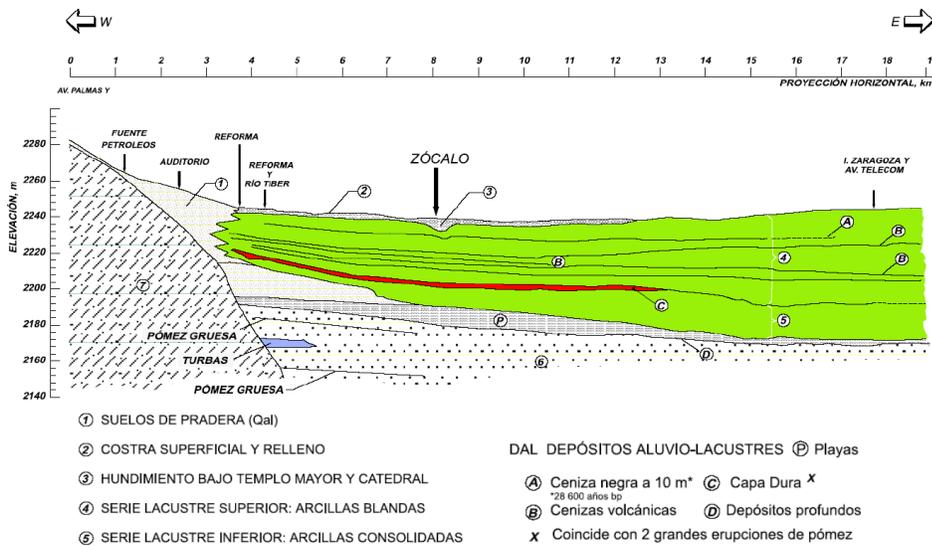


Figura 2-8: Corte que representa la secuencia estratigráfica propuesta por Marsal y Mazari. Tomado de (Juárez, 2015).

En el trabajo previo al de Marsal y Mazari (Marsal, 1952) se realizó un primer mapa representando la zonificación geotécnica de la CDMX, término que se refiere a la separación de la zona de estudio en subregiones con comportamientos de las propiedades del subsuelo semejantes. Su propuesta abarcaba 4 regiones.

**La zona A:** Son terrenos limo-arenosos compactos, conglomerados y derrames basálticos, en el sur de la CDMX (Juárez, 2015).

**La zona B:** Rocas de transición entre la zona A y el ex lago de Texcoco. Se evidencian mantos de arcilla en la parte superficial y debajo se presentan depósitos de aluvión gruesos y compactos (Juárez, 2015).

**La zona C y D:** Formadas por estratos arcillosos muy compresibles. La diferencia entre las zonas se debe al efecto de las cargas superficiales y a las perturbaciones influidas por el bombeo en los acuíferos profundos (Juárez, 2015)

Sin embargo, las propiedades del subsuelo tienden a cambiar a raíz de fenómenos naturales o por acción del hombre, sumado a que con el tiempo se acrecen nuestros conocimientos del terreno conforme se cuenta con más información (Juárez, 2015), es por ello, que varios trabajos posteriores han hecho nuevas propuestas al esquema de zonificación geotécnica de la ciudad.

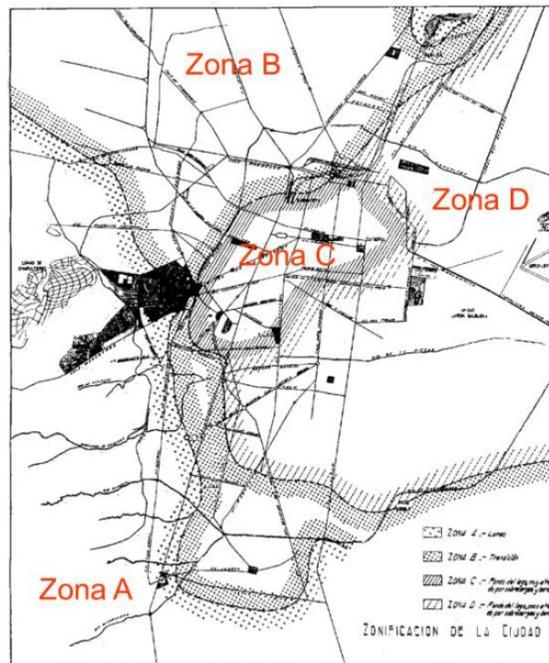


Figura 2-9: Primer modelo de zonificación propuesta para la CDMX hecha por Marsal, 1952. Tomado de (Juárez, 2015)

El primer cambio destacado proviene del trabajo de (Marshall & Mazari, 1959) en donde se proponen solo tres zonas principales:

**Zona de lomas:** Se agrupan principalmente las rocas basálticas y andesíticas de las serranías que limitan la cuenca en sus extremos Norte y Poniente, así como los derrames provenientes del Xitle al SSW (Juárez, 2015). No exhibe espesores de arcillas compresibles y su capacidad de carga es elevada.

**Zona de transición:** Separa la zona de lomas, materiales pétreos, de los depósitos lacustres que pertenecen a la zona de lago. Está compuesta por gravas, arenas y tobas con intercalaciones de capas de arcilla volcánica muy compresible (Juárez, 2015). La razón de esta configuración entre capas gruesas con capas de arcilla compresible se debe a las transgresiones y regresiones que ocurrieron en el ex lago, estos procesos aumentan o disminuyen el nivel del agua, provocando un cambio en la frontera del lago, y facilitando que se depositen momentáneamente capas de arcilla en las zonas transgredidas por el agua.

**Zona de lago:** Situada en la parte más baja de la cuenca y constituida fundamentalmente por capas arcillosas muy compresibles y saturadas. A cierta profundidad también se encuentra la capa dura formada por limos – arenosos compactos. Esta composición, en su mayoría arcillas compresibles, le da la menor resistencia entre todas las zonas (Juárez, 2015).

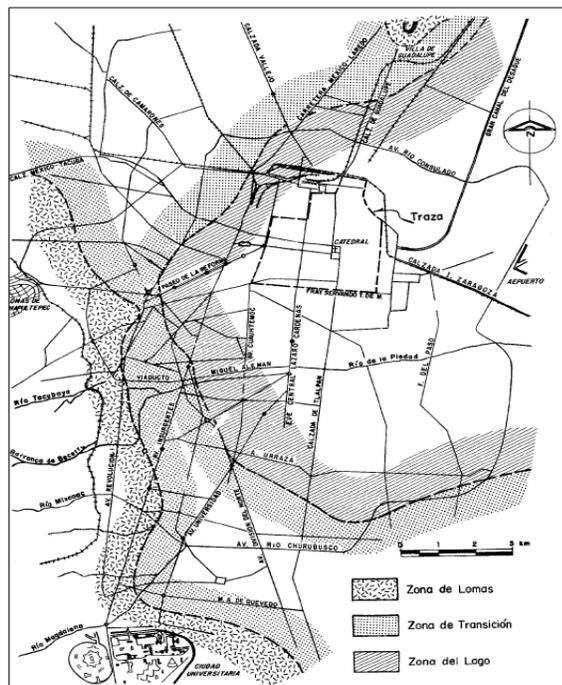


Figura 2-10: Propuesta de zonificación hecha por (Marshall & Mazari, 1959). Tomado de (Juárez, 2015).

## APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Tiempo después se producen algunas otras propuestas como la generada por el Reglamento de Construcciones para el Distrito Federal, publicada en 1966; la del reglamento de construcción de 1976; la propuesta hecha por Schmitter en 1968, que propone a partir de información elaborada en la comisión Hidrológica de la Cuenca del Valle de México; la expuesta por Rodolfo del Castillo en 1978 y presentada en el simposio “El subsuelo y la Ingeniería de Cimentaciones en el Valle de México”; la propuesta hecha por el Reglamento de Construcciones de 1987, que se desprendió de los análisis elaborados a causa del sismo de 1985. En 1987 la Comisión de Vialidad y Transporte Urbano (COVIATUR) publicó una propuesta de zonificación diferente a lo que hasta el momento se venía trabajando, añadiendo nuevas subdivisiones a las tres zonas previamente definidas. Esta propuesta recibe gran aceptación al integrar información de la historia geológica, el uso histórico del suelo y las características que en su momento exponía el subsuelo. La división comprende una separación de la zona de transición en zona de Transición Alta y zona de Transición Baja, por su parte, la zona lacustre registra una separación en zona de Lago virgen, Centro I y Centro II. Es este modelo el que se usó en el presente trabajo para guiar las extrapolaciones de algunas variables que no contaron con bases de datos más extendidas.

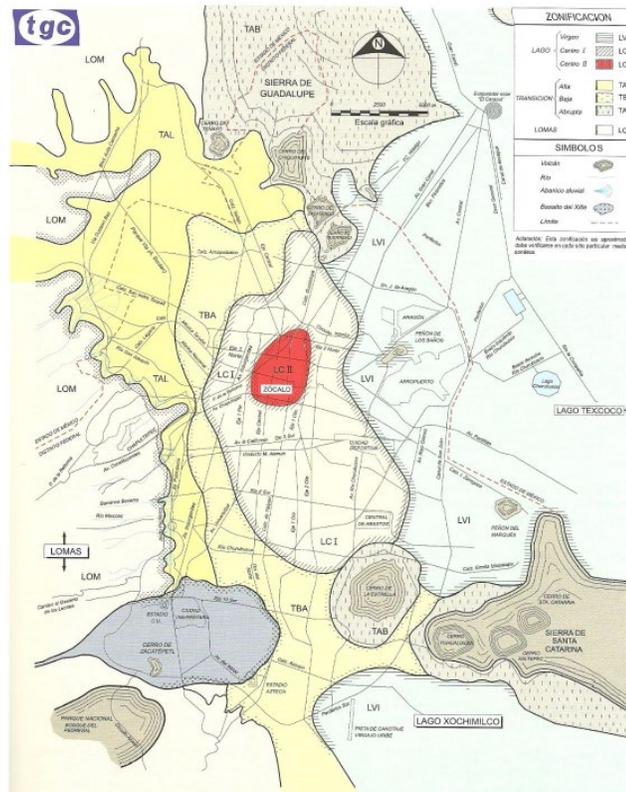


Figura 2-11: Modelo semejante al propuesto por COVIATUR en 1987. Tomado de (Castillo, 2019).

En años posteriores se generaron nuevos mapas de zonificación geotécnica, que retomaron el modelo de tres zonas para fines de sencillez en la reglamentación, entre los nuevos mapas está el propuesto en las Normas Técnicas Complementarias para Diseño y Construcción de Cimentaciones de 1995, y el del Reglamento de Construcciones para el Distrito Federal de 2004, este último mapa es el más reciente encontrado en la literatura consultada (Juárez, 2015).

Por otro lado, la continua extracción de agua de acuíferos en la ciudad de México ha cambiado significativamente el comportamiento del sistema subterráneo. Los niveles del agua han descendido en las últimas décadas a magnitudes tan importantes, que cada vez es necesario perforar pozos mucho más profundos para obtener agua para suministro de la ciudad. Otro problema de la misma dimensión se ha visto reflejado en la relación que existe entre los descensos del nivel del agua y los hundimientos de terreno que experimenta la zona. Los niveles topográficos son monitoreados por la red de bancos distribuidos por la CDMX y algunos otros en el Estado de México. Con esta información o con datos satelitales de INSAR es posible construir mapas que muestran la magnitud de la velocidad de los hundimientos que afectan a la región.

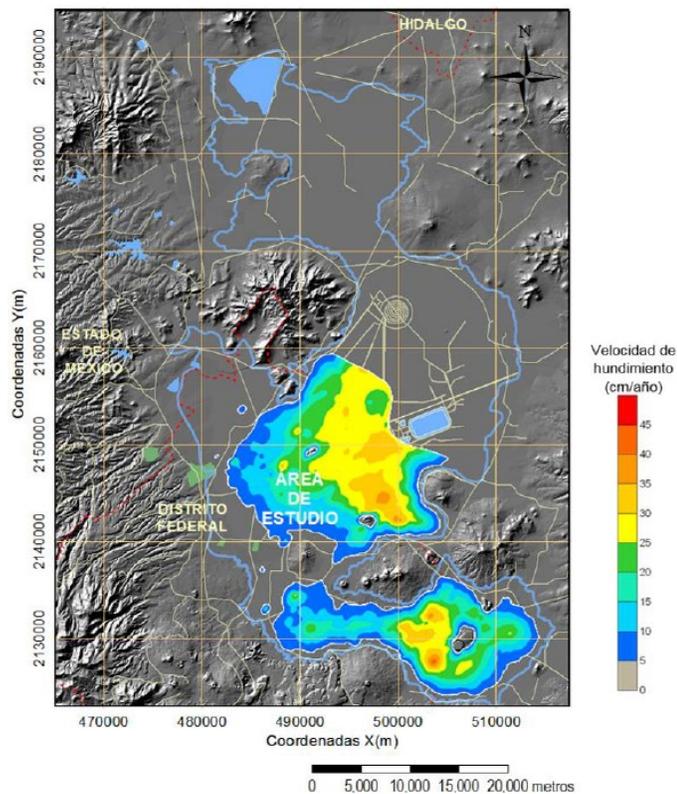


Figura 2-12: Velocidad de hundimiento entre 2000 y 2005 usando la red de bancos. Tomado de (Juárez, 2015)

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

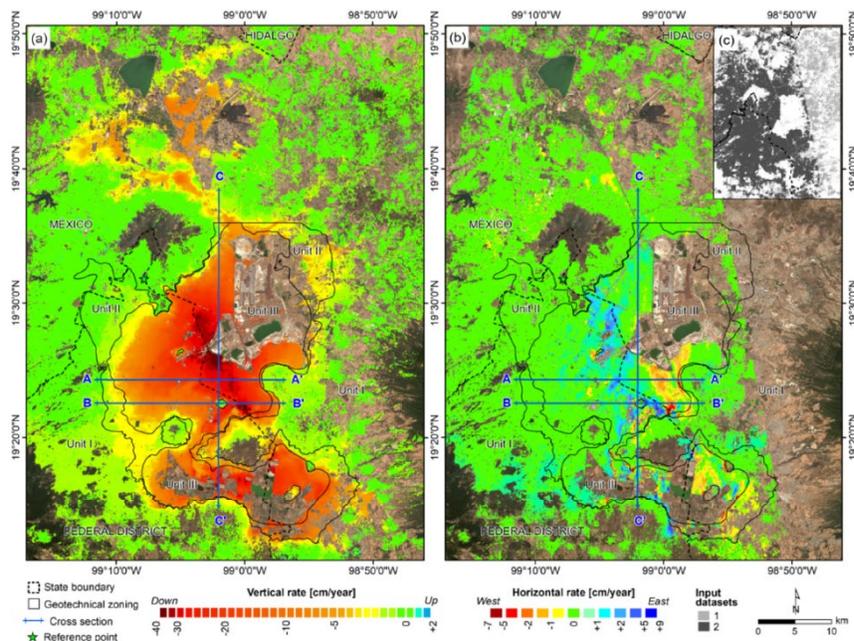


Figura 2-13: Velocidad de hundimiento vertical (a la izquierda) y velocidad de desplazamiento horizontal (a la derecha) entre 2017 y 2019 usando INSAR. Tomado de (Cigna & Tapete, 2021)

Con cualquiera de las dos fuentes de información se puede observar cómo las velocidades anuales de hundimiento alcanzan valores sustanciales en algunas partes de la cuenca, siendo mucho más grandes a medida que se aleja de los límites con las serranías.

### 3. METODOLOGÍA

Para el desarrollo de este trabajo, y con base en la metodología inicial planteada por (Smith & Majumdar, 2020), y convertida en un proceso iterativo, los pasos a considerar son los siguientes:

- I. **Recolección de datos:** En la primera etapa es necesario recolectar datos, a la escala más precisa posible, sobre el nivel piezométrico del agua en el acuífero superior en la mayor cantidad de años que se tenga registro, con dicha información es posible determinar el abatimiento puntual en cada posición del dominio de trabajo; también es necesario configurar una base de datos sobre espesores de la hidrofacies A, zona que bajo nuestra hipótesis manifiesta el comportamiento más compresivo de sus sedimentos, o en su defecto, información de los espesores del acuitardo superior; adicional, se requiere una base de datos, con alta densidad de mediciones, que permita identificar la carga de preconsolidación y el coeficiente de compresibilidad de las rocas que forman el acuitardo superior del sistema. Finalmente, para calibrar los modelos y que consigan predecir el hundimiento esperado, se requiere de una base de datos, distribuida espacialmente, para la primera etapa, que proporcione el valor del hundimiento medido con una alta fidelidad, las opciones posibles son, usar información calibrada por medio de imágenes satelitales y procesadas bajo la técnica InSAR o emplear los registros de los bancos de nivel con los que cuenta la ciudad desde 1983. La fuente escogida fue InSAR para esta primera parte. La segunda etapa de este proceso iterativo requirió la incorporación de nuevos conjuntos de datos de información para reemplazar algunos predictores que se tuvieron en cuenta en la primera etapa, pero que, por su baja precisión y alto grado de incertidumbre en ciertas zonas, afectaron el desempeño de los modelos calibrados. La primera base de datos que se incorpora es el índice de compresión para cada una de las capas conocidas como Arcilla Superior, Capa Dura y Arcilla Inferior, junto con sus respectivos espesores, para sustituir al coeficiente de compresibilidad de estas capas, trabajado como recurso básico en la primera fase. El segundo cambio proviene de suplir la baja confiabilidad en el conjunto de datos de carga de preconsolidación, por una serie de variables que, aunque no proveen toda la información contenida en la carga de preconsolidación, si están

fuertemente ligadas a esta propiedad, funcionando como un buen estimador de su comportamiento. Las variables consideradas fueron, la cantidad de viviendas, el número de personas, el tamaño de las zonas verdes, la intensidad de la lluvia por año y la suma de infraestructura para negocios y de servicio, conocidas como unidades económicas; todas estas características son estimadas por localidad. Una cualidad adicional que se tuvo en cuenta fue el caudal de extracción de los pozos que mantiene la ciudad, sin embargo, se trabajó como un dato puntual, y no uno distribuido por localidad como los anteriores. La limitación de tomar el caudal como un dato puntual, puede afectar ampliamente el peso que tenga esta propiedad en el modelo, no obstante, añadirle un radio de afectación a cada pozo agrega más complejidad al estudio, por lo que se requeriría de más tiempo del que se dispone para concluir esta investigación. El último cambio de la fase dos, parte de tomar los datos de hundimiento para calibrar las predicciones de los registros de bancos de niveles de la ciudad, y no del promedio de la tasa de hundimiento de los últimos años compartidos por (Fernández, y otros, 2022) que usa la técnica InSAR.

Tabla 3-1: Descripción de las variables usadas y su relación con su respectiva propiedad física del sistema, la fuente que la suministró y su escala.

DATOS USADOS EN EL MODELO				
Variante	Variable física que aproxima	Tipo	Fuente	Resolución
Espesor sedimento	Espesor sedimento	Predictor	Medina(2016) , Espriu (2021)	100 m
Coficiente de compresibilidad o Índice de compresión (a partir del contenido de agua)	Compresibilidad del sedimento	Predictor	Marsal et al. (1969), Geotest (2021), Juárez (2015), Resendiz et al. (1970)	Datos en puntos dispersos
Litología	Compresibilidad del sedimento	Predictor	Vazquez et al. (1989)	1:100000
Carga de preconsolidación	Carga de preconsolidación	Predictor	Marsal et al. (1969)	Datos en puntos dispersos
Unidades económicas, viviendas, población, áreas verdes, intensidad de lluvia, caudal de extracción	Carga de preconsolidación	Predictor	datos.cdmx.gob.mx/data set/	Por localidades
Abatimiento	Abatimiento	Predictor	Herrera (2021)	1000 m
Tasa de hundimiento	Tasa de hundimiento	Predicción	Cabral(2021), SEHEDIS (2021)	80 m. Los otros en puntos dispersos.

- II. **Homogenización de escalas:** Las diferentes fuentes de información consultadas compartieron sus datos en diferentes formatos tales como, imágenes, informes impresos, archivos planos, informes digitales en formato pdf y de excel, archivos de ArcGIS y páginas web, además de estar a escalas diferentes. Fue necesario extraer todos los datos en un solo formato que, tuviera la capacidad de alimentar los modelos de machine learning que se despliegan mediante un entorno virtual que usa notebooks de Jupyter, el formato escogido fue un solo archivo CSV exportando luego de concentrar toda la información en una base de datos de MySQL. Para obtener todas las propiedades consultadas en los mismos puntos geográficos se recurrió a usar dos escalas, se construyó una base de datos con la escala de 1000 m en todas las medidas, y una base de datos para la escala de 100 m. La técnica usada para hacer coincidir las escalas en los mismos puntos geográficos fue por medio de interpolaciones y extrapolaciones usando un método bilineal, también se recurrió al promediado de valores para reducir la escala en algunos casos. Se seleccionaron estas dos escalas, dado que son las escalas compartidas por la mayoría de las variables, esperando encontrar cuál de las dos produce los mejores resultados, consumiendo la menor cantidad de recursos computacionales.
- III. **Creación y calibración del modelo:** La implementación se llevó a cabo en dos entornos diferentes, para la primera parte se desplegaron los modelos usando el entorno de trabajo que provee Anaconda y que permite la ejecución de código de Python en notebooks de Jupyter. Para la segunda fase, se desplegaron los modelos en Google Colab, un entorno en la nube que proporciona Google y que mantiene la facilidad para trabajar con notebooks de Python, pero sin la necesidad de ejecutarse en los servidores locales, por lo que es posible aumentar los recursos computacionales como la memoria RAM y el disco duro sin tener que adquirir nuevo hardware. En ambos casos se hizo uso de los frameworks Keras y Tensorflow, y de las librerías Pandas, Matplotlib y Numpy para desplegar los modelos bajo el lenguaje Python 3.9. El algoritmo seleccionado es conocido como modelo de regresión en Deep Learning. Estos algoritmos contienen varios hiperparámetros por calibrar, por lo que se debe recurrir no solo al entrenamiento automático del modelo, sino que es necesario un proceso manual e iterativo que varíe los parámetros con el fin de obtener la mejor calibración.

- IV. **Generar y graficar salidas:** Los datos de salida del modelo son entregados como arreglos numéricos en archivos planos. Para hacer un mejor análisis de los resultados, es preciso diseñar rutinas en Python aplicando las funciones de la librería Basemap, para graficar mapas y funciones. Los mapas en la primera etapa son evaluados únicamente de manera espacial, pero para la segunda etapa se examinan algunos alcances temporales también.
- V. **Validación:** Estos algoritmos incorporan varias métricas estadísticas de validación de los resultados, incluso es posible implementar nuevas. Sin embargo, para este trabajo se escogieron métricas de uso común para evaluar el rendimiento del modelo, estas son: las curvas de entrenamiento vs testeo, la gráfica de valores predichos contra medidos, los histogramas de error, y las tablas con los valores de error cuadrático medio, error absoluto medio y R2. También se grafican los diagramas de dependencia para valorar el peso que cada variable tiene sobre el modelo.

La metodología se sintetiza en el diagrama de la Figura 3-1.

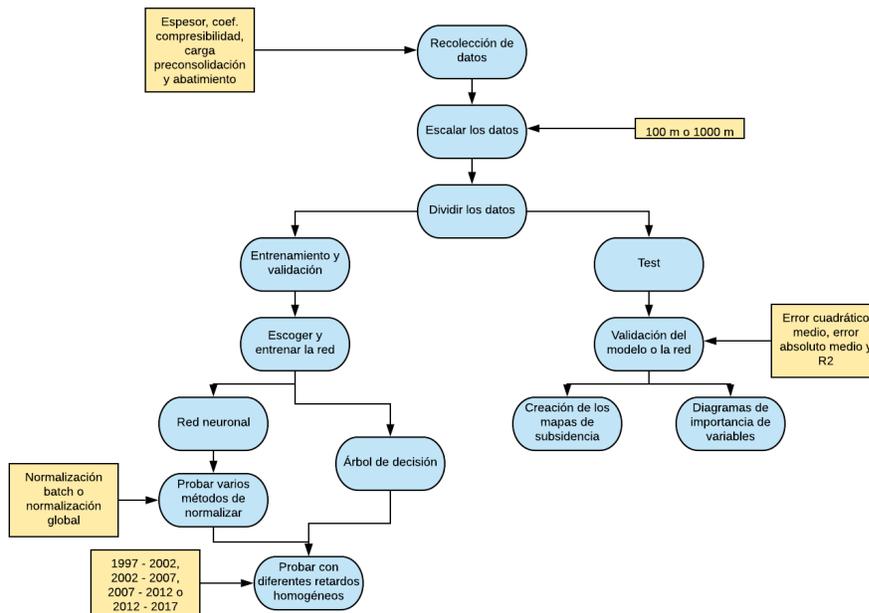


Figura 3-1: Pasos seguidos en la investigación. Desde dividir los datos es un proceso iterativo, también lo es el diagrama como un todo, aunque por el tiempo que conlleva, solo se llevaron a cabo dos ciclos.

## 4. MARCO TEÓRICO

### 4.1. Teoría de la consolidación

El esfuerzo dentro de un material refleja la distribución de fuerzas internas generadas en respuesta a las cargas aplicadas, este material puede ser una roca o suelo. El análisis en tres dimensiones del esfuerzo requiere el conocimiento de las nueve componentes de un tensor de orden 2, conocido como  $\bar{\sigma}$ . Cada componente representa esfuerzos normales o tangenciales en las diferentes direcciones del espacio. Existe una relación constitutiva entre el esfuerzo total, el esfuerzo efectivo y la presión de poro (Duque & Escobar, 2016).

$$\bar{\sigma}_e = \bar{\sigma} - p \bar{I}$$

*Ecuación: 1*

El esfuerzo efectivo  $\bar{\sigma}_e$  se calcula como la diferencia entre el esfuerzo total y la presión de poro  $p$ , y representa el esfuerzo que contribuye verdaderamente a la resistencia y deformación del material. Es responsable de la transferencia de carga a través de los granos del material. La presión de poro es la presión ejercida por un fluido, como el agua, en los poros del material, ya sea suelo o roca. Esta presión puede ser positiva o negativa dependiendo de si el fluido está bajo una presión mayor o menor que la atmosférica. La presión de poro actúa en todas las direcciones y puede debilitar la resistencia del material al reducir el esfuerzo efectivo (Camacho & Garzón, 2014).

En hidrogeología, es común analizar el fenómeno en una sola dirección, generalmente la vertical, lo que reduce la ecuación a una relación escalar (Fregosa, 2012).

$$\sigma_e = \sigma - p$$

*Ecuación: 2*

El estudio de los esfuerzos es crucial para comprender el comportamiento de las deformaciones que puede experimentar un material poroso. Para calcular la deformación, es necesario comprender una serie de propiedades intrínsecas del suelo, entre las que destaca el coeficiente de compresibilidad  $a_v$ . Este coeficiente representa la tasa de cambio de la relación de vacíos  $e$  con respecto al esfuerzo efectivo aplicado, si solo consideramos el comportamiento en una dimensión (Ossa, 2004).

$$a_v = \frac{de}{d\sigma_e}$$

Ecuación: 3

Vale la pena recordar que la relación de vacíos  $e$  denota el volumen de vacíos en el medio poroso en relación con el volumen ocupado por los sólidos.

En el laboratorio, se llevan a cabo una serie de pruebas conocidas como pruebas de consolidación uniaxial o pruebas odométricas para medir el desplazamiento vertical de una muestra saturada de agua sometida a una carga vertical que se incrementa gradualmente en el tiempo. Estas pruebas registran la deformación en función del tiempo, así como la relación de vacíos y la carga aplicada (Giraldo Sierra, 1996).

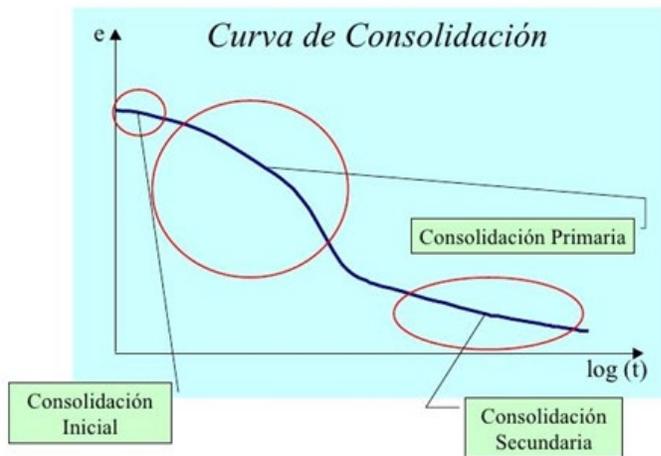


Figura 4-1: características de la curva de consolidación. La curva se construye mediante las pruebas odométricas y muestra la relación entre tiempo y la consolidación o asentamiento del suelo. Tomado de (Calvo & Durán, 2013)

Cada curva de deformación-tiempo, conocida como curva de consolidación, permite calcular un punto en la curva de relación de vacíos-carga, conocida como curva de compresibilidad. A partir de la construcción completa de esta última curva, se obtiene una propiedad conocida como el índice de compresión  $C_c$ . Esta propiedad también se puede obtener a partir de la relación de vacíos y el esfuerzo efectivo, pero en una escala semilogarítmica. El valor del índice de compresión representa una medida adimensional (López, 2002).

$$C_c = \frac{\Delta e}{\Delta \log_{10}(\sigma_e)}$$

Ecuación: 4

Gráficamente, el índice de compresión se obtiene como la pendiente de la porción recta de la curva de compresibilidad, conocida como curva virgen. Sin embargo, el valor obtenido en el laboratorio puede tener una ligera variación en comparación con el valor real en el terreno debido al remoldeo que la muestra experimenta durante la exploración de campo, o debido al método y la forma de realizar las pruebas en el laboratorio, lo cual puede influir en la curva de compresibilidad resultante.

El índice de compresión se utiliza para estimar el valor del coeficiente de compresibilidad mediante la relación entre estas dos propiedades:

$$C_c = 2.303 * \sigma_e * a_v$$

Ecuación: 5

Sin embargo, el índice de compresión no exhibe un único comportamiento. Por el contrario, tiene un valor correspondiente a la etapa de deformación virgen y otro valor correspondiente a la etapa de recompresión o rebote, conocido como índice de expansión  $C_s$ .

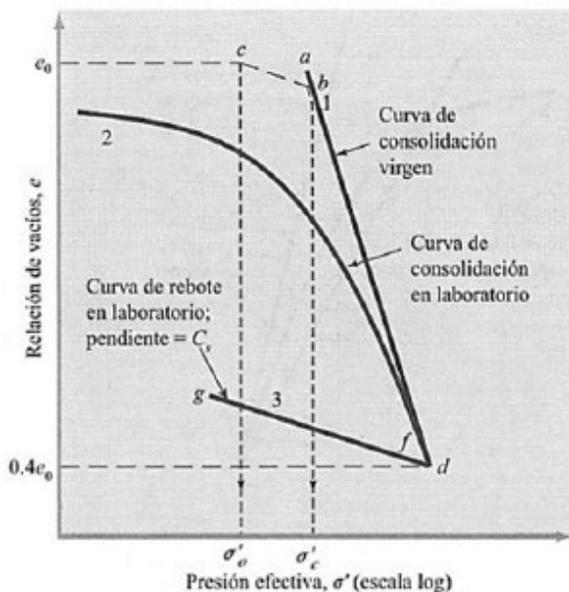


Figura 4-2: Curva de compresibilidad, muestra la curva de consolidación virgen que corresponde a la deformación virgen y la curva de rebote que corresponde a la etapa de recompresión. Tomado de (Muñoz, Sánchez, & García, 2020)

Por lo tanto, se observa que la forma de la curva de compresibilidad varía según el tipo de consolidación presente en la roca. Puede variar desde la consolidación inicial, que está influenciada por la carga máxima previa a la cual se sometió la roca, conocida como carga de preconsolidación, hasta la consolidación primaria, que implica una reducción en el volumen de la muestra debido a la aplicación de una carga permanente, lo que expulsa el agua de los vacíos y transfiere más carga a las partículas sólidas de la muestra. Finalmente, se encuentra la consolidación secundaria, que ocurre después de la consolidación primaria y está relacionada con cambios internos en la estructura de la muestra bajo una tensión efectiva constante (Ossa, 2004).

La carga de preconsolidación es un parámetro que indica el esfuerzo máximo que el suelo ha soportado a lo largo de su historia geológica. En la curva de compresibilidad, este valor se encuentra cerca del punto de máxima curvatura y precede al inicio de la consolidación primaria, que se representa mediante la curva virgen o curva K (Alanis, 2003). La carga de preconsolidación puede verse afectada por el desarrollo de nuevas construcciones y por la extracción constante de agua subterránea en un área determinada. Además, el valor obtenido en el laboratorio puede estar influenciado por la velocidad a la que se realizan los análisis (Ovando E. , 2021). Por lo tanto, se recomienda utilizar una metodología de medición consistente en todas las muestras recopiladas para estudios regionales, a fin de minimizar la incertidumbre en los resultados. En caso de no cumplirse estas condiciones, puede ser necesario trabajar con variables relacionadas con la carga de preconsolidación que sean más fácilmente medibles y que existan catálogos actualizados de sus valores para toda el área de estudio.

La caracterización del índice de compresión en cada ubicación requiere un tiempo considerable, especialmente en estudios regionales que implican analizar un gran número de muestras. Por esta razón, a menudo se recurre a relaciones empíricas que permiten estimar el valor del índice de compresión a partir de otras propiedades, como el contenido de agua, el límite líquido, la relación de vacíos, entre otros. Estas relaciones empíricas se desarrollan específicamente para cada zona, considerando el tipo de roca que conforma la cuenca estudiada (Ovando S. , 2021).

En el caso de la Ciudad de México, se han realizado investigaciones que exploran la relación del índice de compresión con otras variables (Ovando E. , 2011) y que permiten obtener relaciones empíricas del índice de compresión para las arcillas de la Ciudad de México (Ayala, 2013).

Algunos estudios también analizan las variaciones temporales del índice de compresión. Por ejemplo, en el trabajo titulado "Some geotechnical properties to characterise Mexico City Clay" del Dr. Ovando, se analiza la curva de compresibilidad de una muestra en la misma ubicación para tres años diferentes, observando que el valor de la pendiente de la curva virgen es muy similar en todos los casos.

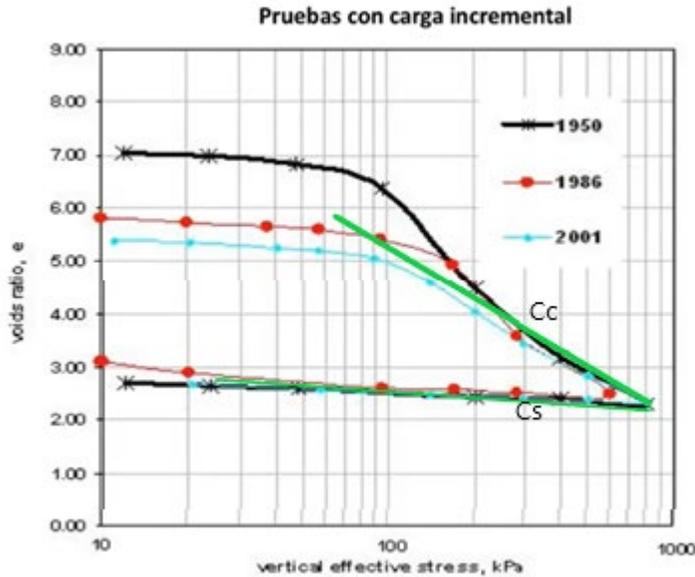


Figura 4-3: Curvas de compresibilidad para una misma ubicación medidas en tres años diferentes. Modificado de (Ovando E. , 2021)

En trabajos posteriores como el de (Mánica, Ovando, Botero, Gens, & Vaunat, 2021) se registran curvas de compresibilidad en la Ciudad de México para años más recientes en las que es posible inferir que aún las rocas de la zona presentan consolidación primaria, de esta manera, sería posible usar los valores del índice de compresión y las relaciones empíricas propuestas en trabajos citados por esta investigación como insumos para modelos regionales como los generados con redes neuronales.

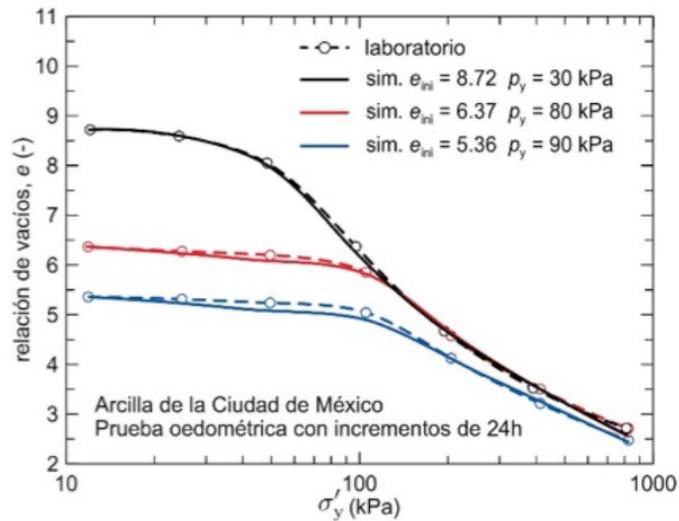


Figura 4-4: Curvas de compresibilidad calculadas en tres locaciones en el Lago de Texcoco en 2013. Tomado de (Mánica, Ovando, Botero, Gens, & Vaunat, 2021)

En el marco de esta investigación, se asumió que el comportamiento de la deformación se puede expresar únicamente mediante el uso del índice de compresión  $\alpha$ , en caso de encontrarse en áreas donde el esfuerzo efectivo se libera, el índice de recompresión. La liberación del esfuerzo efectivo ocurre cuando el nivel freático o piezométrico aumenta o se recupera, siempre y cuando no haya cambios en la carga superficial del terreno. El índice de compresión se utilizará en ubicaciones donde el esfuerzo efectivo excede el esfuerzo de preconsolidación, mientras que en lugares donde el esfuerzo de preconsolidación no es superado, se empleará el índice de recompresión. Entre estos dos diferentes parámetros mencionados, el índice de compresión y la carga de preconsolidación, el segundo variará en cada período de tiempo debido a su continua evolución. Además, esta evolución es irreversible, ya que no es posible volver a valores anteriores. Por otro lado, el índice de compresión puede considerarse constante si se mantiene en la zona de consolidación primaria. El supuesto adoptado en este estudio establece que tanto el sólido del material poroso como el agua son incompresibles, lo que implica que la deformación se debe únicamente a cambios en la estructura del medio. Esto implica omitir la deformación creep, que es la deformación sin cambios en el esfuerzo, y la deformación plástica, que altera la pendiente de las curvas de compresibilidad después de pasar la etapa de consolidación primaria. Este supuesto es ampliamente utilizado en hidrogeología (Narasimhan & Witherspoon, 1977). Basándonos en lo anterior, en este trabajo es posible relacionar los cambios en la deformación directamente con cambios en la porosidad. Asimismo,

el modelo simplificado de deformación utilizado permite considerar exclusivamente el índice de compresión para describir la deformación de la estructura.

#### 4.2. Subsistencia

En el campo de la hidrogeología, es frecuente emplear el parámetro del almacenamiento específico ( $S_s$ ) para caracterizar el comportamiento de un acuífero. El almacenamiento específico se compone de dos elementos: el almacenamiento específico del armazón ( $S_{sk}$ ), que refleja la compresibilidad del sistema sólido del acuífero, y el término  $S_{sw}$ , que representa el almacenamiento específico del líquido presente en el acuífero (Smith & Majumdar, 2020).

$$S_s = S_{sk} + S_{sw}$$

*Ecuación: 6*

A través de la teoría de la consolidación (Narasimhan & Witherspoon, 1977), es posible establecer una relación entre el almacenamiento específico y el coeficiente de compresibilidad. La ecuación general que describe esta relación es la siguiente:

$$S_s = \gamma[\emptyset C_w + (1 - \emptyset)a_v]$$

*Ecuación: 7*

Donde  $\gamma$  es el peso específico del agua,  $C_w$  es la compresibilidad del agua,  $\emptyset$  es la porosidad del medio y  $a_v$  es el coeficiente de compresibilidad. Este coeficiente puede referirse al de la zona virgen o al de recompresión, de acuerdo con la parte de la curva de compresibilidad por la que esté atravesando el proceso de deformación.

La ecuación 6 representa una relación general aplicable a los diferentes tipos de almacenamiento específico, sin importar si la deformación es elástica o inelástica. Esto se debe a que un acuífero confinado permanece saturado incluso si se reduce la cantidad de agua almacenada en él, lo cual se acomoda mediante la expansión del agua almacenada y la compresión del armazón. Los acuíferos con subsidencia significativa presentan un  $S_{sk}$  elevado, lo que permite despreciar el término  $S_{sw}$  en los cálculos. En otras palabras, la compresibilidad del agua puede ser despreciada, resultando en la siguiente expresión:

$$S_s = S_{sk} = \gamma(1 - \emptyset)a_v$$

*Ecuación: 8*

De esta manera, es posible utilizar el coeficiente de compresibilidad, o incluso el índice de compresión dado su vínculo, para formular ecuaciones de deformación que se refieran al almacenamiento específico.

La subsidencia es ocasionada por la disminución de la presión de poro en los sedimentos que conforman un acuífero debido al bombeo del agua que contienen. Esta reducción de presión incrementa el esfuerzo efectivo en la roca, lo que conlleva a la consolidación del sedimento (Smith & Majumdar, 2020). Las rocas compuestas principalmente por arcillas son las más susceptibles a este proceso de consolidación, mientras que las arenas son mucho más resistentes, y los granitos o las calizas prácticamente no experimentan cambios significativos al extraer el agua que contienen. El almacenamiento específico del armazón ( $S_{sk}$ ) es la propiedad que describe la compresibilidad en cada capa de roca y se define de la siguiente manera:

$$S_{sk} = \frac{\Delta b}{\Delta h * b_o}$$

*Ecuación: 9*

Donde  $h$  representa la carga hidráulica, que es una medida de la altura del nivel freático o nivel piezométrico en cada posición del acuífero.  $\Delta h$ , por su parte, indica el cambio en la carga hidráulica después de una perturbación, medido sobre un mismo punto y en un intervalo de tiempo determinado.  $b_o$  es el espesor de la capa y  $\Delta b$  es el cambio experimentado por el espesor debido a la consolidación. A medida que el valor de  $S_{sk}$  es mayor, la capa es más compresible (Smith & Majumdar, 2020).

El proceso de compactación puede ser elástico, es decir, reversible, si la carga hidráulica no disminuye por debajo del valor de la carga de preconsolidación histórica, que indica la máxima presión aplicada previamente a la roca. Una vez alcanzado este valor, la roca no recupera su espesor original debido al colapso de los espacios de poro. Los valores de  $S_{sk}$  son varios órdenes de magnitud más pequeños durante una compactación elástica que durante una compactación inelástica. Para distinguirlos, se utiliza  $S_{ske}$  para la compactación elástica y  $S_{skv}$  para la compactación inelástica, también conocida como compactación virgen. Al reescribir la ecuación 9, se obtiene la función básica que describe el proceso de subsidencia:

$$\Delta b = \Delta h * S_{sk} * b_o$$

*Ecuación: 10*

Es posible utilizar el fenómeno de subsidencia para estimar los cambios en el almacenamiento de agua en un acuífero. Los acuíferos semiconfinados o confinados experimentan una consolidación más significativa,

ya que la deformación se relaciona de manera lineal con los cambios en la carga hidráulica. Estos acuíferos experimentan cambios en la carga hidráulica que son varios órdenes de magnitud superiores a los observados en acuíferos no confinados (Smith & Majumdar, 2020). Si se realiza una simplificación considerando un acuífero confinado compuesto únicamente de arcillas y arenas, se puede describir la función que relaciona los cambios en el volumen de agua almacenada en el acuífero por unidad de área ( $\Delta S$ ) con los cambios en la carga hidráulica:

$$\Delta S = \Delta h * S_s * b_o$$

*Ecuación: 11*

Como ya se mencionó previamente, los acuíferos con valores de subsidencia importantes tienen un  $S_{sk}$  elevado, por lo que el  $S_{sw}$  se puede despreciar de los cálculos. Bajo este supuesto, y combinando las ecuaciones 8, 10 y 11, se concluye que:

$$\Delta S = \Delta b$$

*Ecuación: 12*

Existe un período de retardo durante el cual no se observan cambios significativos en el espesor de la capa después de reducir el almacenamiento de agua en el acuífero. Esta situación se debe a las diferencias en los materiales de roca y su velocidad de transmisión del agua. Durante el bombeo, las arenas liberan el agua con mayor rapidez y, al mismo tiempo, son una litología resistente a la consolidación. Posteriormente, el agua comienza a redistribuirse en el sistema, lo que disminuye la presión de poro en las arcillas y genera una consolidación, ya que son materiales vulnerables a este proceso. Los cambios pueden llevar años en estabilizarse, dependiendo del espesor de la capa de arcilla y de su baja permeabilidad.

Al analizar la relación que describe la subsidencia dada por la ecuación 10 se encuentran varias simplificaciones negativas si se emplea en un acuífero con los supuestos de composición y confinamiento definidos por (Smith & Majumdar, 2020). En primer lugar, falta considerar términos temporales, ya que, si bien la ecuación se basa en un análisis físico razonable, el retardo en la propagación de los cambios es un factor importante para predecir con precisión el hundimiento en estratos con abundante presencia de arcillas. En segundo lugar, se considera que todas las capas de arcilla son componentes del acuífero, cuando lo habitual es agrupar los espesores de arcilla superior e inferior como capas separadas que confinan al acuífero, conocido como acuitardo para este caso, debido a sus propiedades hidráulicas

diferentes. Al separar estas capas con comportamientos distintos, es posible obtener una relación muy distinta a la expresada en la ecuación 10, que refleje la interacción entre las capas y no solo el comportamiento de una de ellas.

Se han propuesto varias ecuaciones alternativas que incorporan el término temporal para describir la subsidencia. Una ecuación reciente es la función de tiempo de Gompertz, utilizada en la investigación realizada por (Wang, Keming, Wei, Shi, & Yao, 2022):

$$W(t) = w_f * e^{-e^{-k(t-b)}}$$

Ecuación: 13

Donde  $W(t)$  representa el hundimiento instantáneo del punto superficial en el tiempo  $t$ ,  $w_f$  es el hundimiento máximo del punto superficial,  $k$  es el coeficiente de velocidad para alcanzar el estado estabilizado (también conocido como parámetro de forma), que afecta la pendiente de la curva y el tiempo requerido para alcanzar el estado estabilizado, y  $b$  es el momento de máxima velocidad de hundimiento del punto superficial (también conocido como parámetro de posición), que afecta la posición de la curva en el eje de las abscisas (Wang, Keming, Wei, Shi, & Yao, 2022).

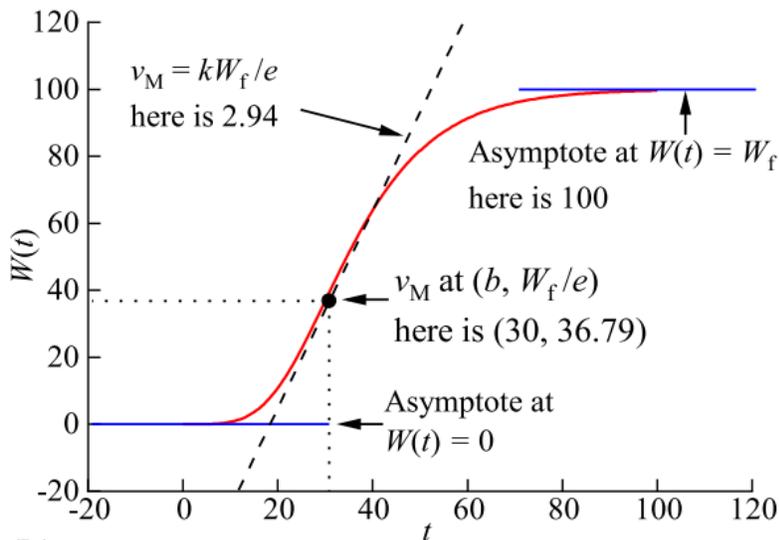


Figura 4-5: Curva de subsidencia en un punto del terreno contra el tiempo. Tomado de (Wang, Keming, Wei, Shi, & Yao, 2022)

La ecuación 13 es una buena opción para modelar subsidencia en la zona de estudio propuesta porque permite capturar la variación espacial al aplicar la ecuación en cada punto del dominio, al mismo tiempo que se consiguen apreciar los cambios temporales. No obstante, se introducen una serie de variables que son difíciles de determinar en todos los puntos del terreno, y que, por su misma complejidad, no se cuenta con bases de datos disponibles para la zona. También será necesario calibrar por medio de métodos estadísticos el valor de  $w_f$  añadiendo incertidumbre y pérdida de precisión en la predicción.

Además, la ecuación 13 no relaciona propiedades medidas en distintas capas, sino que se enfoca exclusivamente en el comportamiento de cada capa. Esto dificulta su aplicación en acuíferos no superficiales, donde se requiere realizar perforaciones profundas y costosos análisis en numerosos puntos del terreno para obtener un conjunto confiable de datos que permita crear un modelo riguroso. Para abordar esta situación, es necesario contar con una relación multicapa que combine algunas propiedades de la capa profunda, las cuales cuenten con bases de datos, junto con otras propiedades más complejas de determinar que provengan de las capas más superficiales, debido a su accesibilidad.

Es posible que existan estudios que hayan deducido ecuaciones con una base física sólida para abordar las limitaciones de las dos relaciones de subsidencia mencionadas anteriormente. Sin embargo, se han desarrollado métodos que brindan flexibilidad para trabajar con características medidas en diferentes capas y para introducir cambios temporales discretizados en los modelos, como los algoritmos de redes neuronales. Una ventaja de estos algoritmos, como se mencionó anteriormente, es su flexibilidad para incorporar variables que afecten el fenómeno, incluso si se miden en capas diferentes. No obstante, la precisión de los resultados estará sujeta a la inclusión de las variables más relevantes que describan la subsidencia en la región. Una desventaja es la pérdida del conocimiento físico del sistema, ya que estos métodos son puramente matemáticos y computacionales, lo que impide obtener una ecuación explícita que explique la subsidencia. Otro inconveniente es que suelen tener una precisión buena pero menor en comparación con los modelos basados en ecuaciones físicas.

A pesar de estas limitaciones, contar con un modelo de redes neuronales proporcionará un método de aplicación sencillo para guiar la toma de decisiones sobre las medidas que se deben adoptar para prevenir daños significativos en el futuro. Además, es un elemento importante en el análisis de la vulnerabilidad por zona, ya que proporciona información sobre la influencia de cada variable en la generación de los hundimientos.

En el contexto de los modelos de subsidencia, es crucial considerar la compresibilidad del sedimento, ya sea a través del coeficiente de compresibilidad o del índice de compresión. Sin embargo, esta variable está influenciada por diversas características de la roca, las cuales están intrínsecamente relacionadas con su determinación. Algunas de estas características son:

- Contenido de agua (W): Indica la proporción entre el peso de la masa de agua y el peso de la masa de suelo, y suele expresarse en forma de porcentaje. En sedimentos saturados de agua y con alta porosidad, es posible obtener valores superiores al 100%.
- Límite líquido (LL): Representa el porcentaje del contenido de humedad que marca la transición entre los estados líquido y plástico de un suelo.
- Límite plástico (PL): Indica el porcentaje del contenido de humedad que delimita la transición entre los estados plástico y semisólido de un suelo.
- Índice de Plasticidad (IP): Se calcula como la diferencia entre el límite líquido y el límite plástico, y refleja el rango de variación del contenido de humedad en el cual el suelo se mantiene plástico.

Para determinar el índice de compresión, se han establecido varias relaciones empíricas que utilizan los valores de W, LL, PL e IP. Por lo tanto, es crucial conocer estos valores (Ayala, 2013). Algunas de las relaciones empíricas más conocidas son las propuestas por Terzaghi y Peck en 1967, Rendón-Herrero en 1983 y Nagaraj y Murty en 1985. Sin embargo, debido al carácter empírico de estas fórmulas, es necesario calibrar expresiones específicas para cada región.

Otra variable importante que debe incorporarse para lograr una predicción precisa es la carga de preconsolidación, ya que proporciona información sobre el máximo esfuerzo al que el terreno ha sido sometido. A pesar de su importancia, no existen bases de datos actualizadas, extensas y disponibles sobre esta variable que se puedan utilizar en el proceso de modelado. Se podría generar el mismo efecto al reemplazar esta propiedad por información de la porosidad y el esfuerzo efectivo aplicado en cada punto del terreno, datos igualmente complejos de obtener para una zona tan amplia. Una alternativa consiste en estudiar los mecanismos que causan la carga de preconsolidación, con el objetivo de identificar características medibles que permitan aproximar su efecto. Algunos de los mecanismos investigados son:

- Cambios en la tensión total debido a la adición o remoción de sobrecargas (Yang, Jia, Liu, & Shan, 2009).

- Cambios en la presión de poro causados por variaciones en el nivel freático, bombeo profundo, flujo en túneles y desecación del suelo debido a la vegetación o el clima (Yang, Jia, Liu, & Shan, 2009).
- Alteraciones en la estructura del suelo debido al envejecimiento, conocido como compresión secundaria (Yang, Jia, Liu, & Shan, 2009).
- Cambios ambientales, como variaciones en el pH, temperatura y concentración de sal, que pueden afectar la carga de preconsolidación (Yang, Jia, Liu, & Shan, 2009).
- Meteorización química, que implica la precipitación, agentes cementantes y el intercambio iónico, entre otros factores (Yang, Jia, Liu, & Shan, 2009).

Es posible relacionar cada uno de estos mecanismos con algunas bases de datos disponibles. Por ejemplo, el primer mecanismo se correlaciona con la cantidad de estructuras, viviendas y negocios, así como con el número de habitantes en un área determinada. El segundo mecanismo se vincula con el caudal de extracción de pozos, el área de zonas verdes y la precipitación. En cuanto a los últimos tres mecanismos, que están relacionados con la edad de las rocas, el pH, temperatura, concentración de sal del agua y la precipitación, se considera que su efecto es menos significativo en el área de estudio, además, dada la dificultad para recolectar conjuntos de datos de estas propiedades, se usarán solo los mecanismos expuestos en las dos primeras descripciones para aproximar el comportamiento de la carga de preconsolidación en el modelo.

### 4.3. Redes neuronales

Una neurona artificial es la unidad básica de trabajo para la construcción de los algoritmos de deep learning más conocidos, uno de ellos, el perceptrón multicapa (Acevedo & Vargas, 2017). El aprendizaje en estos modelos se hace con base en un entrenamiento supervisado, donde se tienen los vectores de entrada  $\bar{x} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_i, \dots, \bar{x}_n)$ , un conjunto de cantidades de cada una de las variables seleccionadas para predecir, por cada coordenada  $i$ -ésima del espacio de trabajo, pero a su vez, se cuenta con el valor de la propiedad a predecir  $\bar{y} = (y_1, \dots, y_i, \dots, y_n)$  en los mismos puntos geográficos en donde se cuenta con vectores de entrada.

El conjunto de datos, en su totalidad, es dividido en dos grupos, entrenamiento y validación. Los porcentajes en los que se hace la separación no son equivalentes, siendo mucho mayor para la etapa de entrenamiento porque es de este conjunto que el algoritmo aprende a reconocer el patrón que siguen los datos. Los porcentajes que se suelen seguir son de 70-80% para el entrenamiento, y de 30-20% para la validación. El suministro de datos de validación se usa al final de cada iteración del entrenamiento para evaluar la calidad de las predicciones, lo que permite ser un referente para saber cuándo parar el proceso de entrenamiento luego de conseguir un resultado aceptable, al mismo tiempo que se comporta como una herramienta visual para controlar el overfitting, término usado para describir a modelos de regresión que pierden su capacidad de predicción al sobre entrenarse. Los datos de validación no son usados completamente para saber en qué momento el ciclo de entrenamiento debe detenerse, una buena parte de ellos, alrededor de la mitad de los datos, es dedicado a comprobar el poder predictivo del algoritmo, en lo que sería un segundo estado de validación, la diferencia es que esta verificación se da luego de encontrar el mejor ajuste para el algoritmo, en comparación con la anterior que requería aplicarse luego de cada etapa de entrenamiento. Ambos pasos de validación son necesarios para evitar el overfitting y garantizar la generalización del patrón de comportamiento descubierto por el algoritmo.

Los algoritmos basados en aprendizaje supervisado abarcan dos tareas fundamentales: clasificación y regresión. En la clasificación los valores predichos son números enteros positivos, variables discretas, y su finalidad es pronosticar la pertenencia o no de un dato de entrada a un grupo o grupos que poseen los mismos patrones, un ejemplo de su funcionalidad es la clasificación de una imagen como un perro o un gato o ninguno de los dos. Por otra parte, en la regresión la salida es cualquier número real, a fin de emular el patrón que sigue cualquier fenómeno no discretizado en la naturaleza, por ejemplo, estimar el precio de una vivienda por medio del comportamiento del sector inmobiliario en la región.

Al unir varias neuronas se estructura una red neuronal artificial, que intenta reproducir el funcionamiento básico de una red neuronal biológica. La neurona está formada por cuatro elementos funcionales: los predictores o receptores, la función sumadora, la función activadora y la predicción o salida.

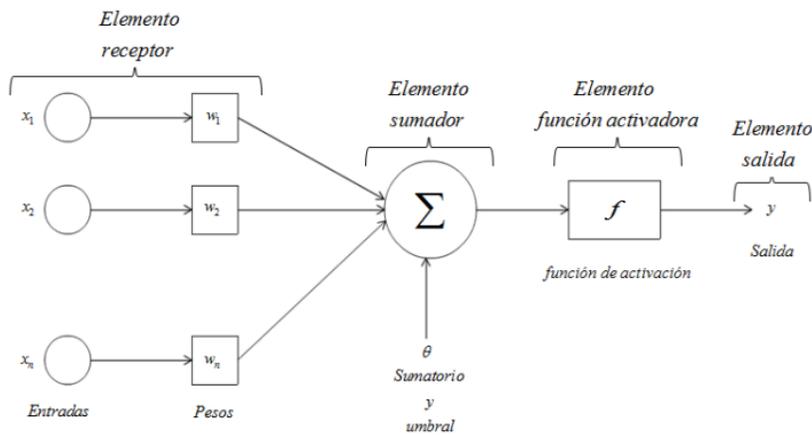


Figura 4-1: Partes que componen una neurona. Tomado de (Acevedo & Vargas, 2017)

La función sumadora es la encargada de efectuar una suma ponderada de cada uno de los valores de entrada. Los pesos introducidos para promediar las entradas son los parámetros que debe variar el proceso de entrenamiento, con el fin de obtener el mejor modelo de predicción.

$$S = \sum_{i=1}^n w_i x_i$$

Ecuación: 14

La función activadora añade la no linealidad al algoritmo evitando o no la activación de la neurona por medio de una función de probabilidad, necesaria a raíz del comportamiento no lineal en la mayoría de los fenómenos cotidianos. La neurona se acciona si al aplicar la función activadora al resultado de la función sumadora se excede un umbral establecido, de lo contrario se interrumpe el paso de la señal.

Función de activación			
	Función	Rango	Gráfica
Escalón	$y = \begin{cases} 1 & \text{Si } x \geq 0 \\ -1 & \text{Si } x < 0 \end{cases}$	[-1, 1]	
Sigmoidal	$y = \frac{1}{1+e^{-x}}$	[0, 1]	
Tangente Hiperbólica	$y = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	[-1, 1]	

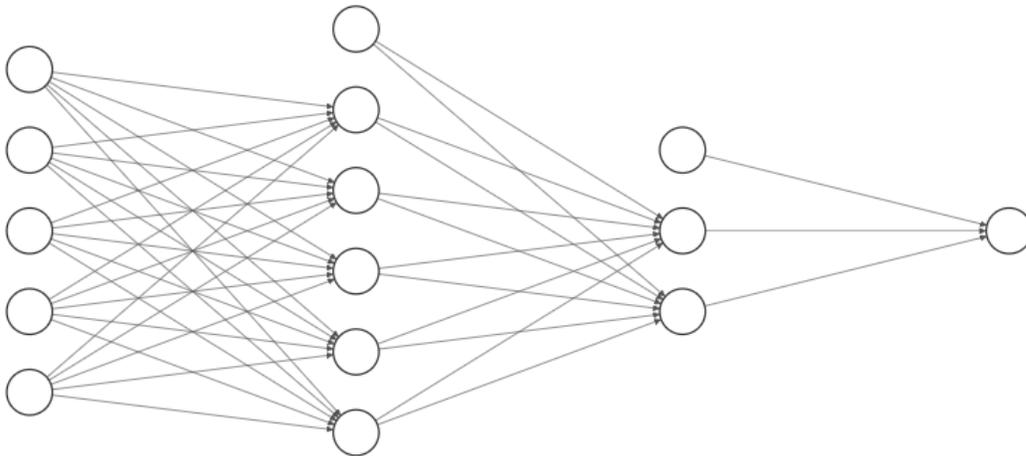
Figura 4-2: Funciones de activación más utilizadas. Tomado de (Acevedo & Vargas, 2017)

La predicción finalmente será el resultado luego de aplicar la función activadora.

$$y = f\left(\sum_{i=1}^n w_i x_i\right)$$

*Ecuación: 15*

Para aumentar el poder predictivo se orchestra una red de neuronas conectadas en lo que se conoce como la arquitectura de la red. Las neuronas se ordenan en un mismo nivel llamado capa, y las diferentes capas pueden conectarse entre sí. La primera capa se le denomina capa de entrada y mantiene una neurona por cada predictor del modelo, la última capa es la capa de salida con una neurona por cada propiedad a predecir, comúnmente se tiene solo una neurona en esta capa, sin embargo, modelos con diferentes aplicaciones pueden requerir más de una salida. Por otro lado, a las capas intermedias se les da el nombre de capas ocultas, pueden contener una cantidad de neuronas arbitrarias, lo mismo que el número de ellas, el valor que se establece para cada una dependerá de la complejidad del fenómeno, de la disponibilidad de recursos computacionales y de la experticia y criterio propio del programador.



*Figura 4-3: Red con 5 neuronas en la capa de entrada, 1 en la capa de salida y 2 capas ocultas de 5 y 2 neuronas respectivamente. Las neuronas no conectadas de las capas ocultas son los sesgos.*

Las conexiones entre neuronas solo suceden de atrás para adelante entre miembros de dos capas contiguas, nunca se establecen en el sentido contrario o entre neuronas de una misma capa.

El algoritmo más sencillo en deep learning es el perceptrón simple, su particularidad es no contar con capas ocultas, además de una sola neurona en su capa de salida. En cuanto a la capa de entrada, no se restringe el valor de neuronas que contenga.

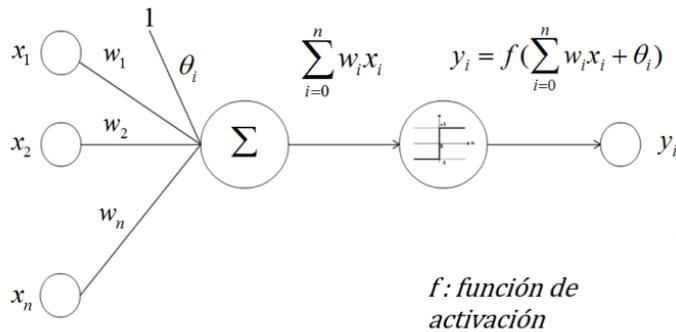


Figura 4-4: Ejemplo de perceptrón simple. Modificado de (Acevedo & Vargas, 2017)

El funcionamiento del perceptrón simple es similar al explicado para una sola neurona, los cambios se presentan en las dos funciones adoptadas. En el caso de la función sumadora, se adiciona un término independiente a la sumatoria que no está promediado por un peso, la cantidad es llamada umbral y se suele denotar por  $\theta$ . Para la función de activación la expresión más utilizada se conoce como Unidad Lineal Rectificada ReLU, su comportamiento es dado por la Ecuación: 16

$$f(x) = \max(0, x)$$

*Ecuación: 16*

Para el entrenamiento del perceptrón, así como para cualquier otro algoritmo de redes neuronales, se sigue el siguiente procedimiento: asignar valores arbitrarios a los pesos y al umbral; ordenar los datos de entrada como un conjunto de arreglos o vectores; calcular salidas iniciales aplicando cada arreglo a cada una de las funciones explicadas en el orden en que aparecen en el perceptrón, a este paso se le conoce como propagación hacia delante; se compara cada salida con su valor esperado, designando una función de costo que agrupe todas las diferencias entre valores reales y predichos; si el resultado no está dentro del rango de error establecido por el programador, se aplica un proceso denominado propagación hacia atrás para calibrar los valores de los pesos y el umbral, con el fin de converger la solución hacia un mínimo de error posible. Todos los pasos entran en un ciclo iterativo hasta que el compendio de errores esté entre la medida de incertidumbre que se fija, o hasta que el proceso de propagación hacia atrás ya no cambie significativamente los valores de los pesos y el umbral, se cae en un mínimo local para el modelo.

La propagación hacia atrás o retropropagación es un método basado en el cálculo de derivadas parciales, que se conduce desde la última neurona hacia la primera capa pasando por todas las capas intermedias. Las derivadas van enfocadas a calcular la dirección de máximo descenso del gradiente, por lo que su resultado es disminuir la diferencia entre la predicción y lo esperado. Para algoritmos con muchas neuronas, estimar las derivadas es un proceso muy dispendioso computacionalmente, razón por la que el método no alcanzó su auge hasta entrado el siglo XXI, aun cuando su origen radica en el siglo pasado.

Si en lugar de tener un perceptrón simple se construye un perceptrón multicapa, se sigue la misma lógica ya explicada.

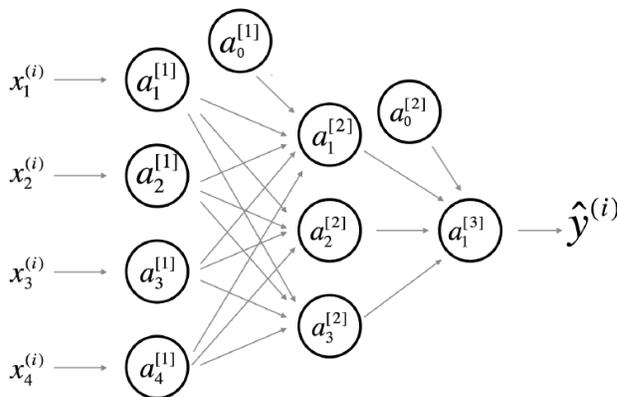


Figura 4-5: Diagrama de un perceptrón multicapa con una capa intermedia. La primera capa (con superíndice 1) recibe una propiedad de entrada en cada neurona, las entradas se denotan con una  $x$ . Las neuronas con subíndice cero son los términos umbral que se añaden en cada capa menos en la última. La capa final es de una sola neurona, entregando el valor de predicción indicado con  $\hat{y}$ .

Cada neurona de las capas intermedias hasta la capa final calcula una cantidad que mezcla funciones lineales y no lineales, la primera parte de este computo se produce al emplear la función sumadora sobre los valores de las neuronas de la capa inmediatamente anterior y unos pesos que corresponden a las relaciones de dicha capa con la neurona que conmuta la cantidad, enseguida, se inserta el resultado en una de las funciones de activación antes mencionadas. No es necesario que todas las neuronas de cada capa utilicen la misma función de activación, aun cuando es lo más usual. El producto de todo este proceso en cada neurona es denotado por una letra  $a$ , junto con un superíndice que indica la capa a la que pertenece y un subíndice para marcar el número de neurona dentro de la capa.

$$a_j^{[i]} = f(\bar{W}^{[ij]} \cdot \bar{a}^{[i-1]})$$

Las cantidades de las propiedades de entrada no son indexadas a las neuronas de la primera capa de manera directa, se emplea un método de normalización que facilita el proceso de convergencia, disminuye la cantidad de iteraciones en el algoritmo de entrenamiento y evita el desvanecimiento o explosión del gradiente, nombre dispuesto en algoritmos de machine learning para referirse al cómputo de gradientes que producen valores muy bajos o muy alto, difíciles de almacenar con precisión en espacios de memoria de computador.

Las técnicas de normalización son muy variadas y existen de diferentes tipos, las más comunes son la normalización por capa, layer normalization, y la normalización por lotes, batch normalization.

La normalización por capa calcula la media y la desviación estándar de los datos de cada predictor, luego resta a cada miembro del conjunto de datos su media y lo divide por su desviación estándar. En esencia, esta normalización lleva todas las medidas a una media cero y varianza unitaria. Es aplicable únicamente una vez al proceso del entrenamiento en la primera capa, produciendo buenos resultados por su simplicidad en algoritmos de redes neuronales recurrentes RNNs (Lei, Ryan, & Hinton, 2016).

Por su parte, la normalización por lotes solo calcula la media y la varianza sobre un subgrupo del conjunto de datos de entrenamiento. La razón radica en la forma de entrenamiento de los algoritmos más eficientes de redes neuronales, en ellos, el conjunto de datos entero de entrenamiento no es consumido en cada iteración del proceso, por el contrario, se toma una muestra aleatoria de menor tamaño en cada paso, reduciendo el tiempo de procesamiento aun cuando se pueda requerir un mayor número de iteraciones, además de prevenir problemas asociados a una media cero y una varianza unitaria. El cálculo funciona de la misma manera, se sustrae la media de cada medida del lote y se les divide por su desviación estándar, la diferencia es que se requiere hacer este paso en cada iteración en vista de que cada vez será un diferente subgrupo el que se seleccionará. Una ventaja adicional es poder aplicar la normalización a capas intermedias también, en busca de alcanzar una convergencia en un menor número de ciclos. Su desventaja es producto del nuevo grupo de parámetros que demandan calibración, el tamaño del lote y los parámetros aprendibles beta y gamma, que garantizan llegar a una convergencia y no quedar orbitando alrededor de ella (Sun, Cao, Liang, Chen, & Li, 2020).

Para conocer qué tanto entrenamiento le hace falta al modelo, o en su lugar, si estamos frente a problemas de sobreajuste, se recurre a las curvas de entrenamiento y validación. Los errores calculados en los conjuntos de datos de entrenamiento y validación se pueden graficar luego de cada época o iteración

adoptando diferentes funciones de medida, entre las más destacadas están el error cuadrático medio, el error absoluto medio, la precisión, la tasa de aciertos y el R cuadrado.

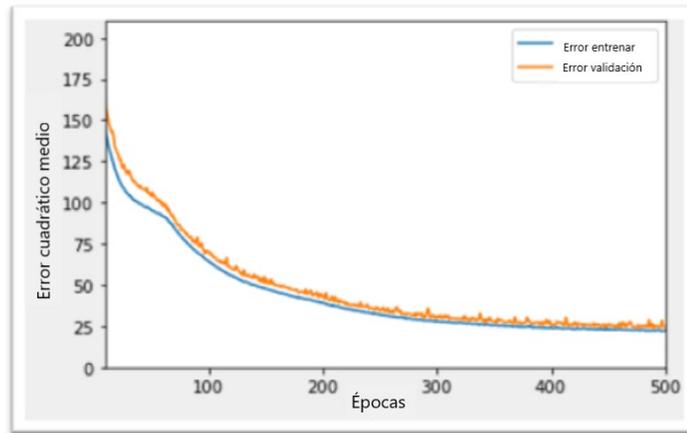


Figura 4-6: Ejemplo de curvas de entrenamiento y validación. Se grafican luego de cada época, pasos de tiempo dados al dividir el conjunto de datos en mini lotes.

En la Figura 4-6 se observa un ejemplo de buen entrenamiento, las curvas de validación y entrenamiento confluyen luego de algunas épocas. Adicionalmente, se concluye que ya no es necesario continuar las iteraciones, debido al aplanamiento de las curvas. Ahora bien, gráficamente también es posible evidenciar los tipos básicos de problemas que puede estar enfrentando un modelo de machine learning.

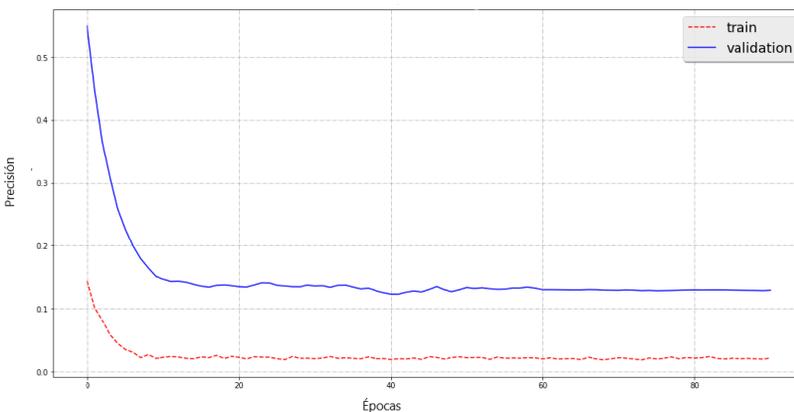


Figura 4-7: Ejemplo de sobre ajuste usando las curvas de entrenamiento y validación. Modificado de (Peña, 2020)

En la Figura 4-7 los errores de la curva de entrenamiento están muy por debajo de los errores de la curva de validación. La brecha entre ambas curvas nos indica el grado de variabilidad o varianza del modelo, una medida de la mala capacidad de generalización. Por otra parte, los bajos valores para la curva de

entrenamiento, sesgo del modelo, permiten inferir que la pérdida de generalización se debe al sobreajuste de estos últimos datos. Este problema se soluciona, entre muchas otras alternativas, con una regularización. La regularización consiste en reducir el número de variables de entrada, al tener muchos predictores y un conjunto de datos pequeño, se está ante la posibilidad de caer con facilidad en problemas de sobreajuste, a fin de resolverlo, aun perdiendo algo de precisión al final, es necesario limitar la cantidad de propiedades que ingresan al modelo.

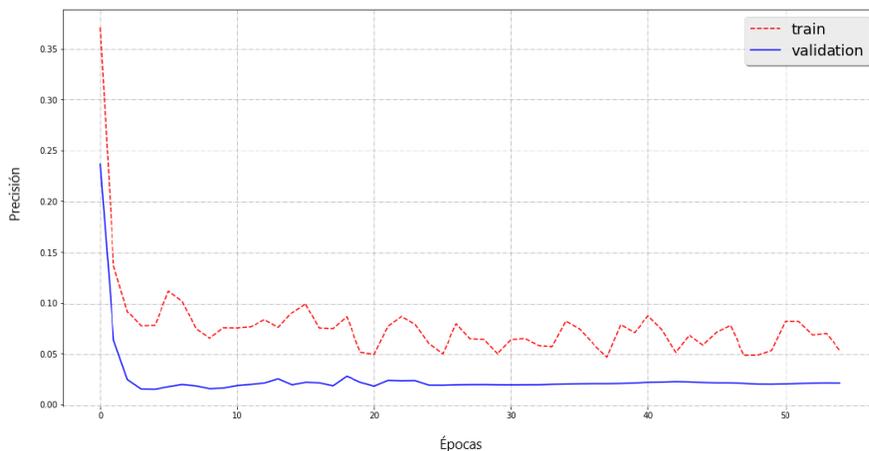


Figura 4-8: Ejemplo de falta de ajuste luego de analizar las curvas de entrenamiento y validación. Modificado de (Peña, 2020)

El caso opuesto es conocido como bajo ajuste o falta de ajuste, como el mostrado en la Figura 4-8. Las gráficas también pueden exhibir una variabilidad, brecha entre curvas, sin embargo, es este caso los valores más bajos del error pertenecen a la curva de validación. Los valores más altos para los datos de entrenamiento revelan la necesidad de iterar más el modelo para permitir al algoritmo encontrar mejor el patrón de comportamiento, otra opción es aumentar la cantidad de datos sobre el que se entrena. En cambio, los bajos valores en el conjunto de datos de validación son un indicio de un conjunto pequeño y no representativo de datos respecto al conformado en el set de entrenamiento.

En el proceso de comprobar la idoneidad del modelo es preciso desplegar algunas herramientas estadísticas de forma gráfica o en tablas resumidas. Los gráficos de errores son diagramas de puntos en un plano cartesiano o histogramas que, representan la distribución de las medidas reales contra las predichas, y la distribución de las diferencias entre los valores de ambas cantidades. A su vez, las tablas estadísticas resumidas proporcionan el valor de la precisión, error cuadrático medio, error absoluto medio y el R cuadrado del último paso de tiempo, es posible configurar la salida de la red para obtener menos

estadísticas o más añadiendo opciones como la tasa de aciertos o las tasas de falsos positivos y falsos negativos.

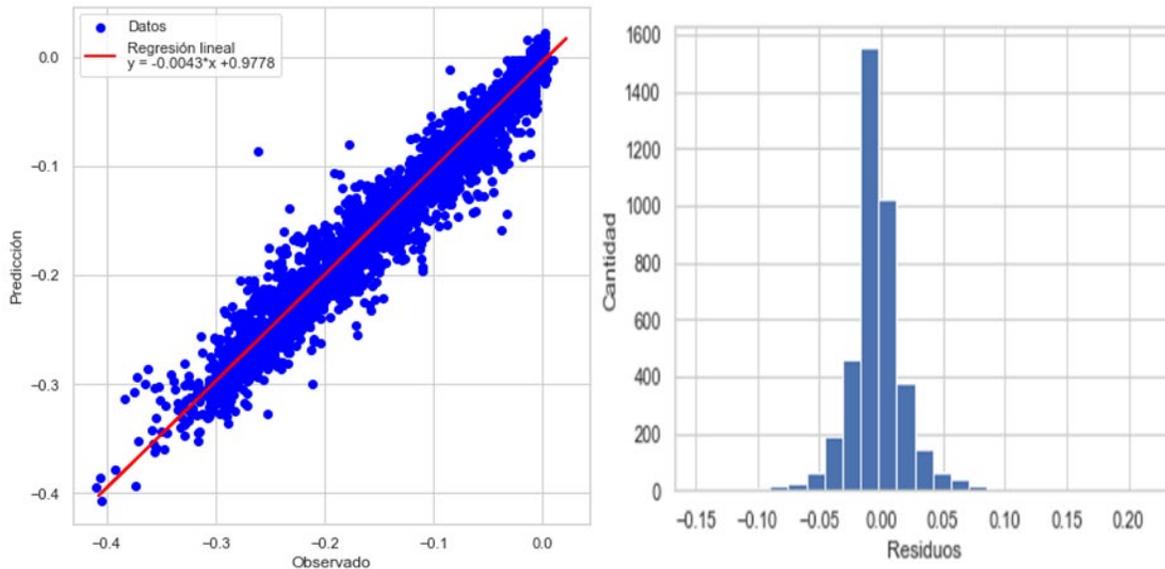


Figura 4-9: Gráficos estadísticos para analizar las predicciones contra los valores observados. El histograma muestra las diferencias entre valores predichos y observados.

```
Mean absolute error (MAE):      0.011932
Mean squared error (MSE):       0.000312
Root mean squared error (RMSE): 0.017651
R square (R^2):                 0.969446
```

Figura 4-10: Ejemplo de tabla de estadísticas resumidas para la última época del proceso de entrenamiento de una red.

Los productos que se generan al final del estadio de acondicionamiento del modelo son: los gráficos de dependencia y los mapas de distribución de errores, para los casos en que la aplicación tiene un comportamiento espacial o geográfico. Los gráficos de dependencia plotean los pesos que cada variable ejerce sobre la predicción, mientras los mapas de distribución grafican el error de las predicciones de manera espacial.

## APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

---

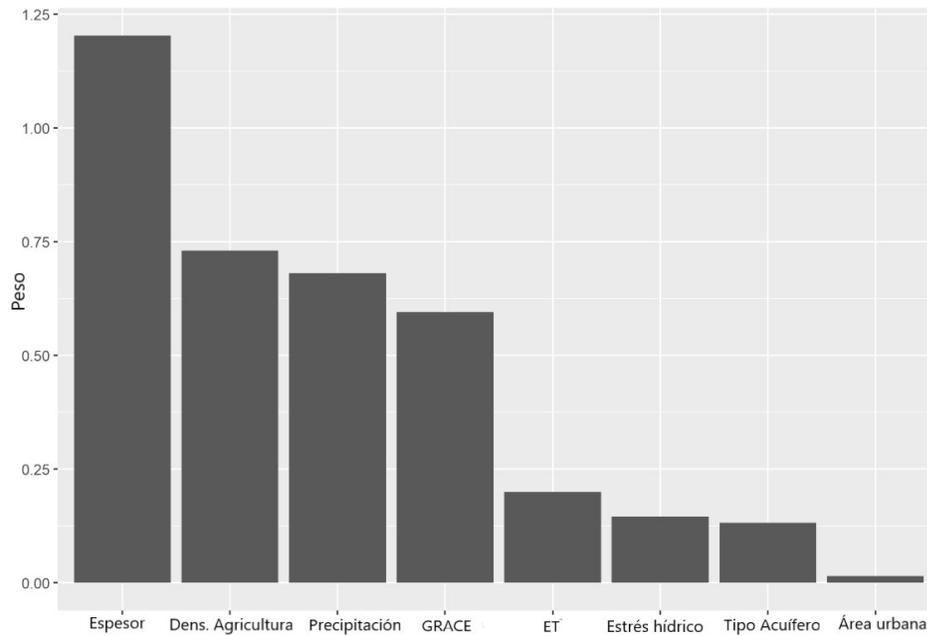


Figura 4-11: Ejemplo de diagrama de dependencia, los valores son la importancia que tiene cada variable para la predicción. Modificado de (Smith & Majumdar, 2020)

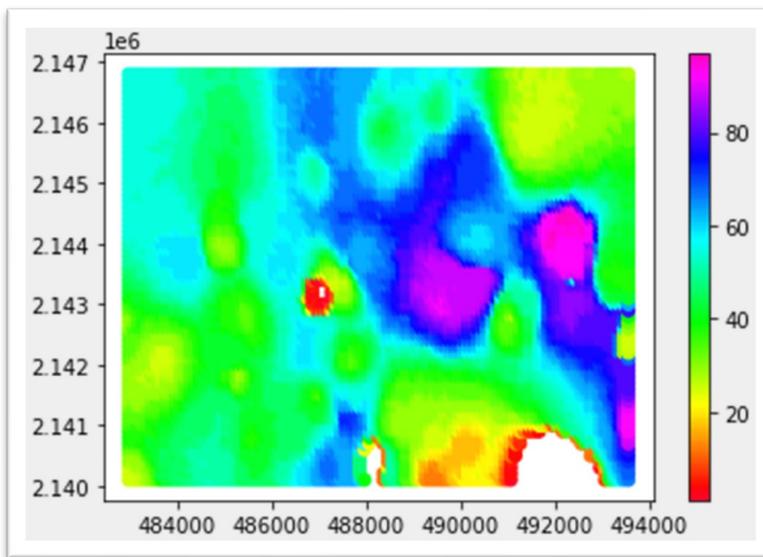
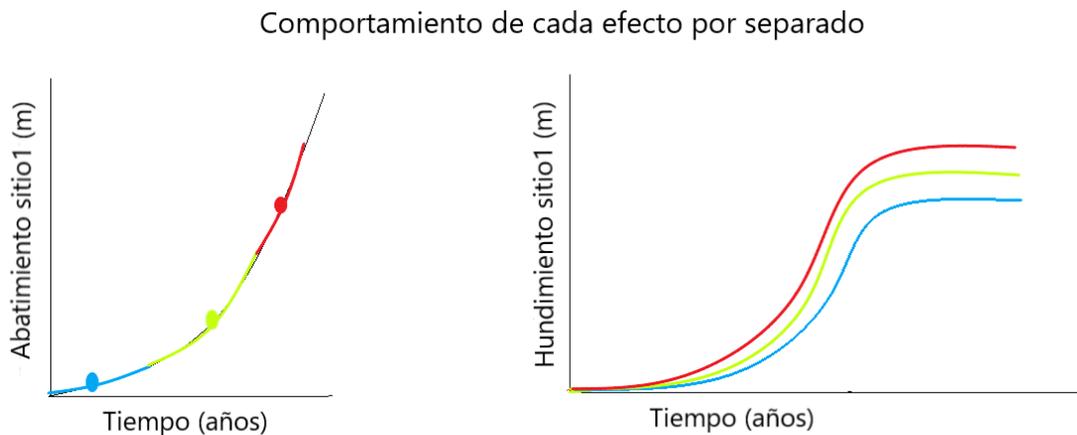


Figura 4-12: Ejemplo de mapa de error en la predicción, diferencia entre lo real y lo predicho, distribuido geográficamente.

#### 4.4. Hipótesis

El supuesto más relevante en esta investigación se basa en considerar que, empleando algoritmos de inteligencia artificial y una serie de datos como el abatimiento, la hidroestratigrafía y otras variables de un terreno, es posible construir un modelo que describa el comportamiento espacial de la subsidencia en la Ciudad de México.

Los datos con un componente temporal, por lo menos desde el enfoque más sencillo, son el abatimiento y la subsidencia. Cada variación en el abatimiento de una localización geográfica tendrá como consecuencia la generación de una curva de hundimiento en el tiempo, la forma que tome la curva y el tiempo que alcance hasta lograr el reposo dependerá del material de las rocas que conforman esa ubicación. Cada pequeña variación del abatimiento producirá una curva de hundimiento, sin embargo, tener registros continuos del nivel del agua para calcular el abatimiento de forma continua no es común, lo normal es consignar medidas cada cierto intervalo de tiempo, por lo que la construcción de una curva de hundimiento corresponderá al efecto promedio de una serie de valores del abatimiento que no se pueden conocer de antemano.



*Figura 4-13: Forma de las curvas de hundimientos en el tiempo generadas por cada cambio en el abatimiento. Se considera que cada abatimiento produce un efecto por separado. Una curva de hundimiento representa todos los efectos causados por la curva del mismo color en el abatimiento, bajo este supuesto, es como si solo se hubiera producido un cambio en el abatimiento con valor igual al promedio de toda la subcurva.*

Las gráficas de hundimiento originadas por cada perturbación del abatimiento no se configuran de manera aislada, más bien, cada nueva curva suma los efectos anteriores, no siendo el resultado de una sola perturbación, sino el acumulado de todo el historial de sucesos.

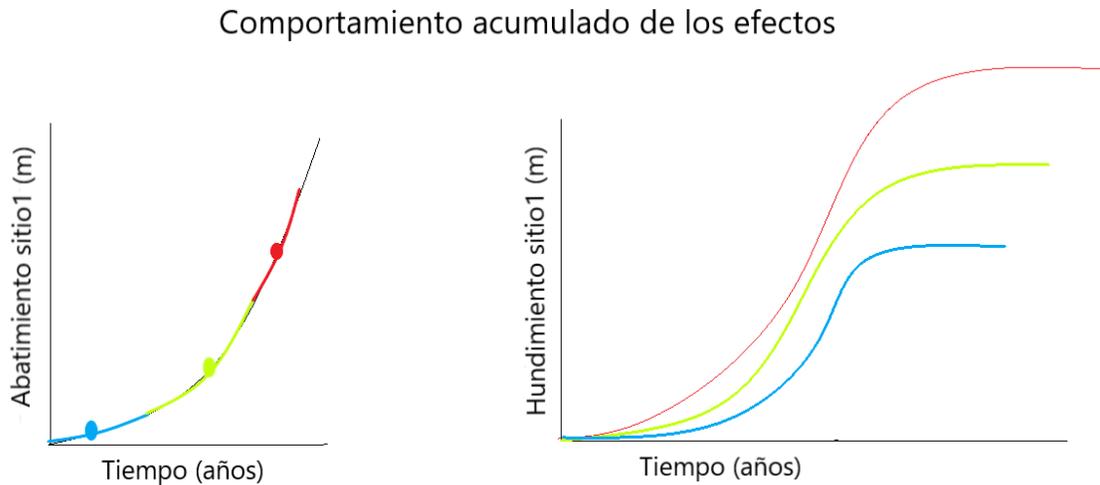


Figura 4-14: Curvas del hundimiento en el tiempo debido a variaciones en el nivel del agua. Cada curva es el resultado del abatimiento actual, más las acciones causadas por los anteriores abatimientos

En busca de generar un modelo que permita conocer cómo será la forma de la curva de hundimiento en una ubicación usando redes neuronales, se requiere conocer el valor en algunas partes de la gráfica. Los mejores sitios donde se podría tener medida son sobre los rasgos más representativos de una función, por ejemplo: sus puntos de inflexión, el lugar de máxima pendiente o el valor en donde la curva alcanza un cierto margen de estabilidad. Alejados del caso ideal, tenemos las dos fuentes que proveen al modelo de bases de datos de hundimiento. La primera es la red de bancos con que cuenta la ciudad, esta fuente proporciona una serie de puntos que, en teoría, deben coincidir con la curva de hundimiento, aun así, pueden estar un poco separados de la misma, a causa de no conocer el nivel de referencia cero, nivel de altura del punto geográfico antes de empezar el proceso de subsidencia. La solución es fijar un punto de referencia arbitrario que, al no concordar con el nivel exacto, traslada las mediciones una cierta distancia respecto a la gráfica. Por su parte, con INSAT solo se cuenta con una medida promediada por los últimos años, 2014 a 2020. Este único punto también estará alejado de la curva real del hundimiento, no solo por no conocerse el valor de referencia cero, sino que se suma la implicación del promediado de los datos.

Luego de ser entrenada la red neuronal, el algoritmo debe tener la capacidad de tomar un valor promedio del abatimiento y descubrir sobre que rasgo de la curva de hundimiento tiene mayor influencia, el patrón descubierto debe poder encontrar ese mismo rasgo dado el valor del abatimiento promedio, medido entre las mismas fechas, en cualquier otra ubicación geográfica.

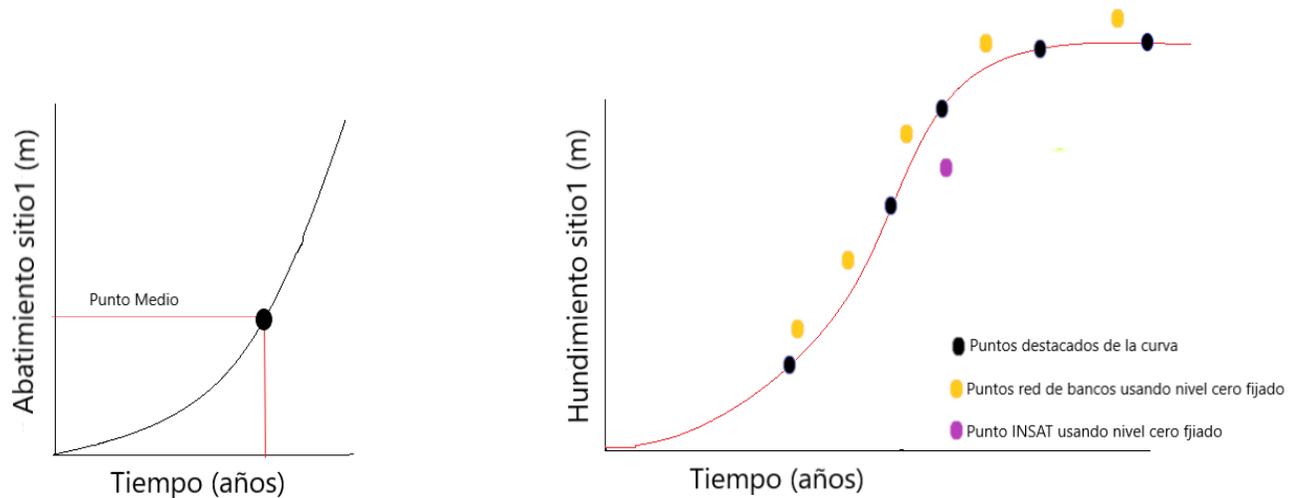


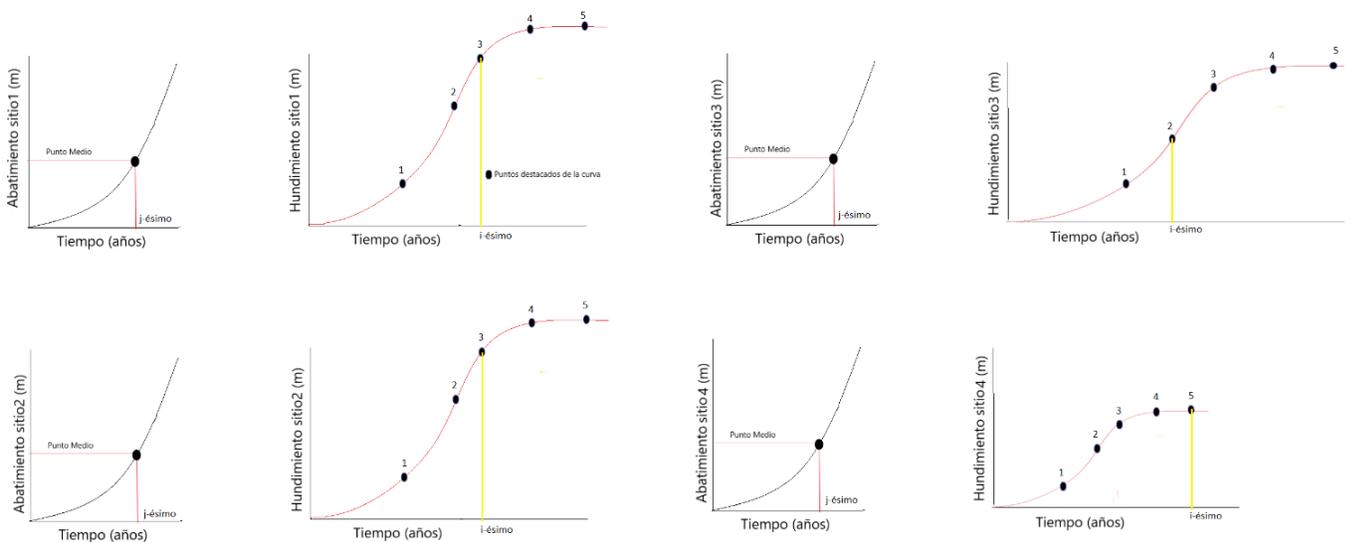
Figura 4-15: Generalmente, solo se tiene una medida del abatimiento en un intervalo de tiempo (izquierda). Las medidas de las dos fuentes de datos consultadas en la investigación en alguna coordenada, junto con los rasgos más destacados de una gráfica de hundimiento estándar(derecha).

El modo de entrenamiento será diferente para cada fuente de información. Los datos de la red de bancos suministran varios valores de la curva, por ende, es posible seleccionar un mismo abatimiento promedio, de un intervalo de tiempo, en todas las locaciones, y alimentar la red con los datos de la curva de hundimiento en todas las ubicaciones de un mismo año. Se repite el procedimiento con todos los periodos de la base de datos de hundimiento hasta encontrar el año para el cual el algoritmo aprende a encontrar el rasgo de la curva que más coincidencias posea, el mayor influyente sobre dicho rasgo será el abatimiento promedio seleccionado.

## APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Cada abatimiento tendrá una coincidencia con un rasgo diferente de la curva, no obstante, la diferencia entre el año del abatimiento y el año del rasgo debe ser un valor constante para todos los diferentes valores temporales que se asuman del abatimiento, propiedad conocida como el retardo del terreno. Los valores del hundimiento son suministrados a la red por años, obligando a todos los puntos geográficos a conservar el mismo retardo. El retardo en la naturaleza está controlado por la estructura y composición de la roca, y como las rocas no se distribuyen de manera uniforme en una cuenca, no es posible tener un retardo homogéneo en todo el terreno. La anterior limitación reduce la precisión del algoritmo, a su vez, es la responsable de las ligeras variaciones entre los retardos estimados para diferentes periodos del abatimiento, como también, suma incertidumbre a los pronósticos de hundimiento que se realicen con el modelo.

Las inexactitudes son solucionadas al agregar un retardo no homogéneo al problema, sin embargo, incorporarlo requiere contar con bases de datos de otras propiedades que, por la extensión de la zona, son precarias.

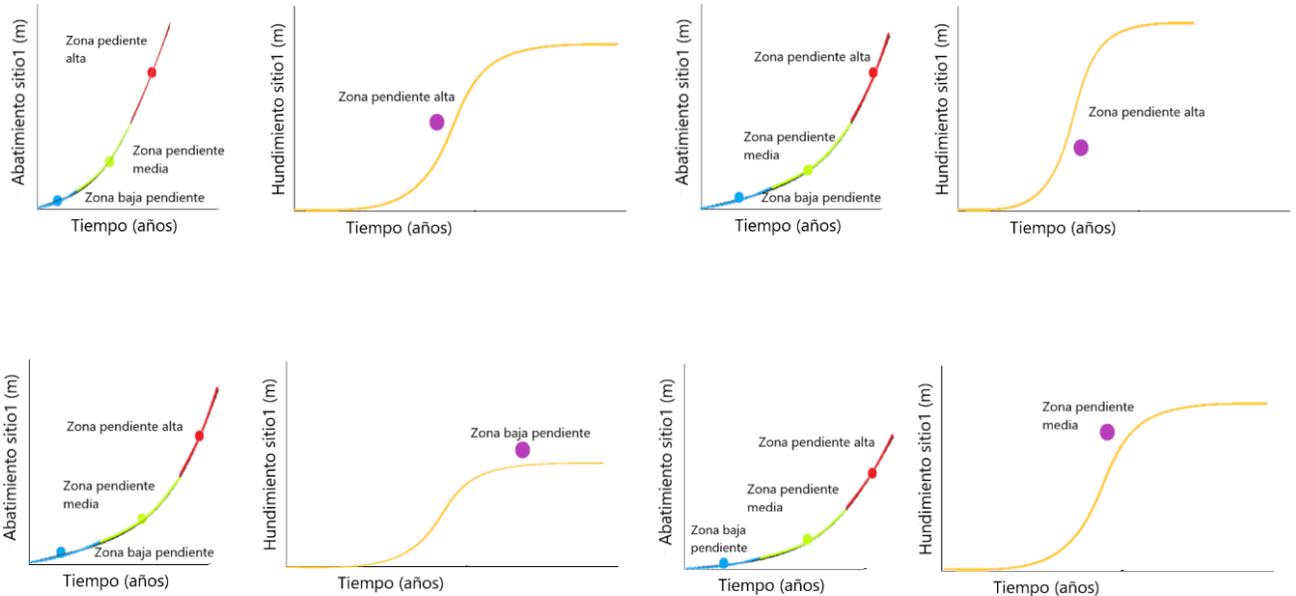


La red aprende el comportamiento de la mayoría, en este caso, aprende a reconocer el patrón del punto 3

Figura 4-16: Calibración de la red usando los datos de la red de bancos. Los valores se pasan a la red por años. Como no todos los puntos espaciales tienen el mismo retardo, la red aprenderá a distinguir el rasgo de la curva que la mayoría de las locaciones comparte.

Al usar la base de datos de INSAT se itera sobre todos los valores del abatimiento a fin de hallar el periodo que presenta mayores similitudes con los datos de INSAT, en otras palabras, fijado un rasgo de la curva encontrar el abatimiento que más influye en su configuración. Si bien, una ventaja de los algoritmos de machine learning es su habilidad para descifrar patrones, el problema atañe una dificultad inabarcable si se entiende la curva de hundimiento no como el producto de un solo abatimiento, sino como la suma de todo su histórico, el cual no se conoce, y, por consiguiente, no es indagado por el algoritmo. A pesar de esto, la red aprenda a desentrañar algunas contribuciones del único abatimiento que se está aprovisionando.

Una alternativa para remediar la disyuntiva es fijar un punto con información conocida como el origen de la subsidencia, procurando que sea un periodo con valores muy bajos de hundimiento para no incurrir en incertidumbres significativas, desde allí continuar entrenando el algoritmo con valores temporales discretizados, pero adhiriendo la salida del intervalo anterior como una variable de entrada al consecuente periodo a entrenar, así la red neuronal aprende el efecto causado por los cambios actuales más una carga acarreada por los efectos pasados. Este es el enfoque de trabajo de las redes neuronales de grafos, un algoritmo de deep learning más complejo y reciente, por lo que su aplicación puede sugerirse para futuros trabajos.



Se itera sobre los periodos de abatimiento hasta buscar la zona con mayores coincidencias en ambas curvas, en este caso, es la zona de alta pendiente. La curva de hundimiento no corresponde al efecto de ningún periodo de abatimiento, es el acumulado de todos, por eso pueden variar las coincidencias.

Figura 4-17: Calibración de la red usando datos de INSAT. Se itera sobre los valores del abatimiento. La red aprende a distinguir que periodo del abatimiento presenta mayor similitud en todas las ubicaciones con respecto al rasgo de las curvas que representan los datos de INSAT.

En ambos casos, el entrenamiento obtendría mejores resultados si los intervalos del abatimiento se redujeran, restricción que fijan las bases de datos consultadas. El proceso que se implementa en la última parte de la investigación, a fin de dar los primeros acercamientos al pronóstico del hundimiento en diversos años, combina las dos formas de entrenamiento en un ciclo anidado. En el bucle exterior se establece la variación de abatimientos descrito con las medidas de INSAT, mientras en el bucle interior se iteran los datos del hundimiento detallado en el entrenamiento que usa la red de bancos.

Por consiguiente, la investigación plantea el supuesto que, una red neuronal profunda es capaz de modelar, con un grado de precisión considerable, el fenómeno de subsidencia de la Ciudad de México. Dicho fenómeno presenta sus cambios de manera continua, y no por intervalos de tiempo discretos como se condiciona en el modelo de inteligencia artificial sugerido, no obstante, se considera que este algoritmo

tiene la capacidad de aprender cuál es el mayor efecto, en cuanto a hundimiento, que tendrá alterar las condiciones del terreno. Partiendo de esta conjetura, es aceptable estimar el tiempo de retardo que exhiben las arcillas de la zona de estudio, como también, estimar con un buen grado de incertidumbre, el peso que cada variable del terreno tiene sobre la predicción del hundimiento. Adicional a lo anterior, también se obtiene un modelo que predice subsidencia, no solo de manera cualitativa, por medio de los pesos del modelo, sino también, de forma cuantitativa al estimar los cambios de espesor en cada punto del dominio de trabajo. Pese a esto, las conjeturas aplicadas en la red no permiten estimar las contribuciones más pequeñas que se generan al alterar el terreno de manera continua y no solo en pasos discretos de tiempo, lo que se verá reflejado en las predicciones del algoritmo como fuentes de error que bajan la calidad del modelo.

La forma que se propone para comprobar la hipótesis principal es por medio de la precisión que tenga el modelo cuantitativo, si este modelo predice con un grado razonable de incertidumbre, podemos inferir que lo aprendido por el algoritmo estima la máxima tasa de hundimiento generado por una perturbación, y que los errores en el modelo son causados por las menores tasa de hundimiento, que contribuyen a la subsidencia total, debido a perturbaciones de pasos temporales previos y posteriores a la perturbación principal.

## 5. BASES DE DATOS

### 5.1. Escalamiento

En el proceso de escrutinio de las bases de datos destacan dos escalas principalmente, a 1000 m y a 100 m. La primera toma relevancia al ser la escala del conjunto de datos de abatimientos, propiedad que da inicio al proceso de subsidencia, además, al ser la escala más grande, es posible reescalar las demás variables a dicha escala incrustando un menor grado de incertidumbre que si se hiciera de modo contrario, pese a esto, el tamaño tan amplio del escalado produce una base de datos con muy pocos datos, imposibilitando a un algoritmo de redes neuronal que, busca encontrar patrones en un fenómeno muy complejo, a tener un buen desempeño.

La otra opción proviene del conjunto de datos de los espesores, las fuentes consultadas construyen sus medidas a escala de 100 m, lo que permite elaborar un conjunto de datos más nutrido. Otras variables como el hundimiento fueron creadas a escalas menores, de este modo, se facilita el proceso de reescalado al emplear un promediado de puntos cercanos a cada vértice de la nueva grilla, o una interpolación lineal simple, cualquiera de los dos métodos no amplifica significativamente la incertidumbre. Caso contrario ocurre con variables que tienen un mayor escalado, por ejemplo, el abatimiento, aquí el proceso de reducir la escala introduce una mayor imprecisión al modelo y dependerá del método que se aplique para lograr la reducción. Una inspección rápida de los datos de abatimiento muestra cambios muy pequeños entre medidas vecinas y con una tasa ciertamente lineal, por lo que una interpolación bilineal es sugerida para este fin. Esta es la escala empleada en el estudio, sin embargo, se fabrica un primer modelo a escala de 1000 m para demostrar el bajo rendimiento que tiene la red a falta de más datos de entrenamiento. Todos los mapas se muestran en escala de 100 m, sin embargo, también se construyeron a escala de 1000 m para la creación del primer modelo.

Una escala menor, como la que agrupa los datos de hundimiento de INSAR se descarta, con el propósito de evitar la reducción de escala de más variables, transformación que agrega mayor potencial de fluctuación a los cálculos.

Todas las variables se modifican a la misma escala y sus medidas se sitúan sobre las mismas coordenadas geográficas, condición necesaria para poder aplicar el algoritmo. A fin de cumplir con este requerimiento se producen cambios en la extensión de la zona de estudio a lo largo de la investigación, la razón recae en la falta de información en ciertos puntos geográficos de las nuevas variables que se van incorporando en cada nueva etapa del trabajo.

## **5.2. Datos manejados**

Los datos que se usaron tanto para construir la red, predictores, como para calibrarla, predicción, son resumidos en la Tabla 3-1.

En la tabla se indica la variable física que representa cada predictor; la clase de función que tendrá en la red, esto es, si es un predictor o la predicción; la fuente de información de donde es extraído el conjunto de datos de dicha variable; y la escala a la que fueron medidos los datos por la fuente.

### **5.2.1. Espesor**

#### **5.2.1.1. Espesor hidrofacies A**

Para obtener los espesores se parte de la información recolectada de los artículos (Medina, 2016) y (Luna, 2014) junto con los documentos facilitados por (Espriu, 2021). El espesor de interés es el expuesto en (Medina, 2016) nombrado como hidrofacies A, sin embargo, en este estudio no se registra la hidrofacies A para toda la ciudad de México y alrededores, por lo tanto, se entrenó una red neuronal que recibe el espesor del acuitardo superior, mismo definido en (Luna, 2014), y una serie de propiedades adicionales para predecir el espesor de la hidrofacies A en las locaciones en donde no se conoce su espesor. Para guiar el entrenamiento supervisado se proporcionan los valores de la hidrofacies A conocidos, de esta manera, el proceso de acondicionamiento es llevado a cabo en las zonas en común tanto de la base de datos de (Espriu, 2021) como la de (Medina, 2016).

Los espesores del acuitardo superior empleados son los que se proveen por (Espriu, 2021) en formato tiff para esta investigación. Un dominio más grande es posible si se consideran zonas adicionales procesadas

por (Luna, 2014), sin embargo, solo se cuenta con las imágenes del artículo, y aunque se diseñaron rutinas en Python para extraer los valores de los espesores de acuerdo con el color de las imágenes, al estar guardadas con una baja resolución, se crea un conjunto de datos con gran incertidumbre, lo que llevó a descartar la ampliación del área de estudio. En las zonas donde no se conoce el valor directo de la hidrofacies A, o donde tampoco se tiene el valor del acuitardo superior, que va a permitir pronosticar el valor del anterior espesor, no es posible considerarlo un punto del dominio del problema.

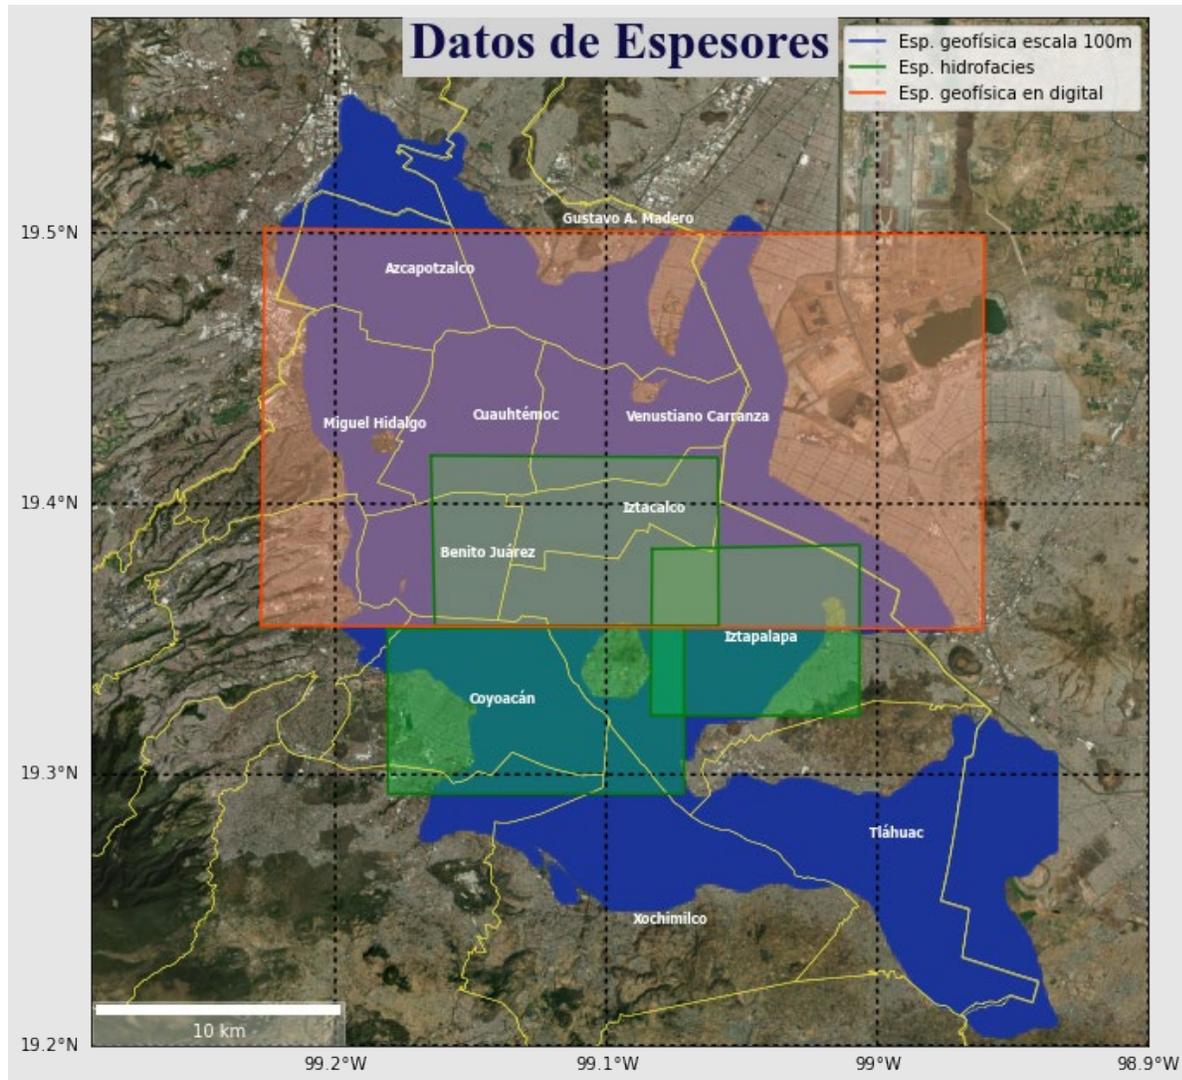


Figura 5-1: Distribución de las diferentes bases de datos de los espesores. En azul, la zona con datos planos del espesor del acuitardo superior (Espriu, 2021), en naranja, la zona con imágenes que muestran el valor del acuitardo superior (Luna, 2014), y en verde, las tres zonas con medidas de la hidrofacies A (Medina, 2016). Los espesores del acuitardo superior se referencian mediante el nombre espesor geofísico porque es el método usado para adquirir la base de datos, los resultados dependen de la forma de procesar e interpretar.

La Figura 2-7 describe la relación que existe entre la hidrofacies A y el acuitardo superior, este último, constituido por la suma de la hidrofacies A y la hidrofacies B. Una forma intuitiva, y más fácil de predecir la hidrofacies A, es encontrando la relación que existe entre el espesor de la hidrofacies A contra el espesor del acuitardo superior en todos los puntos que conforman la zona de estudio. El comportamiento entre los dos diferentes espesores, mostrado en la Figura 5-2, no es posible describirlo mediante una función matemática común, su distribución no parece seguir un patrón perceptible al ojo humano.

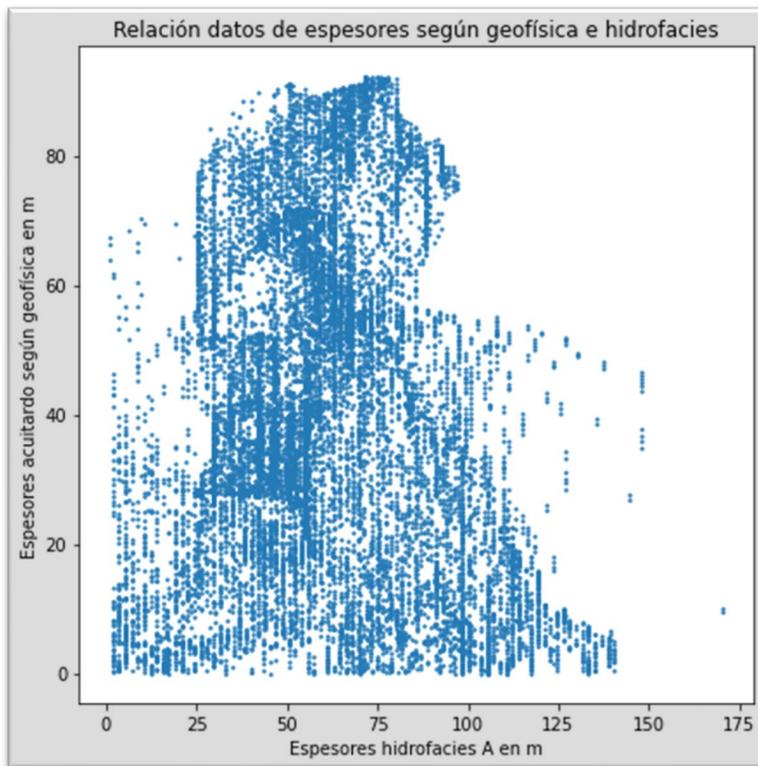


Figura 5-2: Distribución de las medidas del espesor del acuitardo superior contra espesor de la hidrofacies A en las locaciones en donde se tiene medida de los dos valores.

Una alternativa siempre disponible para descifrar patrones mucho más complejos es entrenando un algoritmo de inteligencia artificial. La forma de direccionar al algoritmo para que pueda encontrar conductas, no perceptibles a simple vista, es equipando la entrada al algoritmo con datos provenientes no solo de los predictores básicos, en este caso, el espesor del acuitardo superior, sino que además es necesario entregar bases de datos de nuevas propiedades, relacionadas con el problema. Mediante el análisis teórico del problema se proponen las propiedades: litología discretizada numéricamente por tipo, gradiente de altura del relieve en la dirección este – oeste, y en la dirección norte – sur, y los propios

valores de las coordenadas planas (x,y). Por medio de una serie de iteraciones se selecciona la combinación de las anteriores variables que genera los mejores modelos predictivos de la hidrofacies A.

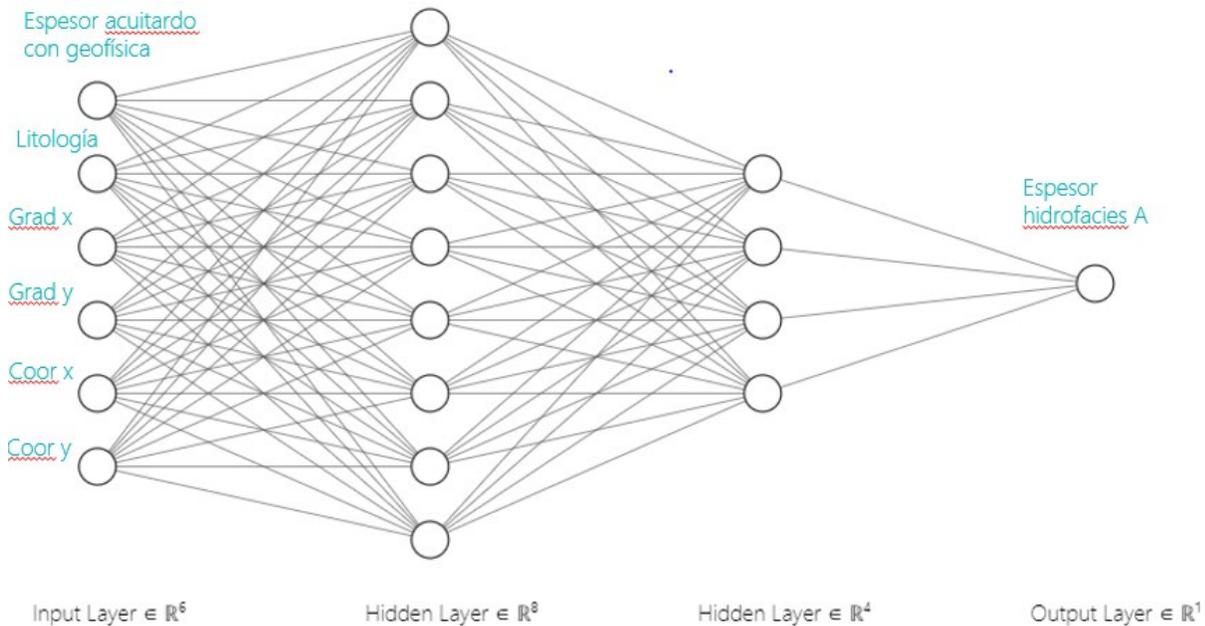


Figura 5-3: Esquema simplificado de la red neuronal desplegada para predecir la hidrofacies A. Las variables en la capa de entrada de la red son todas las posibles propiedades útiles para diseñar el modelo, un subconjunto será extraído como la mejor combinación.

El modelo escogido para predecir el espesor de la hidrofacies A mediante el espesor del acuitardo superior es una red neuronal de 3 capas, la primera de ellas con 16 neuronas, la segunda con 8 y la última con 1.

Luego de entrenar el modelo, las mejores combinaciones de variables para predecir la hidrofacies A son:

- Espesor del acuitardo superior, coordenadas x y y de cada punto.
- Espesor del acuitardo superior, litología, coordenadas x y y de cada punto.

Cada una de las dos propuestas finales es evaluada creando el mapa del valor de la hidrofacies A para toda el área de estudio. El modelo que no incorpora la litología predice valores en la parte sur mucho más grandes, razón por la que se descarta. El otro modelo, que sí incorpora la litología, aunque es el de mejor rendimiento y mejores predicciones, por lo cual es el seleccionado, aún presenta varias inconsistencias, en la zona occidental, próxima a las montañas, se espera una reducción a valores muy bajos del espesor de la hidrofacies A, pero la predicción no exhibe este comportamiento.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

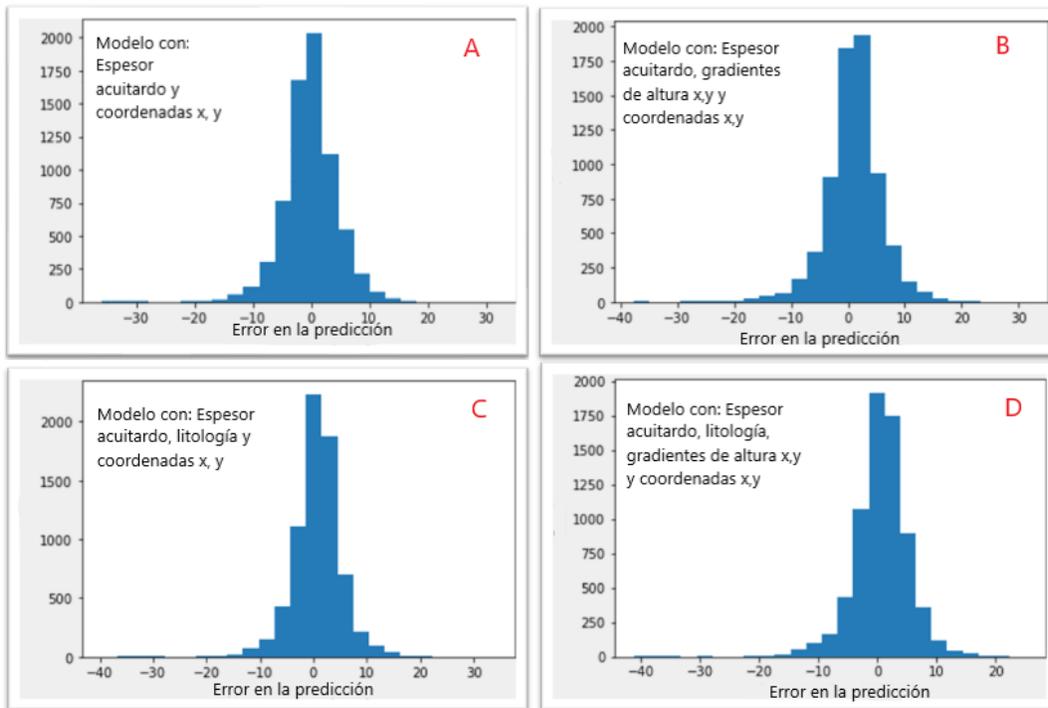


Figura 5-4: Algunas variaciones de los datos de entrada de la red. Los mejores modelos, mayor cantidad de datos centrados próximos al cero, son los modelos A y C.

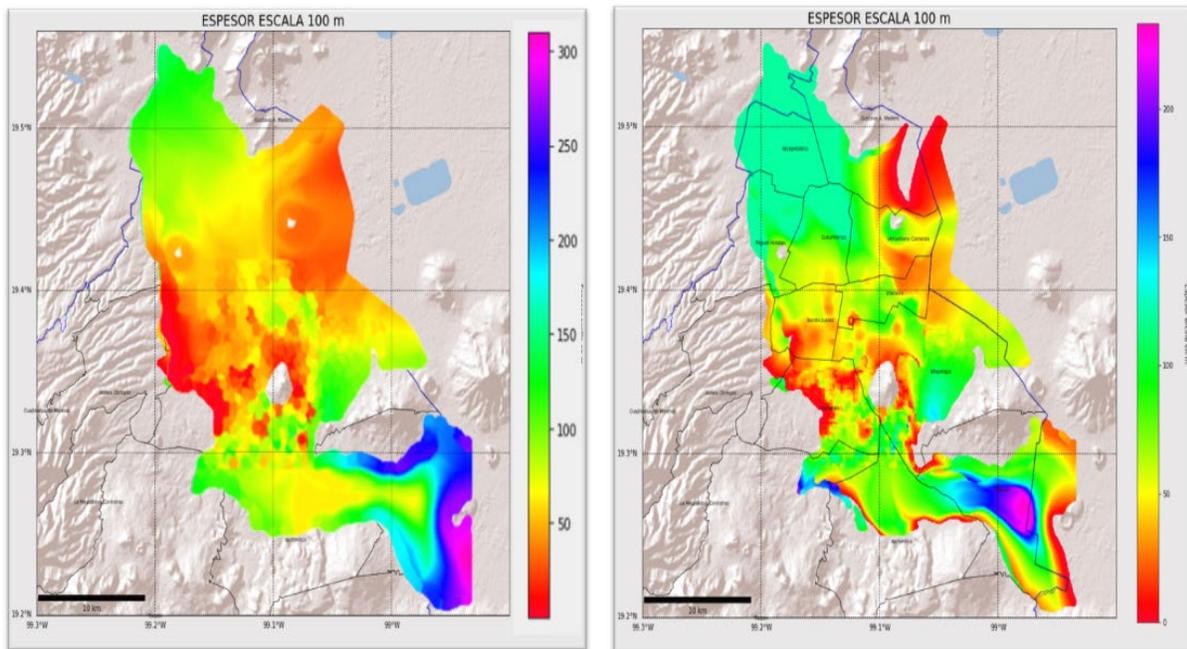


Figura 5-5: Mapa de las predicciones del espesor de la hidrofacies A empleando los dos mejores modelos. A la izquierda, el pronóstico generado con el modelo que no incluye la litología, a la derecha, el pronóstico con el modelo que si la incluye. El modelo de la izquierda alcanza espesores máximos de 300 m, el de la derecha lo máximo son 230 m y en una menor área.



El modelo que se va a utilizar en la primera parte del estudio de subsidencia es el que usa la normalización estándar, sin embargo, se debe destacar que no tiene un poder predictivo alto, así que se hace necesario ajustar una mejor propuesta, o replantear el uso de esta variable por otra. La Tabla 5-1 es un resumen de todos los parámetros de la red entrenada. Por otra parte, la Figura 5-7 expone la distribución y valor de los errores cometidos sobre el conjunto de datos de entrenamiento, mientras la Figura 5-8 es la relación entre la predicción y el valor real sobre todo el conjunto de datos de validación y entrenamiento.

Tabla 5-1: Parámetros de construcción de la red neuronal que predice la hidrofacies A.

Parámetros en la red	
Parámetro	Valores posibles
Número de capas	3
Neuronas por capas	16,8,1
función de pérdida	mse
Alg. Optimización	Adam
Normalización	estándar
Épocas	10000
set train - validación	80% - 10%
set test	10%

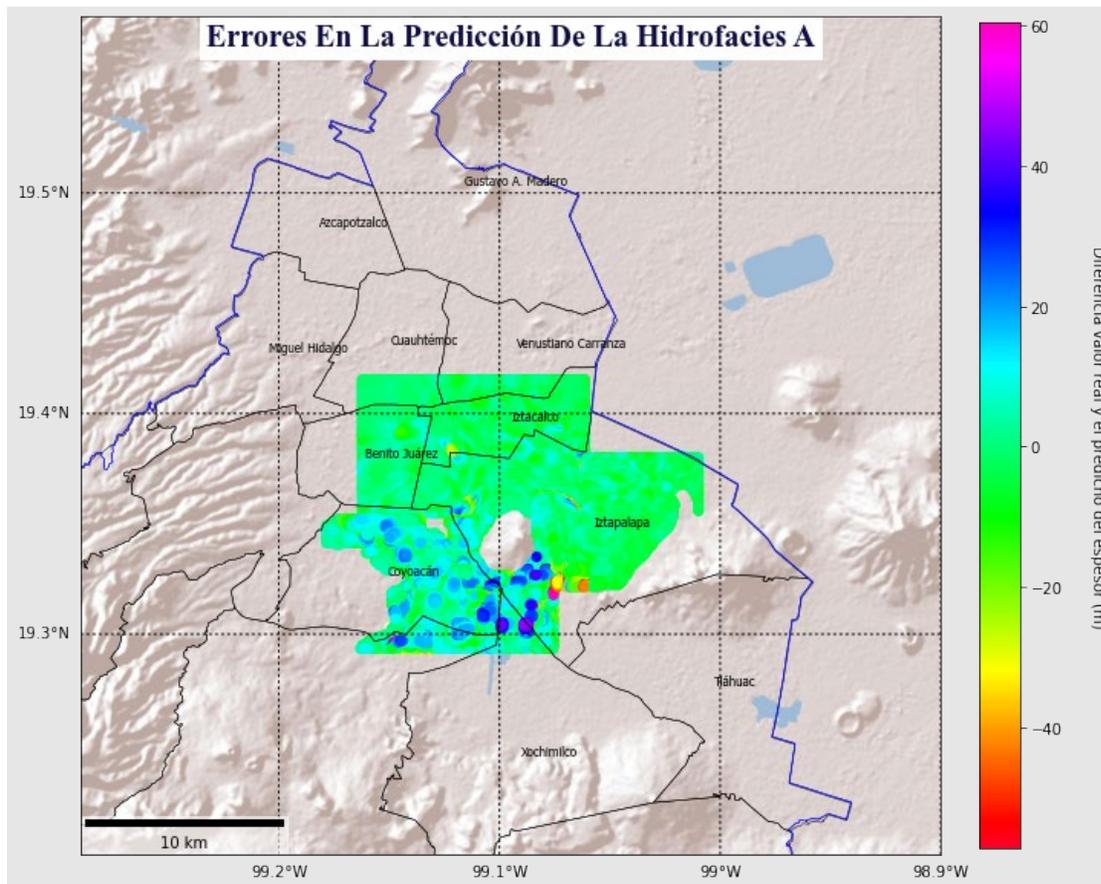


Figura 5-7: Errores al predecir la hidrofacies A en la zona de entrenamiento.

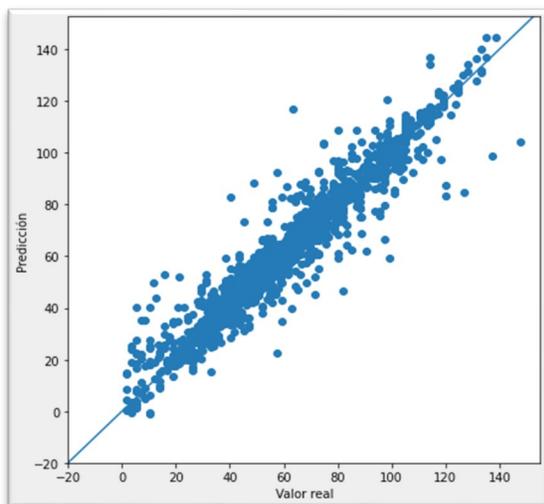


Figura 5-8: Medidas de la hidrofacies A pronosticada contra su valor real. Datos de entrenamiento y validación. Un poder predictivo ideal situaría todas las medidas sobre la red de 45°, línea de color azul.

En la Figura 5-7 los mayores errores se concentran en la alcaldía Coyoacán, se desconoce la razón, aunque es posible que sea más una responsabilidad de los datos que del modelo porque es un resultado constante en todas las variaciones del algoritmo implementado.

La Figura 5-9 representa la base de datos de la hidrofacies A en escala de 100 m que será parte de los predictores del modelo de subsidencia. Se resalta que el modelo no es el mejor al no ser estable, también por los valores elevados en la zona sur y por no reducirse el espesor al acercarse a las montañas.

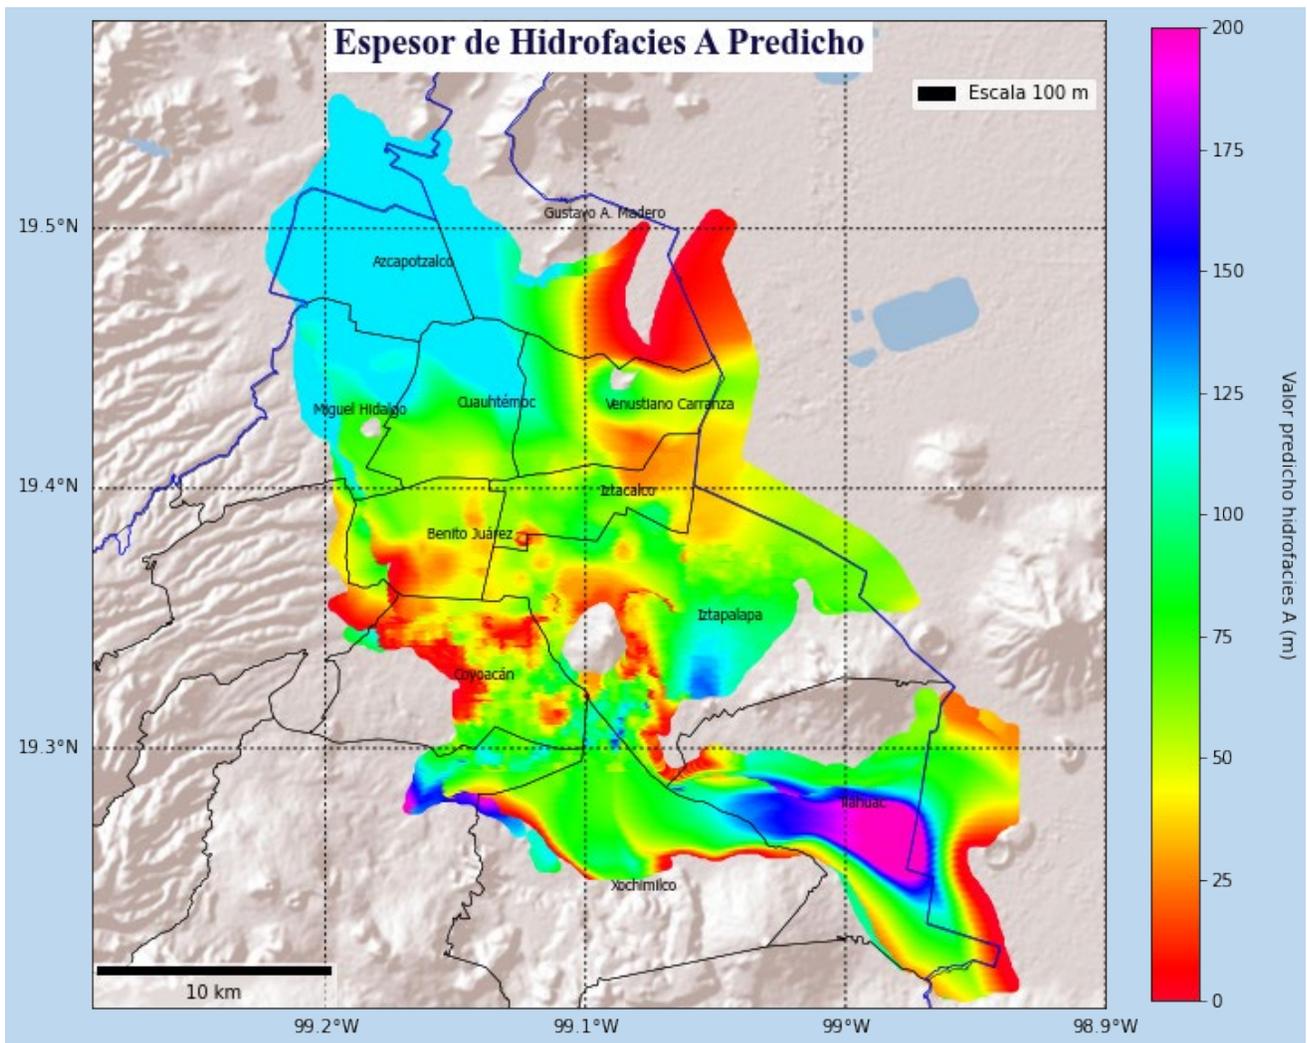


Figura 5-9: mapa con los valores de la hidrofacies A. Este conjunto de datos será parte de los predictores para el modelo de red neuronal que predice subsidencia.

#### **5.2.1.2. Espesor Hidrofacies A mejorado**

La red neuronal para predecir la hidrofacies A, hasta ahora propuesta, no tiene el grado de certeza que nos permita llegar a conclusiones completas. Mejorar el modelo solo es posible incrementando el número de predictores o aumentando la cantidad de medidas en el conjunto de datos. La primera opción fue considerada adhiriendo la distancia del punto hasta el borde de la montaña occidental más cercano, pese a esto, la predicción no mejora porque las montañas no solo están situadas en el borde occidental, sino al ser una cuenca cerrada, las montañas rodean la zona de estudio, por lo que se hace más complejo crear una variable que represente la distancia al borde de la montaña más próximo para cada punto. La segunda opción, aumentar la cantidad de medidas directas de la hidrofacies A, puede ser abordada bajo dos metodologías, una es disminuir la escala de los datos y aplicar alguna función de interpolación, de esta manera, aumentan los puntos de medida en la zona de entrenamiento trabajada hasta este momento, no obstante, si no conocemos como es el comportamiento de la hidrofacies A en locaciones cercanas a las montañas de todas las direcciones, se seguirán reproduciendo conductas anómalas en las cercanías a las montañas. La segunda metodología se basa en fijar puntos arbitrarios, próximos a las montañas, como puntos de control que, son incorporados a la base de datos con un valor de hidrofacies A igual a cero metros. Esta técnica es la que se desarrolla ya que resuelve dos limitaciones expuestas en las anteriores alternativas, ampliar la base de datos y controlar las cercanías con las montañas.

La disposición geográfica de todas las nuevas medidas junto con las antiguas se grafica en la Figura 5-10.

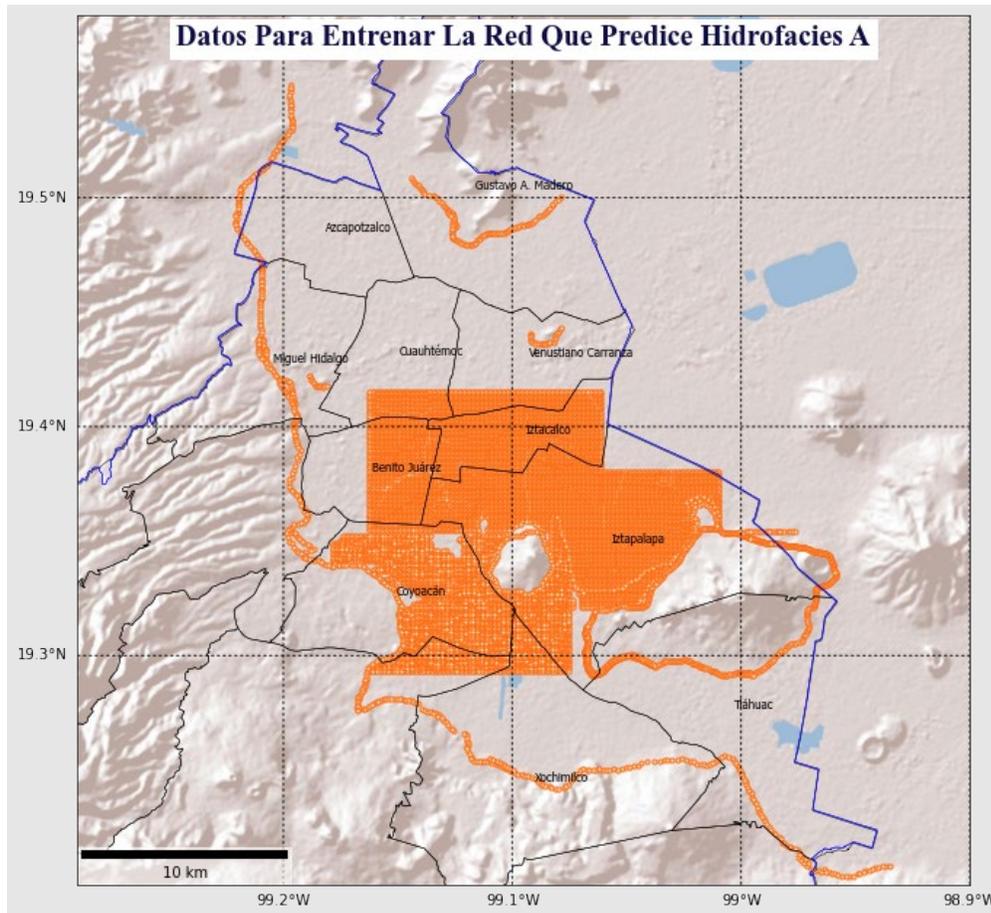


Figura 5-10: Dase de datos ampliada de la hidrofacies A estimada de manera directa.

En la Figura 5-11 se construye una vista de todas las gráficas estadísticas que evalúan el rendimiento de la red. Se percibe una mayor concentración de errores en la predicción con valores próximos a cero. Una apreciación adicional respalda una inferencia anterior, y es que los más grandes errores, aun cuando en magnitud son menores, siguen concentrándose en la alcaldía Coyoacán.

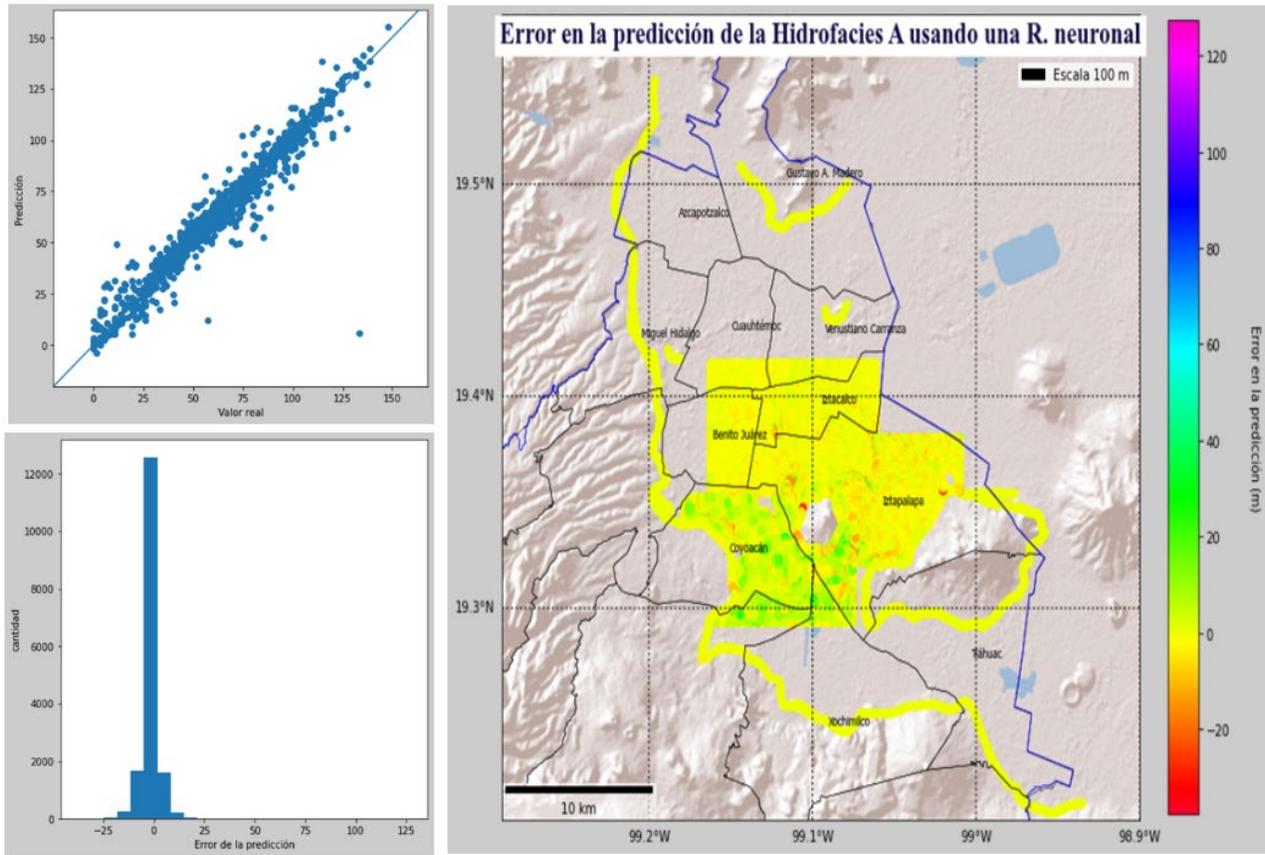


Figura 5-11: Validaciones para evaluar el proceso de entrenamiento de la red. En todos se grafica la diferencia entre el valor real y el predicho.

La predicción del modelo de la hidrofacies A en toda la zona de estudio se grafica en la Figura 5-12.

El modelo sigue sin ser estable, aunque reduce significativamente las magnitudes de los errores. En la zona sur los valores del espesor siguen siendo elevados, pese a esto, los espesores próximos a las montañas si se reducen a medida que se acerca al borde. Las redes neuronales entrenadas para predecir subsidencia tendrán una eficacia clara al usar esta mejora en la predicción de la hidrofacies A, no obstante, asignar el espesor del acuitardo superior como el predictor predeterminado tendrá un mejor desempeño.

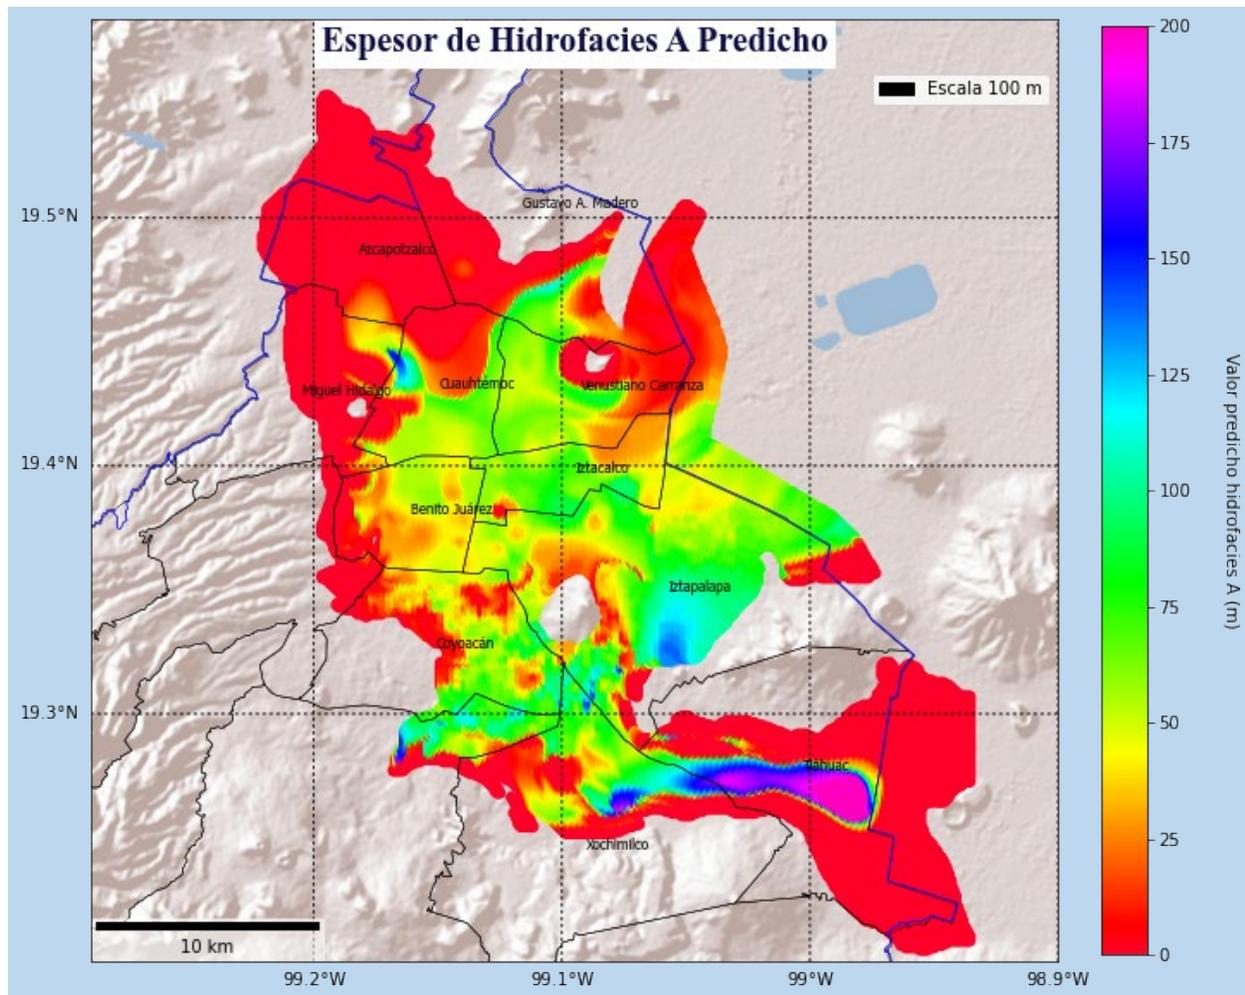


Figura 5-12: Predicción mejorada del espesor de la hidrofacies A.

### 5.2.1.3. Espesor Acuitardo Superior

Este espesor resulta ser el mejor predictor para establecer la cantidad de capas de arcilla compresible que componen cada punto del subsuelo, a pesar de que añade ruido al modelo al integrar capas de roca muy poco compresible también. La Figura 5-13 representa el espesor del acuitardo superior en todo el dominio, los datos son tomados directamente de los archivos suministrados por (Espriu, 2021). La grilla que produce este conjunto de datos será la base para escalar los demás predictores a 100 m. Un mejor modelo que permita desechar la hidrofacies B del acuitardo superior o una mayor cantidad de mediciones de la hidrofacies A por toda la región es una recomendación para mejorar el modelo.

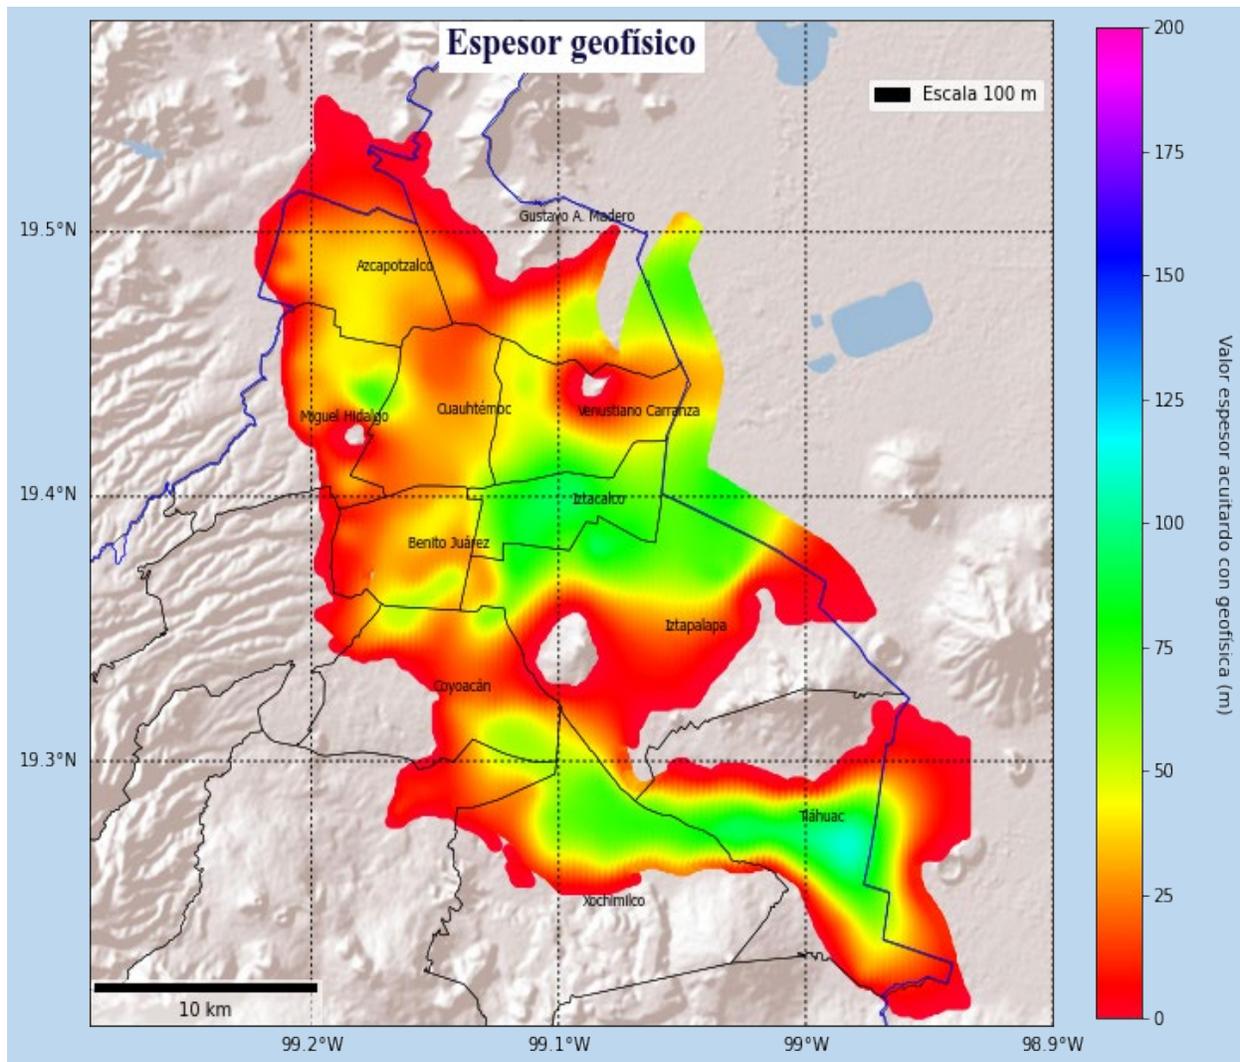


Figura 5-13: Espesor del acuitardo superior en toda la zona de estudio.

## 5.2.2. Compresibilidad de las rocas

### 5.2.2.1. Coeficiente de compresibilidad

Este predictor es obtenido del libro “El subsuelo de la Ciudad de México” (Marshall & Mazari, 1959). En esta referencia se trabaja con una división litológica relacionada con la hidrofacies A que se explica en la Figura 5-14.

Hidrofacies		Unidades litológicas	
Nombre	Descripción	Nombre	Descripción
A	Arcillas lacustres que constituyen el acuitardo superior	Formación arcillosa superior	Depósitos lacustres de ceniza volcánica muy compresibles
B	Sedimentos considerados como los depósitos aluviales	Capa dura	Capas de arena limosa, arcillas arenosas y arenas cementadas muy compactas
C	Basalto, basalto escoria y escoria. Hidrofacies de alta conductividad hidráulica	Formación arcillosa inferior	Depósitos lacustres de ceniza volcánica compresibles
D	Arena, grava y arena-grava. Son los depósitos aluviales de alta conductividad	Depósitos profundos	Serie de capas de arena, arenas y gravas, arenas limosas, limos y arcillas compactas.

Figura 5-14: Relación entre la hidrofacies A y las unidades litológicas presentadas en el trabajo de (Marshall & Mazari, 1959).

Por lo anterior, para cada punto en donde tenemos medido o calculado el espesor de la hidrofacies A obtendremos tres valores de coeficiente de compresibilidad, uno por cada formación vinculada con esta hidrofacies.

La forma en la que se une esta propiedad a la red es tomando cada capa de coeficientes como un predictor individual, o usando un promedio ponderado de cada coeficiente por su espesor para llegar a un único valor; la primera alternativa crea una base de datos más robusta y confiable, puesto que no en todas las formaciones se mide el coeficiente en los mismos puntos, incluso, las capas más profundas tienen una menor tasa de muestreo, por lo que al unificar la información en un solo valor se debe o despreciar algunos puntos de las capas superficiales, o computar el promedio ponderado luego de interpolar los coeficientes de cada formación junto con sus espesores, lo que introduce mucha más incertidumbre que solo hacer una interpolación al final. Por otro lado, la segunda alternativa tiene la ventaja de simplificar el modelo,

circunstancia que llevará a reducir los tiempos de procesamiento de la red. Se desarrollarán dos modelos distintos para evaluar cuál de las dos elecciones causa menos impacto en la predicción de hundimientos.

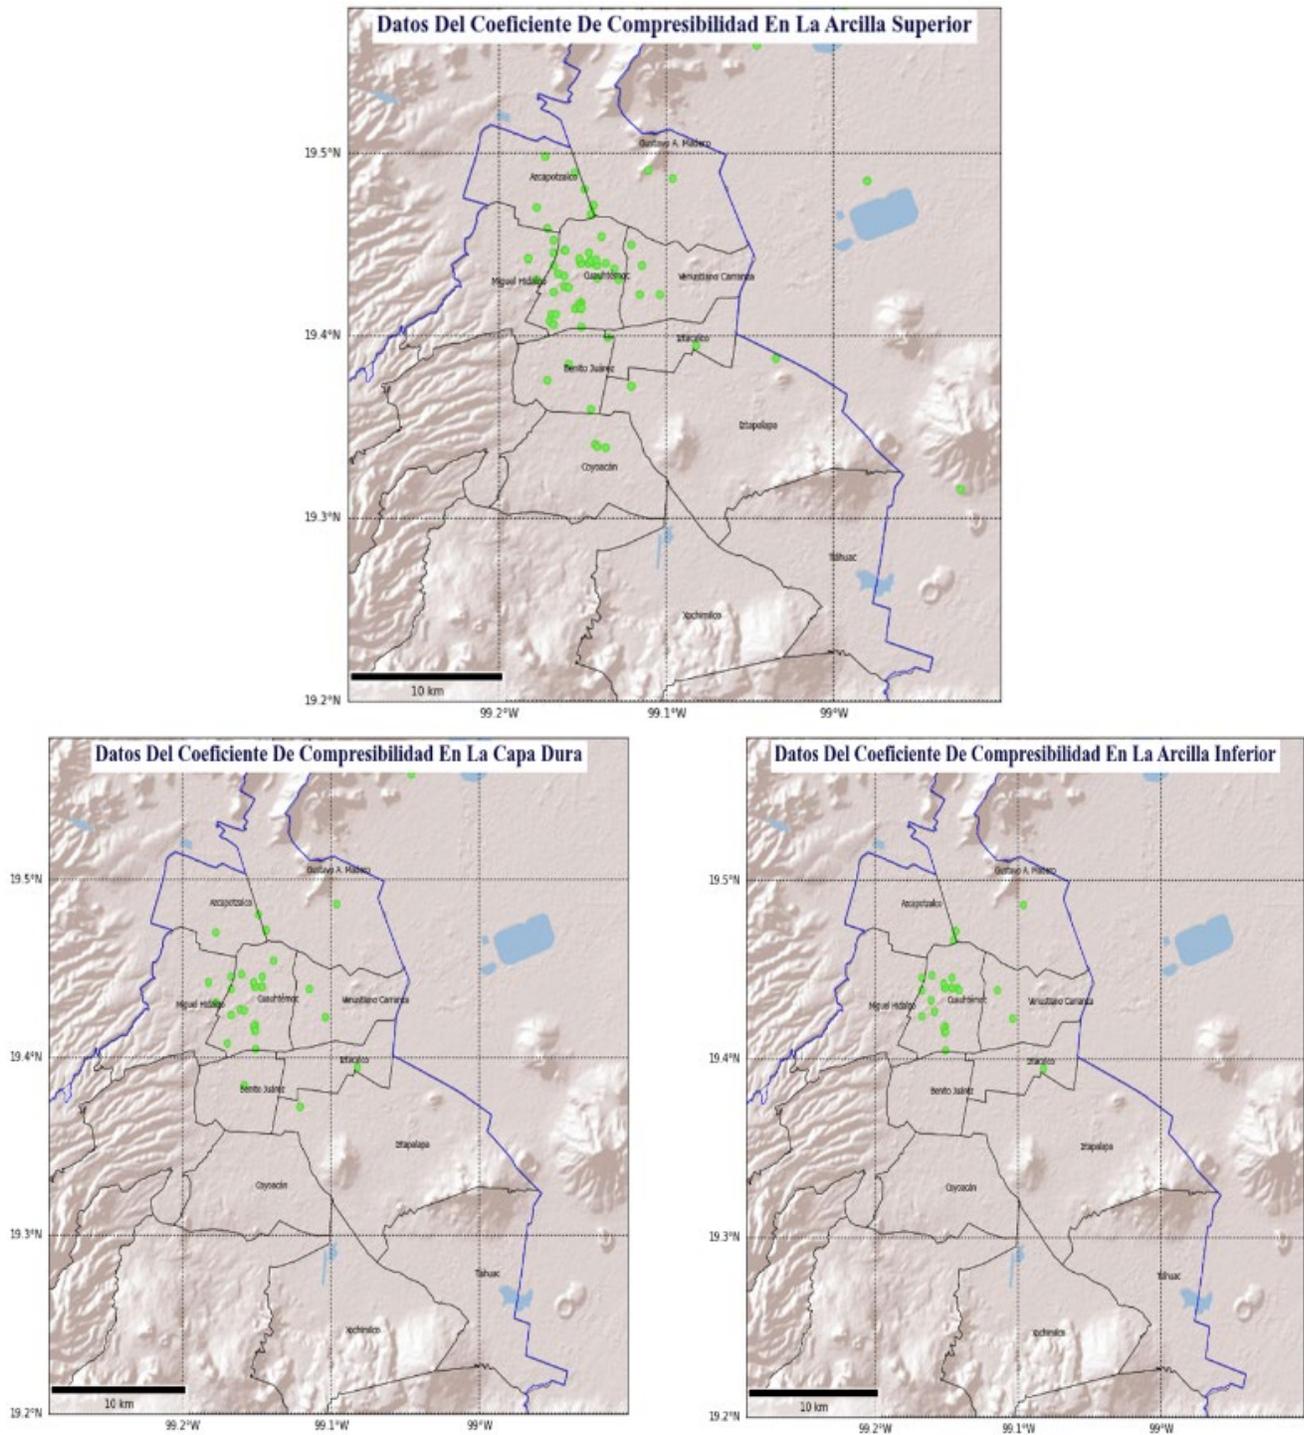


Figura 5-15: Disposición del muestreo del coeficiente de compresibilidad en cada formación

(Marshall & Mazari, 1959) registran la información en su libro por medio de tablas y compendios en gráficas que contienen barras de error, las tablas sintetizan la información básica como contenido de agua, límite plástico y límite líquido entre otras, mientras las gráficas abrevian propiedades más elaboradas como los coeficientes de compresibilidad, por esta razón, las medidas del coeficiente de compresibilidad en cada formación presentan una desviación estándar que puede llegar a ser tan grande como el valor medido. A falta de una distinta fuente de información, estos datos serán la base para construir el primer conjunto de datos del coeficiente de compresibilidad, sin embargo, un nuevo planteamiento se estableció para la segunda etapa de los resultados.

### ZONA DEL LAJO — GRUPO 2

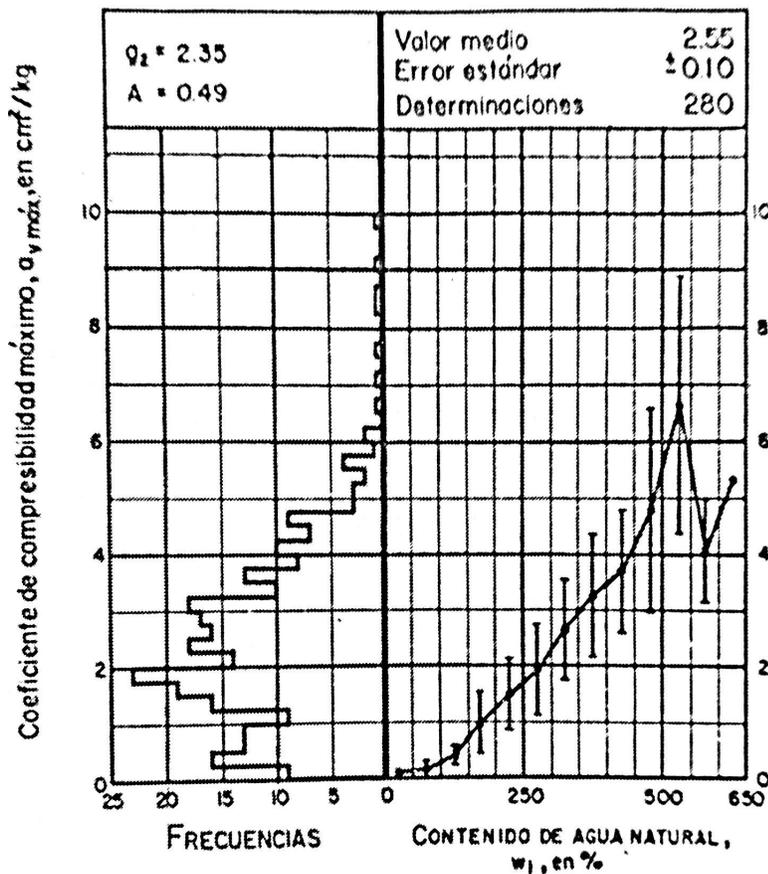


Figura 5-16: Ejemplo de una de las gráficas que promedian los valores del coeficiente de compresibilidad en el libro de (Marshall & Mazari, 1959). Las barras de error, desviación estándar, en las muestras con mayor contenido de agua alcanzan magnitudes similares al valor del coeficiente.

## APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Ya sea aplicando un promedio ponderado de los coeficientes de compresibilidad de las tres formaciones por sus espesores o empleando cada capa de coeficientes por separado, los valores se interpolan y extrapolan a todo el dominio de estudio por medio de un interpolador bilineal. La grilla del área de estudio es extraída del conjunto de datos de los espesores del acuitardo superior, requerimiento necesario para tener una base de datos consistente.

En varios trabajos consultados, obtener el valor del coeficiente de compresibilidad en toda el área de investigación no es posible, más en trabajos con regiones de estudio extensas, por lo que aproximan esta variable usando la litología, cada unidad litológica diferente se le asigna un número natural distinto. Este enfoque es tenido en cuenta en este trabajo con el fin de cuantificar el error cometido al hacer esta aproximación.

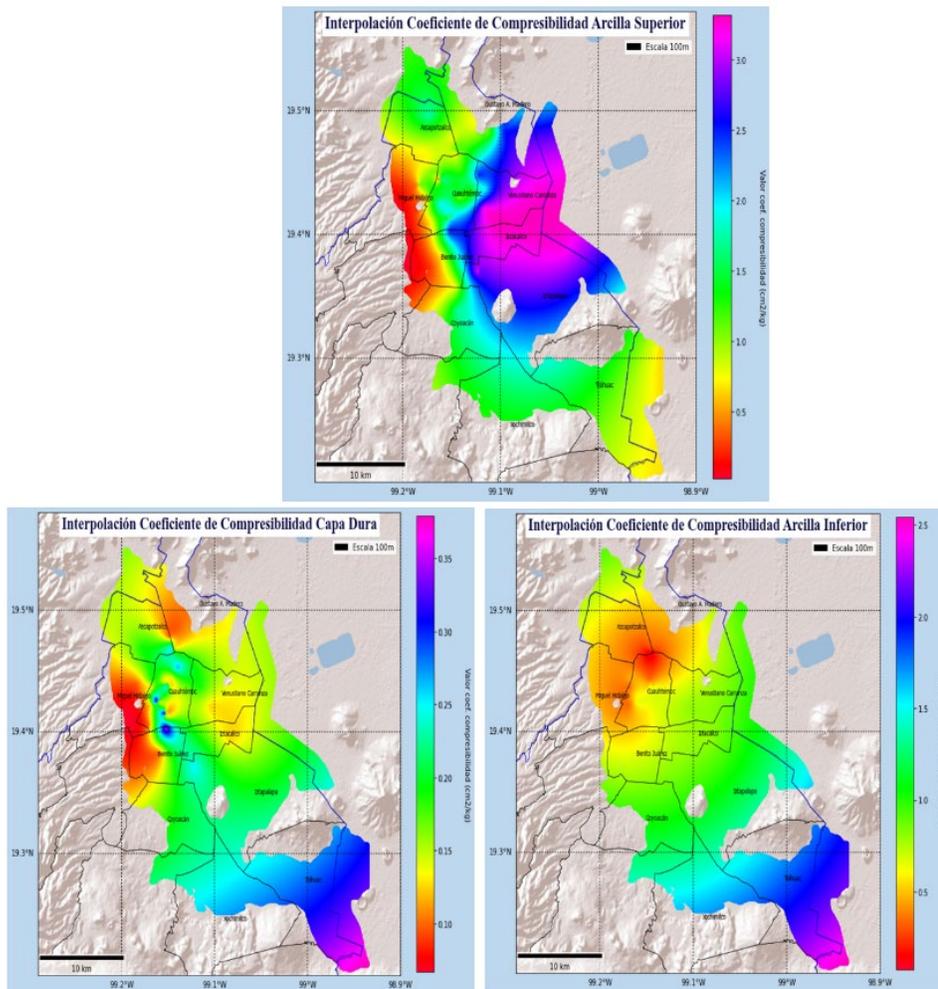


Figura 5-17: Coeficiente de compresibilidad de cada una de las tres formaciones que conforman la hidrofacies A.

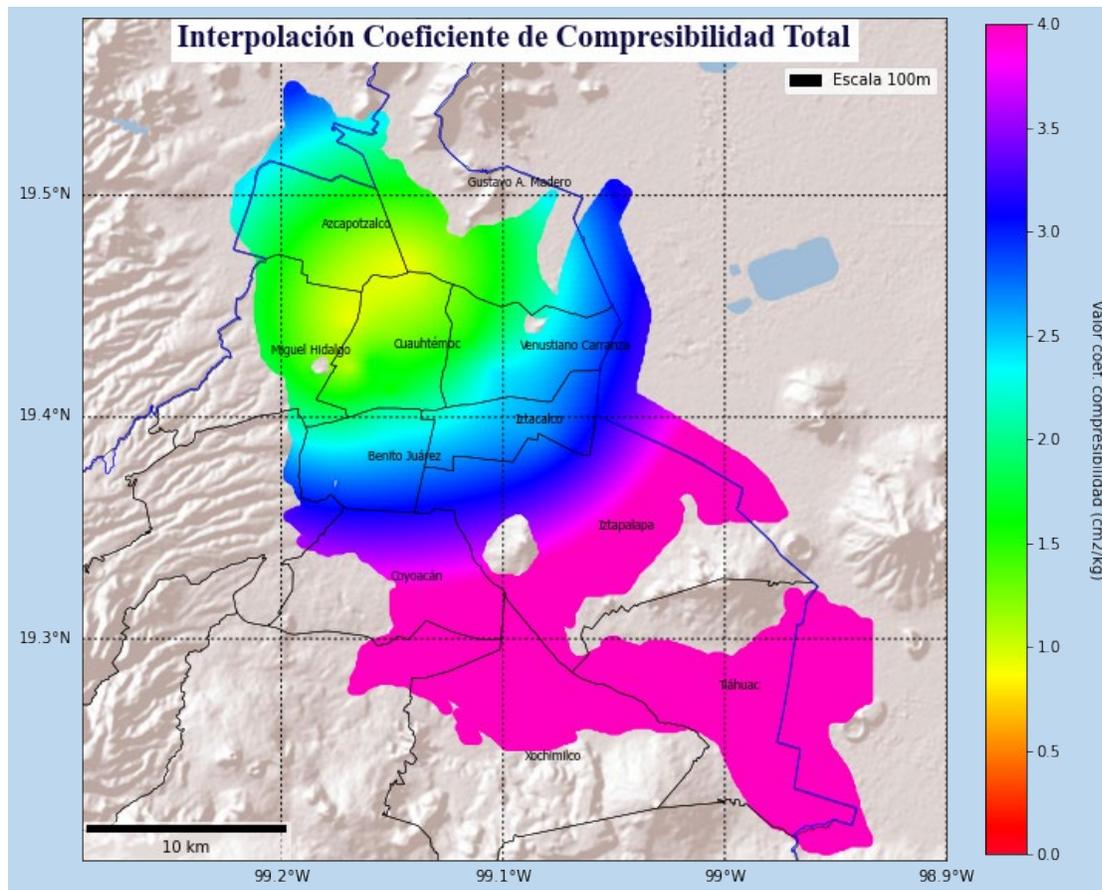


Figura 5-18: Promedio ponderado del coeficiente de compresibilidad de cada una de las tres formaciones por su espesor.

Se espera que el coeficiente de compresibilidad aumente al alejarse de las zonas de montaña, regiones más profundas de la cuenca, como se aprecia a grandes rasgos en la Figura 5-17 y Figura 5-18, sin embargo, en las anteriores figuras también se percibe el gran efecto del interpolador en las zonas sur y oriental de las gráficas, en donde los datos son escasos o nulos.

#### 5.2.2.2. Contenido de agua

El conjunto de dato del coeficiente de compresibilidad construido no mantiene el grado de certeza deseado, sobre todo en algunas partes de la cuenca, además, intentar mejorarlo es complicado, al ser una característica no disponible en muchas bases de datos abiertas. Sin embargo, el contenido de agua, al ser una propiedad fácil de medir, es compartida en un mayor número de investigaciones. En el libro de (Marshall & Mazari, 1959) el contenido de agua,  $W$ , es proporcionado en tablas, por lo que se elimina la

desviación estándar que acarrearán las gráficas. Tres nuevas fuentes de información son consumidas con el fin de mejorar las interpolaciones en algunas zonas de la cuenca. La primera es un informe técnico de dos líneas de transporte en la zona sur de la Ciudad de México llevadas a cabo por la empresa Geotest, Geotecnia y Supervisión Técnica S.A. de C.V. y compartido para la elaboración de esta investigación por (Geotest, 2019) en formato pdf. En su informe se calcula el contenido de agua, límite líquido y límite plástico de la formación Arcilla Superior en aproximadamente 200 locaciones de la zona sur occidental de la CDMX. Por otro lado, el artículo de (Resendiz, Springall, Rodríguez, & Esquivel, 1970) resume la información, disponible a la fecha, del contenido de agua y espesores de las tres formaciones que conforman la hidrofacies A, el artículo proporciona datos de cerca de 400 puntos sintetizados en tablas diligenciadas en máquinas de escribir y luego digitalizadas en formato pdf, algunos puntos no fue posible tenerlos en cuenta por la falta de legibilidad. Por último, la tesis de doctorado de (Juárez, 2015) incluye alrededor de 30 cortes litológicos con algunos registros del contenido de agua de pozos. Se programan algunas rutinas en Python para obtener el valor, en algunas imágenes de los cortes, del contenido de agua sobre los registros cada 5 metros, todas las cantidades de un solo registro son promediadas para producir una sola que, describirá el contenido de agua de la capa en dicha coordenada geográfica del registro. Por la poca profundidad de los registros, la única capa que se penetra es la formación Arcilla Superior.

El contenido de agua no es una propiedad que pueda sustituir directamente el coeficiente de compresibilidad al no ser una característica intrínseca de la roca, esta varía debido a factores externos como la vegetación, el clima o la cantidad de agua subterránea que se extraiga. Pese a esto, el contenido de agua puede desentrañar una relación propia con alguna otra variable que instaure el grado de compresibilidad de la roca.

### **5.2.2.3. Límite plástico y límite líquido**

Las tablas incorporadas en el libro de (Marshal & Mazari, 1959) también registran los límites líquido y plástico de las tres formaciones, por lo que también son datos libres de la desviación estándar alta que exhiben las propiedades expuestas en gráficas, su única diferencia con respecto al contenido de agua es que su muestreo disminuye un poco. La otra fuente de información es el informe técnico de (Geotest, 2019), no obstante, este informe solo inspecciona la formación Arcilla Superior.

Estas dos propiedades son mejores que el contenido de agua para reemplazar el coeficiente de compresibilidad de la roca, hipótesis sustentada solo bajo un punto de vista teórico. Adicional a esto, también pueden ser empleadas para configurar una relación que determine el valor de una variable directamente conectada con el grado de compresibilidad de una roca.

La desventaja, y quizás con un mayor peso que sus ventajas, radica en un muestreo mucho menor que el que se tiene para el contenido de agua.

### 5.2.2.4. Índice de compresión

El índice de compresión es una variable que puede reemplazar mucho mejor al coeficiente de compresibilidad, pero no es sondeada en ninguna de las fuentes de información que se consultaron, sin embargo, el trabajo de (Ayala, 2013) diseña un análisis que compone ecuaciones para extraer el índice de compresión en el Valle de México, dado el valor de una o varias propiedades más fáciles de medir como el contenido de agua, el límite líquido, el índice plástico o la relación de vacíos. En la Figura 5-19 se comparte el resumen estadístico que realiza (Ayala, 2013) para configurar las ecuaciones que permiten predecir el índice de compresión.

Parámetros	w <sub>L</sub> [%]	C <sub>c</sub>	PI [%]	C <sub>c</sub>	w [%]	C <sub>c</sub>	e	C <sub>c</sub>
Población	104		104		104		104	
Valor mínimo	60.40	0.14	17.83	0.14	36.36	0.14	0.99	0.14
Valor máximo	468.00	10.14	344.68	10.14	489.00	10.14	14.10	10.14
Media	231.86	4.28	158.82	4.28	234.56	4.24	5.99	3.91
Varianza	7 637.92	6.07	5 510.45	6.07	9710.03	5.74	7.53	5.79
Desviación estándar	87.39	2.46	74.23	2.46	98.54	2.40	2.74	2.41
Coefficiente de variación [%]	37.69	57.51	46.74	57.51	42.01	56.54	45.82	61.48
Coefficiente de correlación	0.708		0.778		0.890		0.909	
R <sup>2</sup> [%]	50.07		60.59		79.83		82.62	
R <sup>2</sup> -corregida [%]	49.57		60.20		79.62		82.47	
Error típico de la estimación	1.75		1.55		1.08		1.00	
Ecuación	C <sub>c</sub> =0.0199w <sub>L</sub> -0.3406		C <sub>c</sub> = 0.0258PI+0.1812		C <sub>c</sub> =0.0217w-0.8579		C <sub>c</sub> =0.7974e-0.8589	

Parámetros	w <sub>L</sub> [%]	w [%]	C <sub>c</sub>	w <sub>L</sub> [%]	e	C <sub>c</sub>	PI [%]	e	C <sub>c</sub>	w [%]	PI [%]	C <sub>c</sub>	w [%]	e	C <sub>c</sub>
Población	104			104			104			104			104		
Valor mínimo	60.4	36.3	0.14	60.4	0.99	0.14	17.8	0.99	0.14	c	17.8	0.14	36.3	0.99	0.14
Valor máximo	468.0	489.0	10.1	468.0	14.1	10.1	344.9	14.1	10.1	489	344.9	10.1	489	14.1	10.1
Media	231.9	234.0	4.2	231.9	6.2	4.2	158.8	6.2	4.2	234	158.8	4.2	234	6.2	4.2
Varianza	7638	9524	6.1	7637.9	7.6	6.1	5510	7.6	6.1	9524	5510	6.1	9524	7.6	6.1
Desviación estándar	87.4	97.6	2.5	87.4	2.8	2.5	74.2	2.8	2.5	97.6	74.2	2.5	97.6	2.8	2.5
Coefficiente de variación [%]	37.7	41.7	57.5	37.7	44.4	57.5	46.7	44.4	57.5	41.7	46.7	57.5	41.7	44.4	57.5
R <sup>2</sup> [%]	60.85			74.69			76.28			71.54			73.63		
R <sup>2</sup> -corregida [%]	59.72			74.19			75.81			70.98			73.10		
Error típico de la estimación	1.55			1.25			1.21			1.33			1.28		
Ecuación	C <sub>c</sub> =0.0027w+0.0218w <sub>L</sub> +1.0495			C <sub>c</sub> =0.6608e+0.0044w <sub>L</sub> -0.8572			C <sub>c</sub> =0.0089PI+0.5761e-0.7159			C <sub>c</sub> =0.0141w+0.0109PI-0.7472			C <sub>c</sub> =0.8230e-0.0017w-0.4428		

Figura 5-19: Resumen estadístico tomado de (Ayala, 2013) que muestra todas las relaciones entre el índice de compresión y otras variables estudiadas por este trabajo. Las ecuaciones se construyen para el Valle de México.

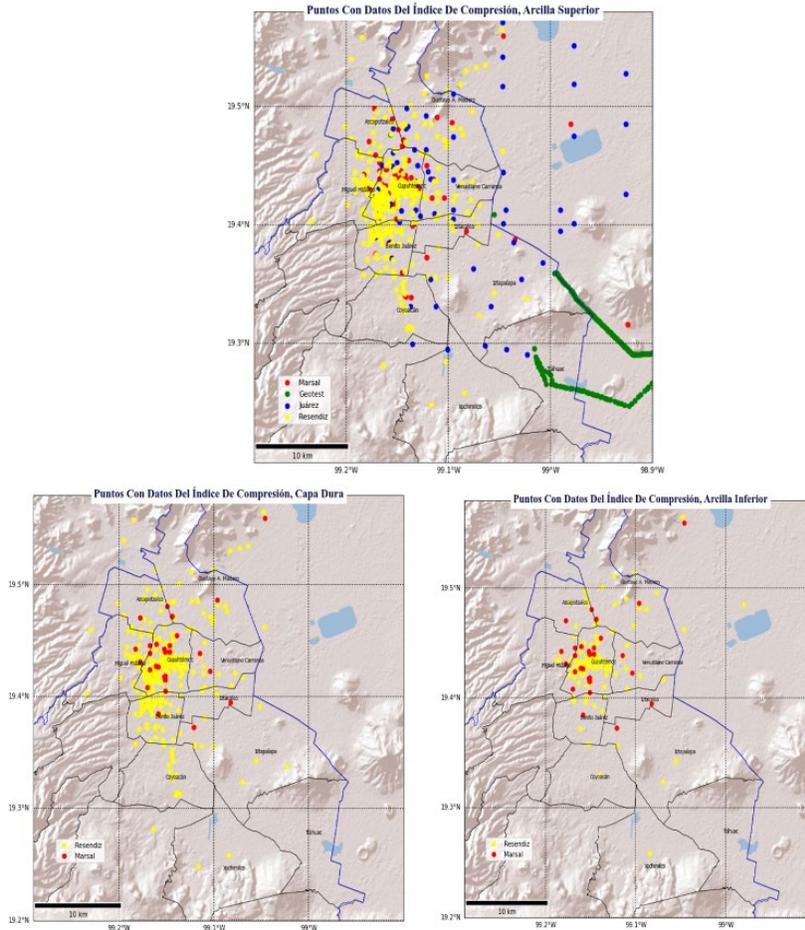
## APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

La ecuación que se elige para construir el conjunto de datos del índice de compresión en esta investigación es:

$$Cc = 0.0217 W - 0.8579$$

*Ecuación: 18*

No solo se selecciona la Ecuación: 188 por ser la que tiene uno de los  $R^2$  más grande de las opciones presentadas por (Ayala, 2013), sino porque la variable  $W$ , contenido de agua, es la que cuenta con el conjunto de datos más numeroso. En la Figura 5-21 y Figura 5-22 se componen los índices de compresión para cada formación de la hidrofacies A, y un promedio ponderado de los índices de compresión por sus espesores. El interpolador usado para proporcionar el valor del índice en las locaciones donde no se tiene medida es uno bilineal.



*Figura 5-20: Ubicación de los puntos donde se tiene medida del contenido de agua que, a su vez, permite calcular directamente el valor del índice de compresión en cada formación.*

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

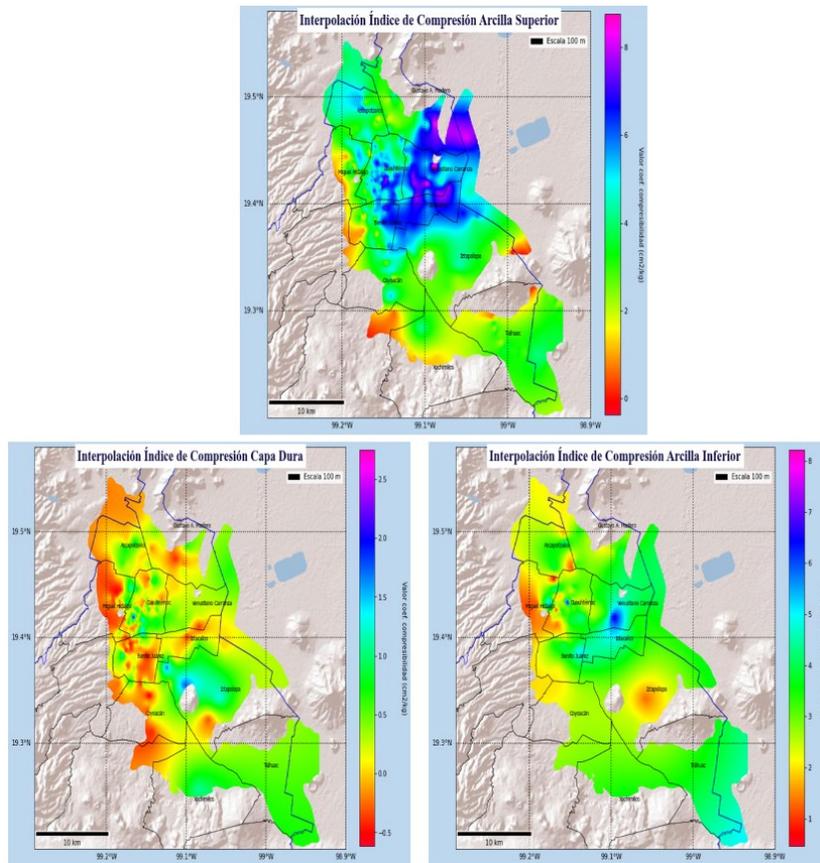


Figura 5-21: Interpolación del índice de compresión en cada una de las formaciones.

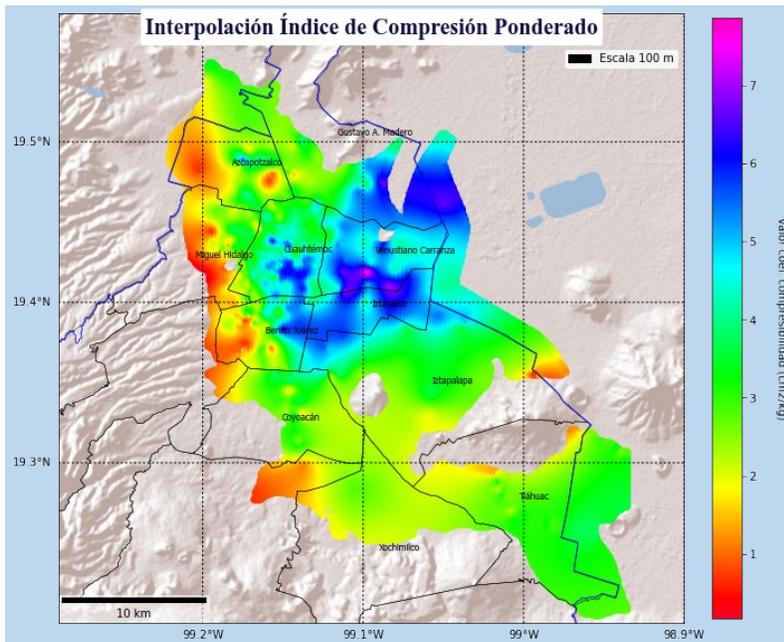


Figura 5-22: Interpolación del índice de compresión unificado.

### 5.2.3. Carga de preconsolidación

Al igual que el coeficiente de compresibilidad, los valores se obtienen de (Marshal & Mazari, 1959). Como se mencionó en el caso del coeficiente, la información es resumida en gráficas, por lo que la carga de preconsolidación también presenta una desviación estándar que llega a ser de la misma magnitud que la medición. Una fuente adicional de incertidumbre es la temporalidad de los datos, esta es una variable que cambia al modificar las condiciones superficiales del entorno, y como toda ciudad tiende a aumentar su número de construcciones y disminuir sus reservas de agua subterránea, estos datos tomados en 1959 pueden no representar muy bien la dinámica actual de fenómeno. También se tendrá el problema de la falta de mediciones en algunas zonas de la región.

En el artículo de (Smith & Majumdar, 2020), referente para este trabajo, este predictor es cambiado por un coeficiente empírico, dada la dificultad para obtener esta variable directamente en toda la región de estudio. Este coeficiente empírico tiene en cuenta la relación de píxeles, en imágenes satelitales, de zonas urbanas y zonas rurales próximas a un punto específico. De esta manera determina que tan estresado podría estar el acuífero, aseveración razonable ya que entre más terreno rural haya, se espera una mayor extracción de agua para alimentar los cultivos y para abastecer a algunas grandes empresas. Este coeficiente tiene la desventaja de no considerar el efecto de las edificaciones, a mayor cantidad de construcciones aumenta el esfuerzo efectivo sobre el terreno, pieza que también es clave para proponer un predictor que sustituya la carga de preconsolidación.

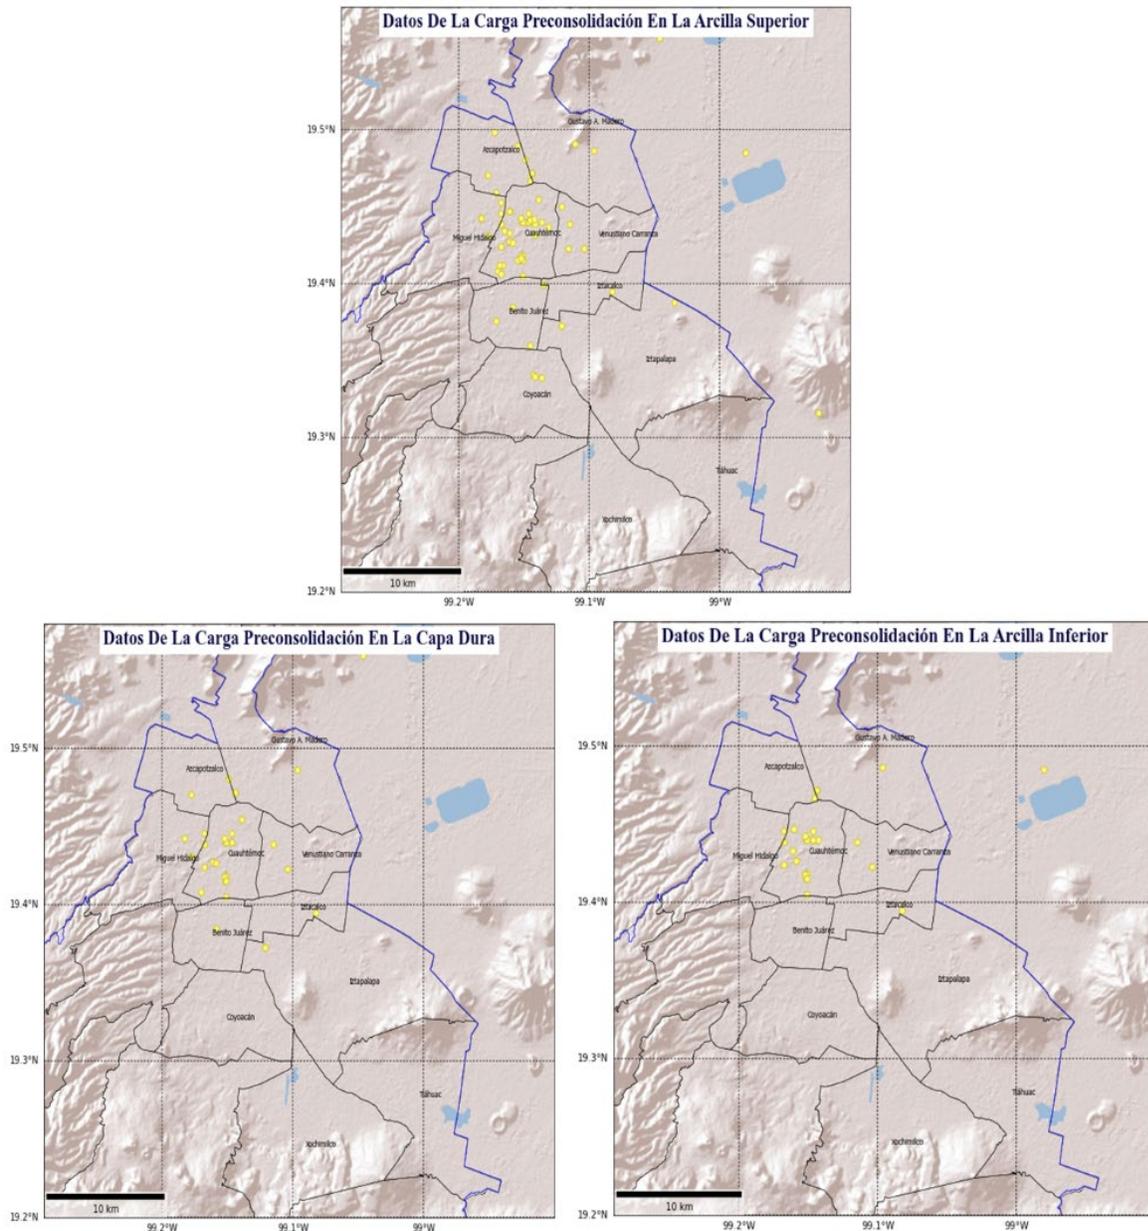


Figura 5-23: Distribución de las mediciones de carga de preconsolidación en cada una de las tres capas.

(Marshal & Mazari, 1959) proponen una zonificación geotécnica para la época, que permite orientar los procesos de interpolación del limitado conjunto de datos de carga de preconsolidación. El área de estudio está dividida en cuatro zonas, por lo que la interpolación o extrapolación de los datos solo tendrá en cuenta las mediciones en cada zona. El interpolador destinado es nuevamente un interpolador bilineal. Esta guía no mejora ampliamente los resultados conseguidos, las razones, ya mencionadas, son la falta de un amplio conjunto de datos y la antigüedad de las mediciones.



Figura 5-24: Zonificación propuesta para la región, se resaltan con líneas los límites de las zonas y con puntos las locaciones con mediciones. Modificado de (Marshal & Mazari, 1959).

En la primera etapa de los resultados se empleó este conjunto de datos de carga de preconsolidación, aun con todas sus desventajas, para establecer una primera aproximación. Por lo tanto, es posible construir una base de datos con los valores de la carga de preconsolidación para cada una de las tres formaciones o un solo valor con el promedio ponderado de las cargas y sus espesores. Se implementa un modelo por cada caso a fin de revelar cuál de las dos alternativas genera modelos más precisos.

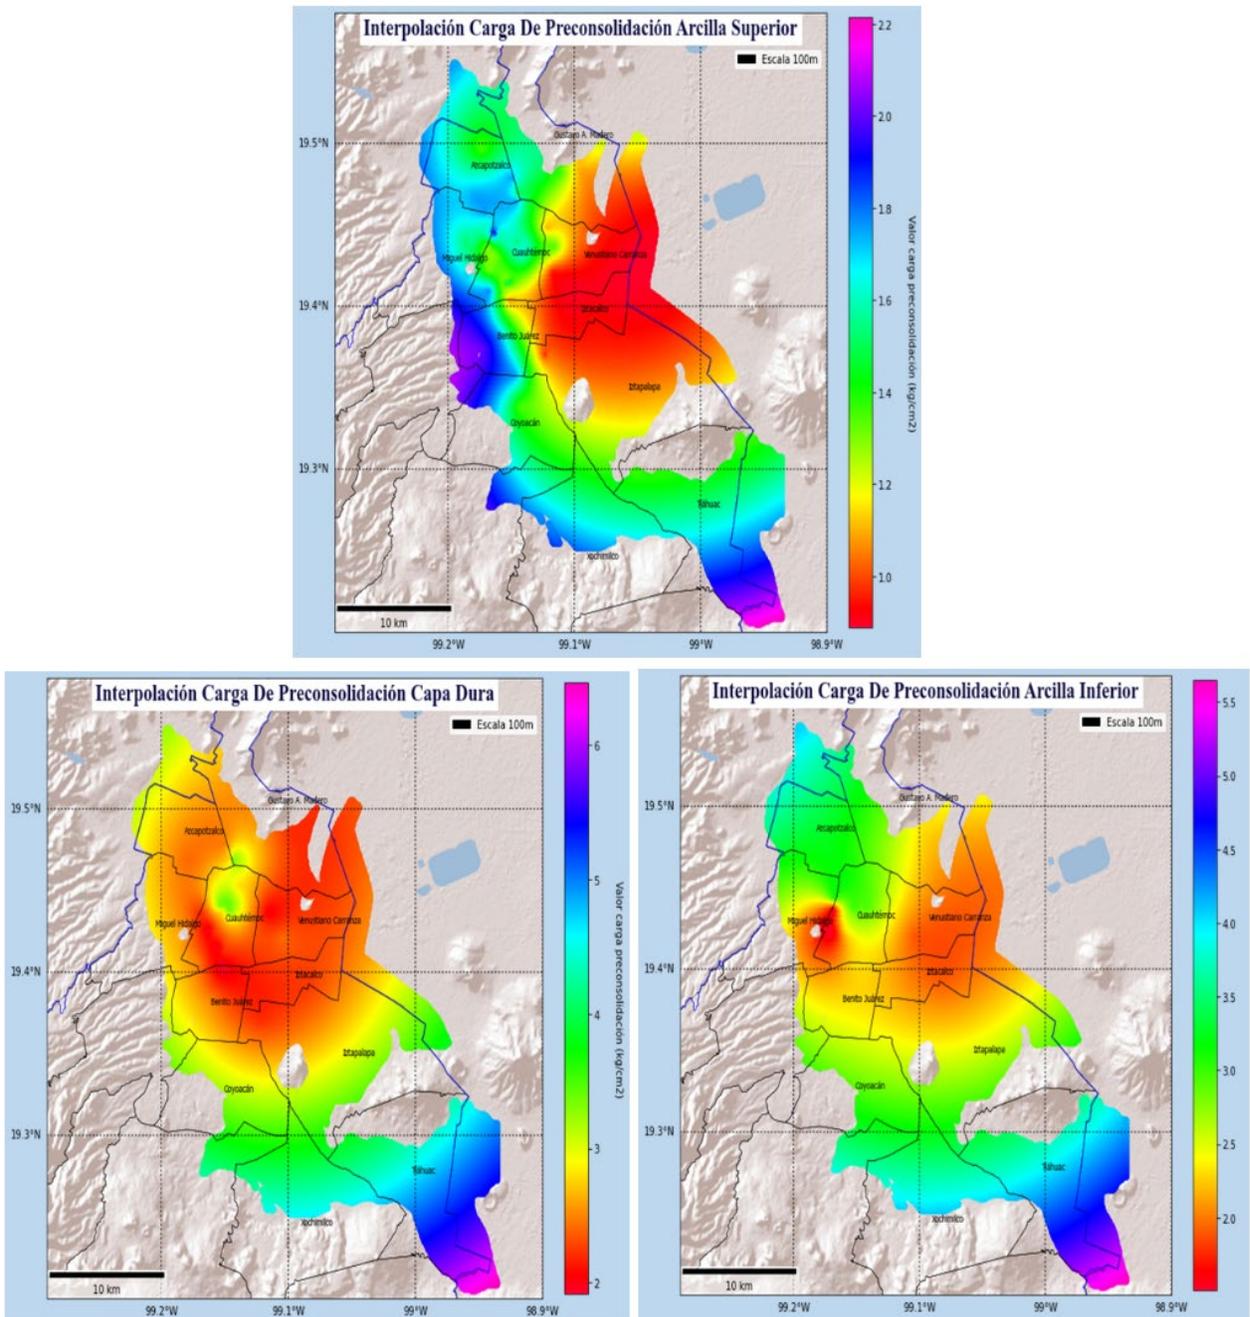


Figura 5-25: Interpolación de la carga de preconsolidación en cada una de las tres formaciones que conforman la hidrofacies A.

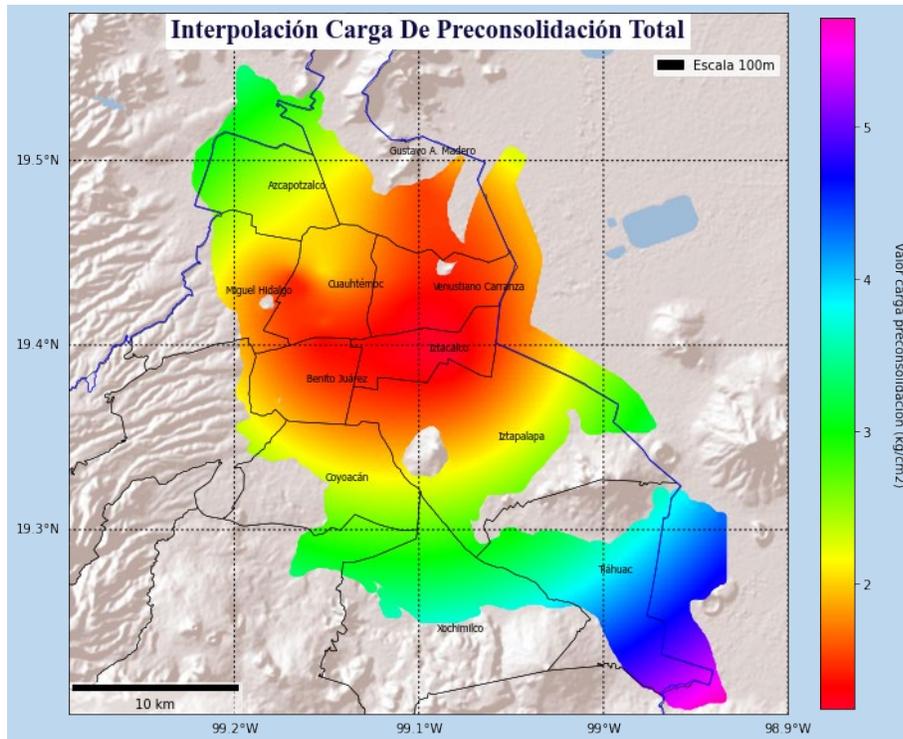


Figura 5-26: Interpolación del promedio ponderado de las cargas de preconsolidación de las tres formaciones por sus espesores.

Para la segunda etapa se reemplaza este predictor por una serie de variables que relacionan tanto el estrés hídrico al que se somete cada punto del terreno, como también la diferencia en la cantidad de construcciones ubicadas espacialmente.

### 5.2.3.1. Unidades socio económicas por localidad

Hace parte de las variables que entran a sustituir la carga de preconsolidación en la segunda etapa del procesamiento. Este conjunto de datos es solamente diseñado para la CDMX, por lo que el área de estudio debió ser modificada en la segunda etapa, a fin de obtener una base de datos uniforme para todos los predictores. La fuente es el servicio web de datos de la CDMX (GOBIERNO\_CDMX, 2021). Este servicio web permite descargar archivos TIFF con varias características medidas por localidades. En el caso de esta propiedad, se agrupan todas las construcciones registradas en las categorías de unidades industriales, unidades de servicio y unidades comerciales. Como los datos son construidos por localidades, cada valor pertenece a un área y no a un punto de una grilla. Para interpolar los datos de forma puntual, los registros

en cada región se dividen por su área, y esta cantidad es la que se le asigna a cada región, luego se sobrepone la grilla con escala 100 m, y el valor de cada punto del dominio corresponderá al valor de la región sobre la que se sitúe dicho punto. El censo que refleja esta página web proviene del año 2010.

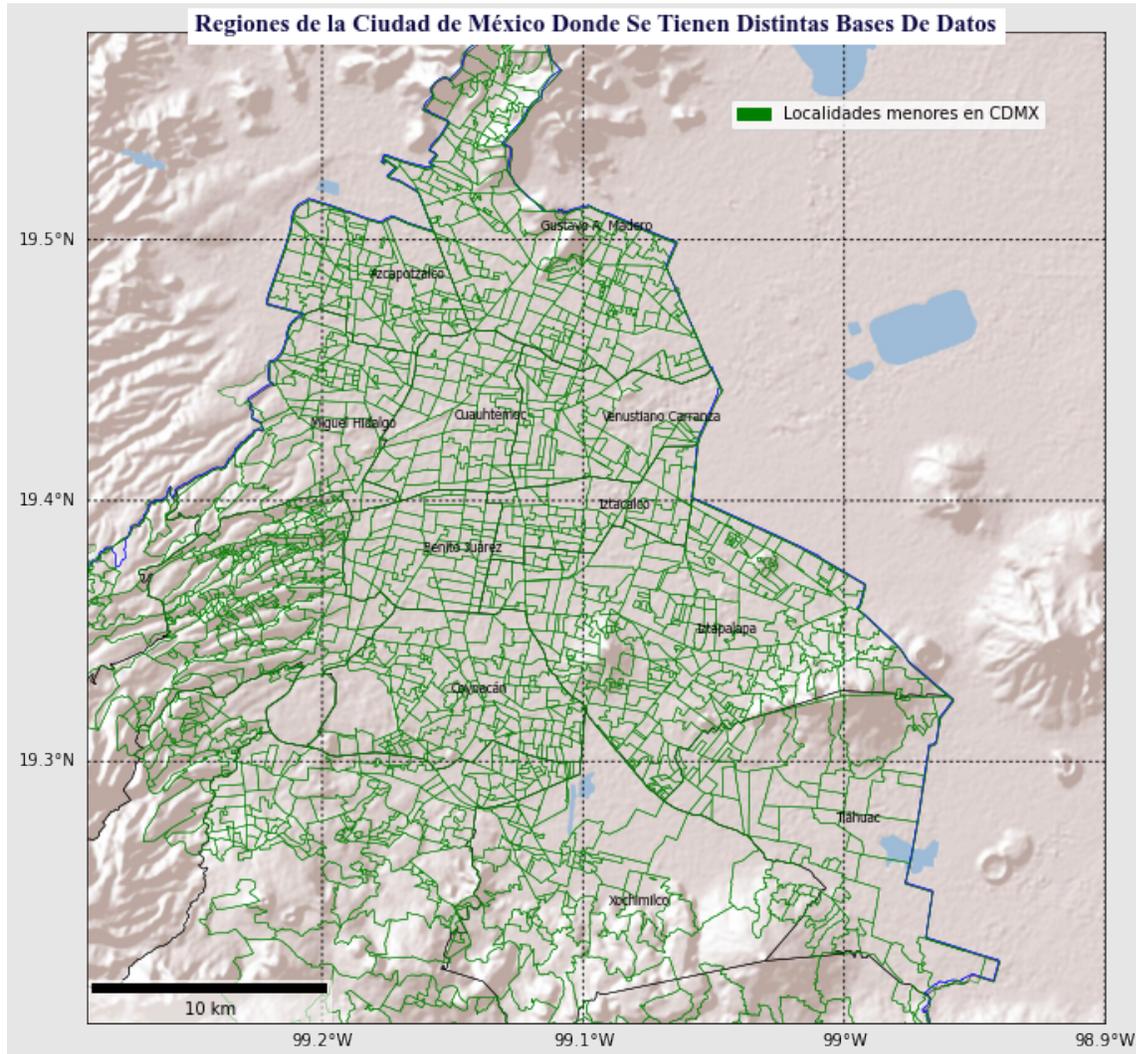


Figura 5-27: Regiones en las que se proveen las diferentes medidas dispuestas por (GOBIERNO\_CDMX, 2021)

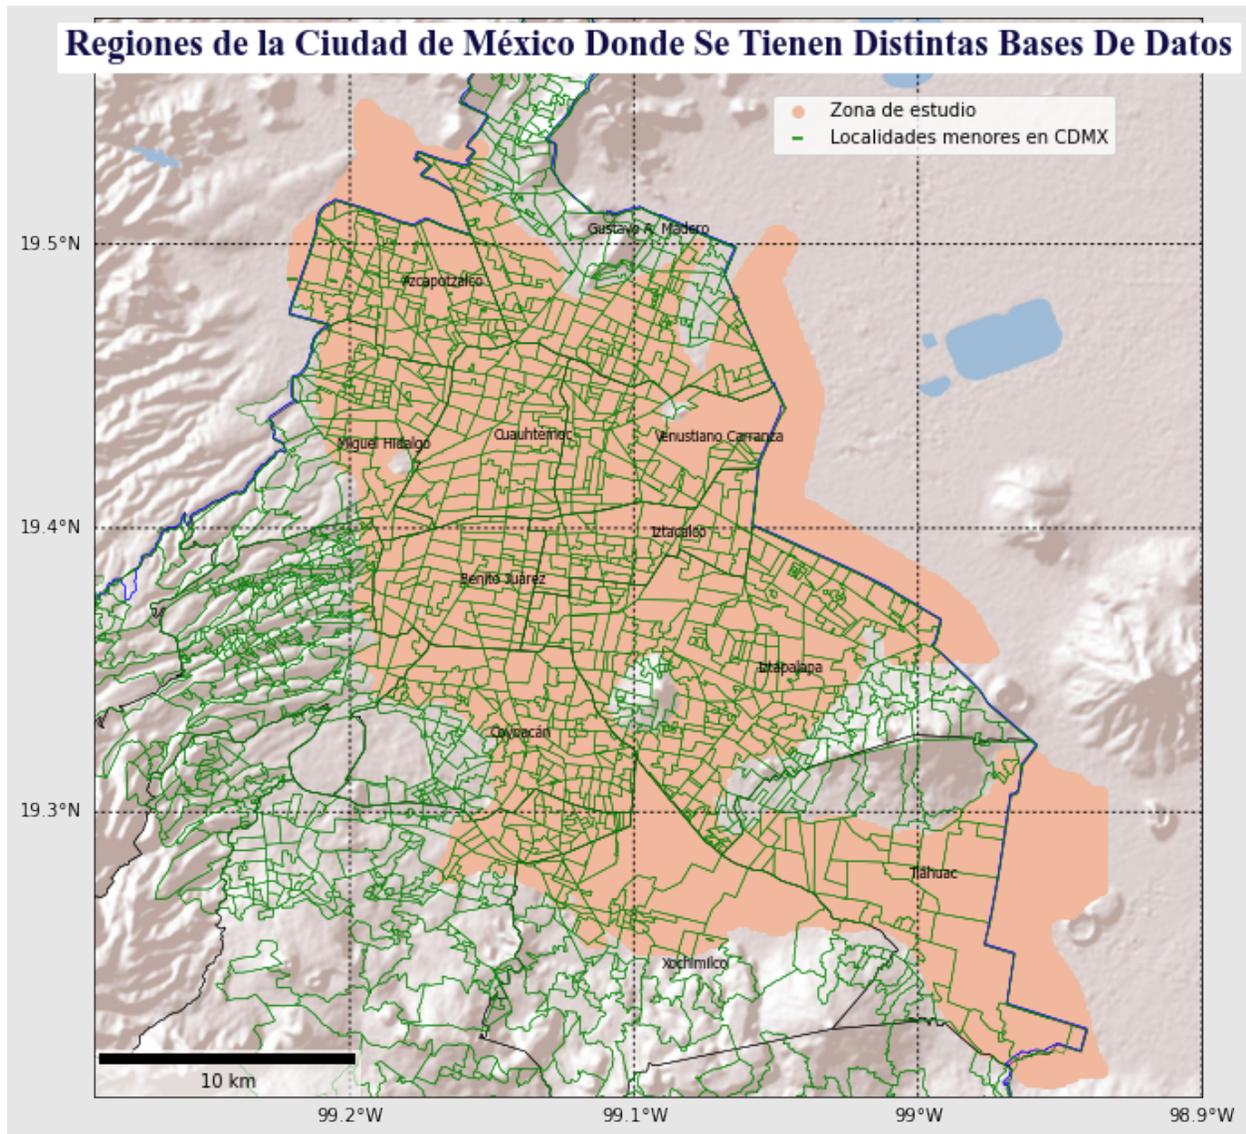


Figura 5-28: En rosado se reproduce la zona de estudio inicial. Con líneas verdes se introducen las zonas en donde se mide el nuevo conjunto de datos que sustituyen a la carga de preconsolidación. La nueva área de estudio es la zona en donde se solapan.

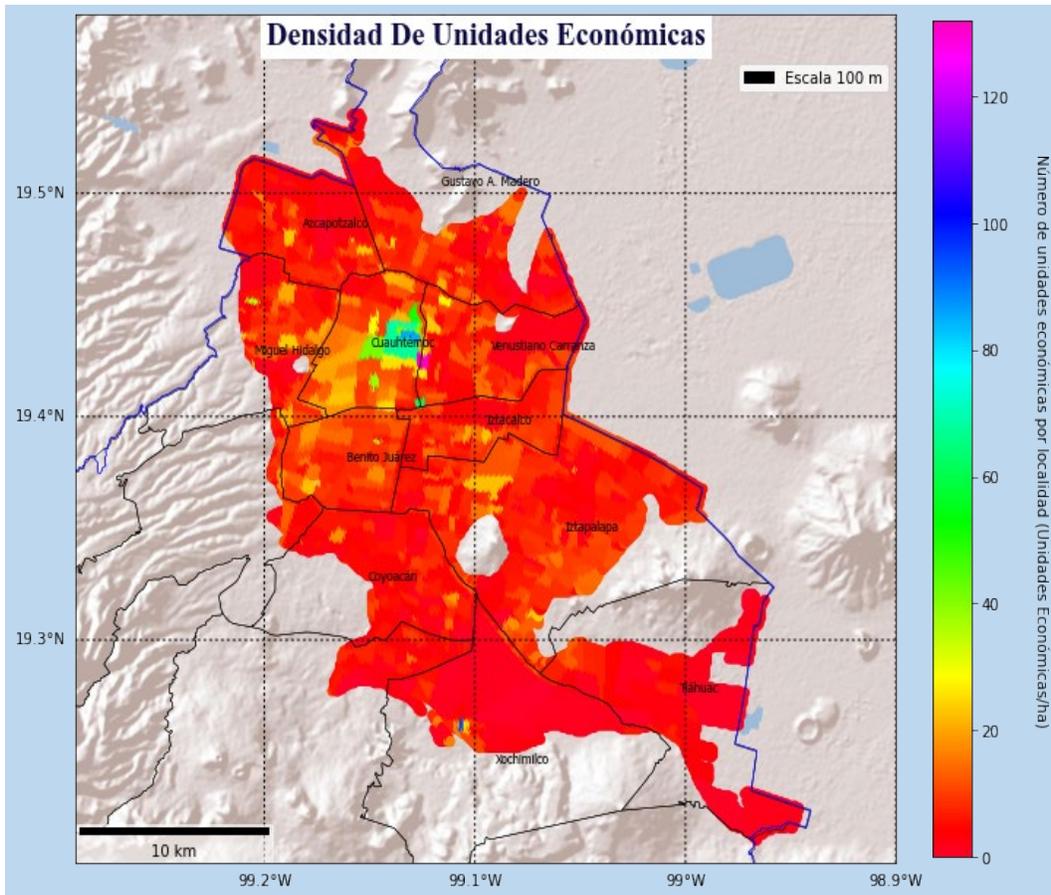


Figura 5-29: Interpolación del valor de las unidades económicas por área en toda la zona de investigación.

### 5.2.3.2. Número de viviendas por localidad

Variable considerada en reemplazo de la carga de preconsolidación. Al igual que las unidades económicas, su origen proviene de la misma fuente y, por tanto, su valor se da por localidades. Describe el número de viviendas censadas en el año 2010. Para interpolar su valor a la escala de 100 m de longitud, se realiza el mismo procedimiento que con la anterior variable, su valor por región es dividido por el área de esta, antes de sobreponer la grilla para extraer los valores.

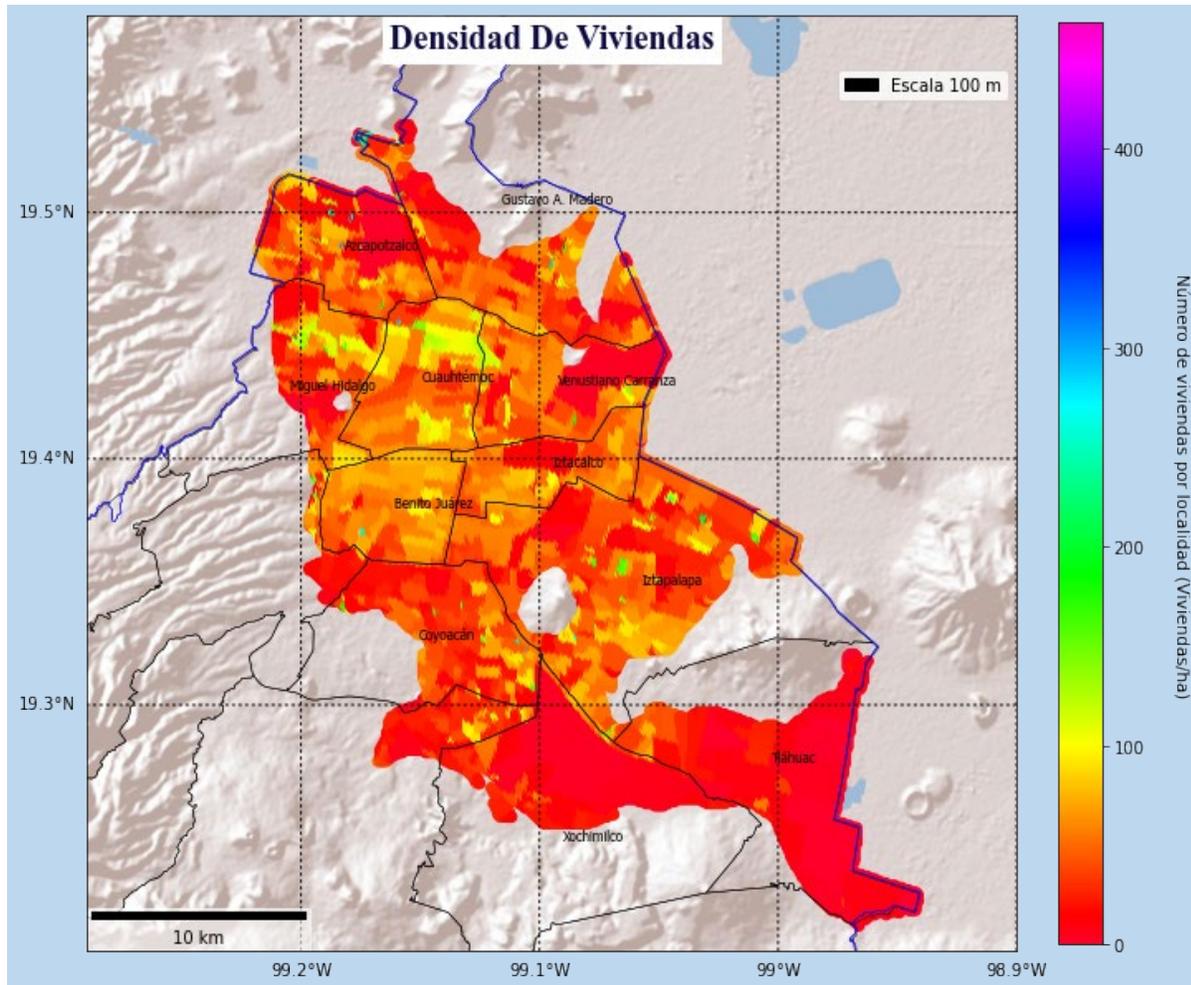


Figura 5-30: Interpolación de la densidad de viviendas en toda la zona de investigación.

### 5.2.3.3. Población por localidad

Hace parte de las variables que reemplazan a la carga de preconsolidación. Especifica la población censada en el año 2010 por cada localidad. Su forma de procesamiento e interpolación es similar al de las anteriores variables.

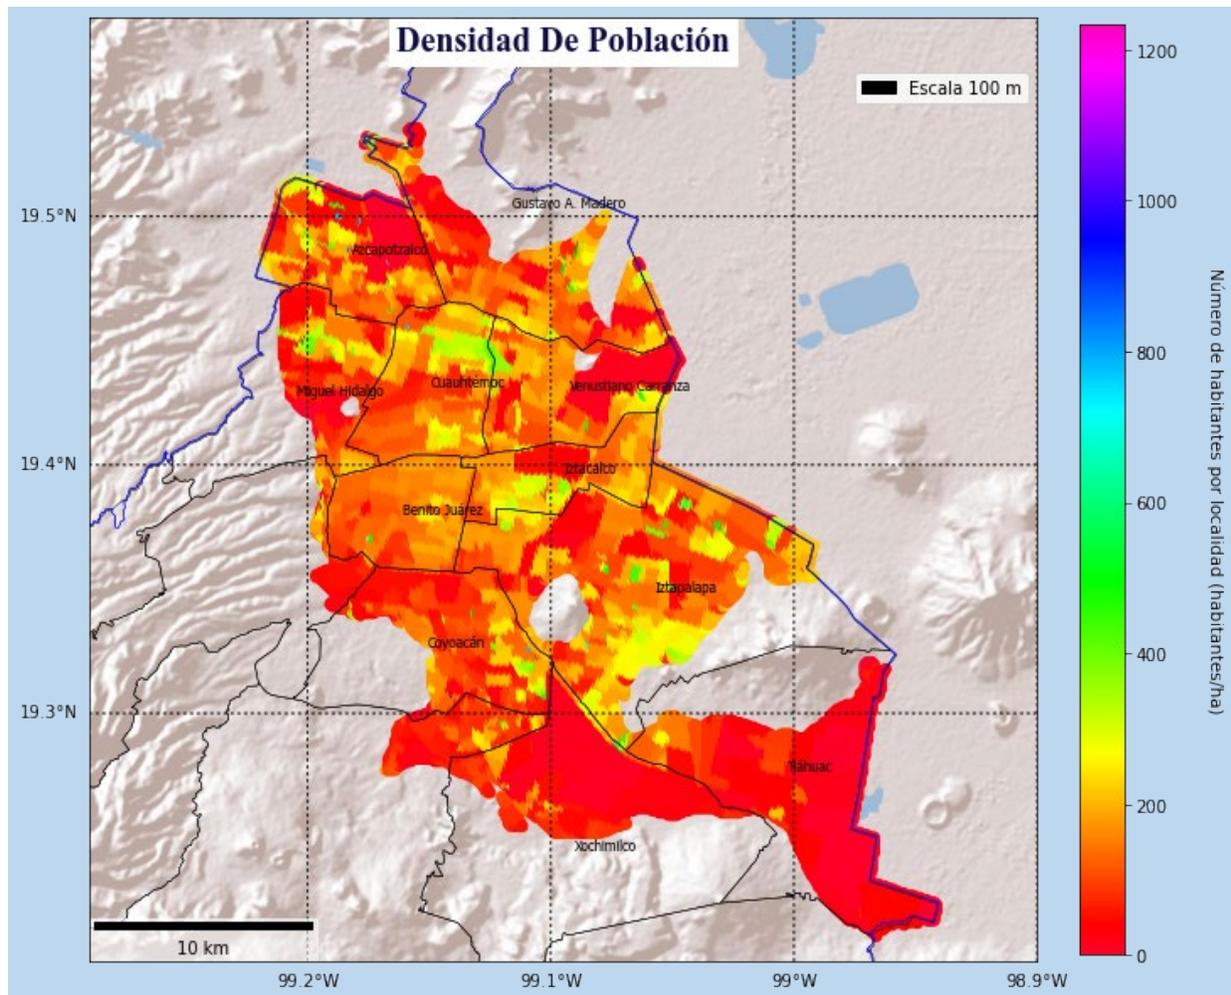


Figura 5-31: Interpolación de la densidad de habitantes en toda la zona de investigación.

#### 5.2.3.4. Áreas verdes por localidad

Pertenece al grupo de variables que reemplazan a la carga de preconsolidación. Denota el área de las zonas verdes en cada localidad. De manera similar, se interpola con la metodología previamente descrita.

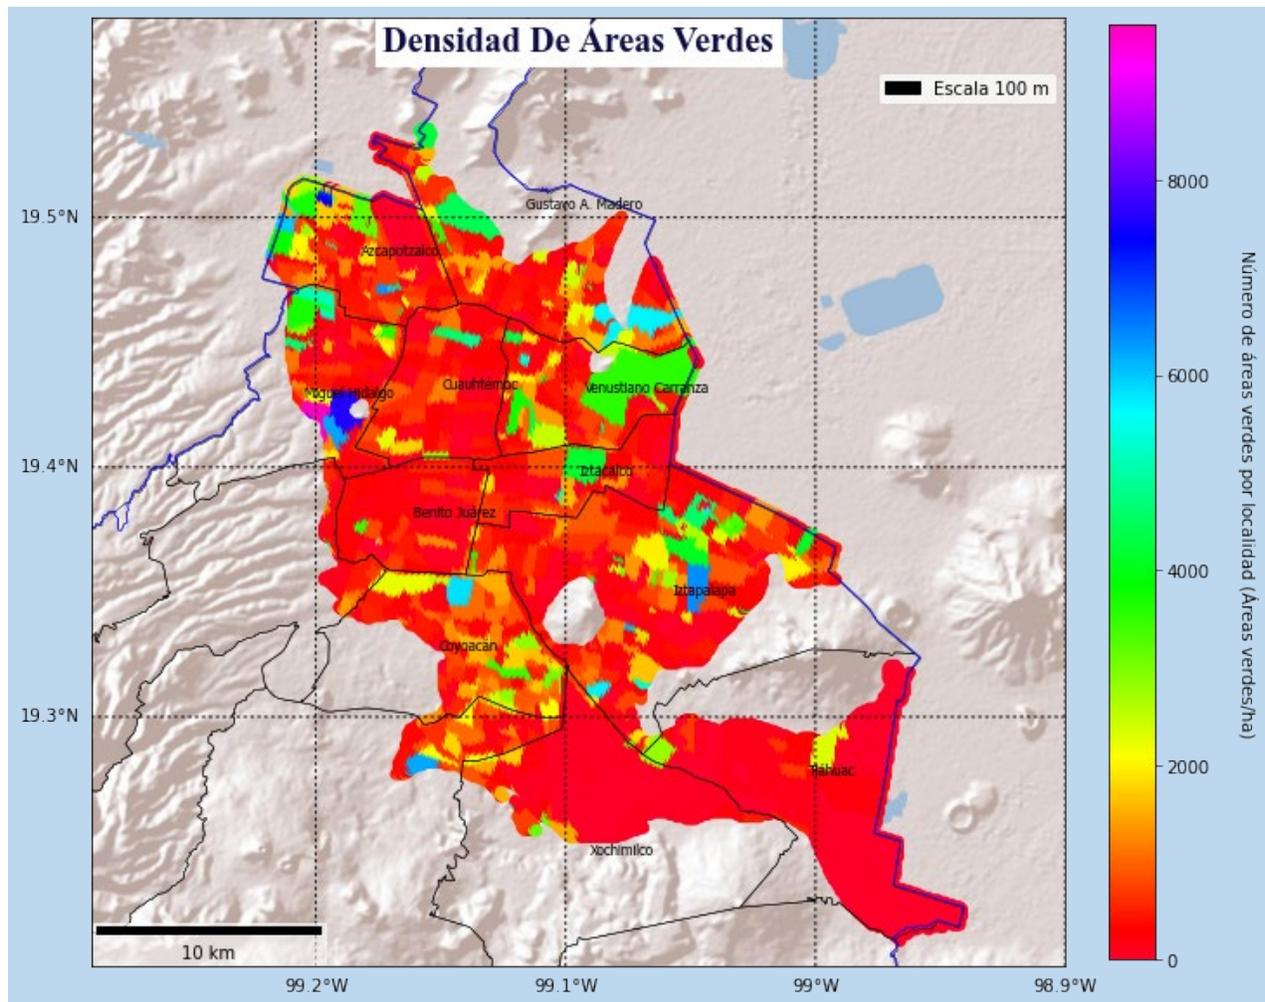


Figura 5-32: Interpolación de la densidad de áreas verdes en toda la zona de investigación.

### 5.2.3.5. Intensidad de lluvia por localidad

Aunque existen otras fuentes que calculan la intensidad de lluvia, a fin de estandarizar los datos, se elige la misma base de datos de las anteriores variables para configurar el conjunto de datos de intensidad de lluvia. Por proceder de la misma aplicación web, las mediciones se dan por localidades. La desventaja en este caso particular es que las cantidades están discretizadas, se da un rango en vez de un valor continuo de la intensidad de lluvia. Se recomienda considerar una fuente de información más completa a fin de mejorar las predicciones. El proceso de interpolación sigue el mismo camino que con las demás variables.

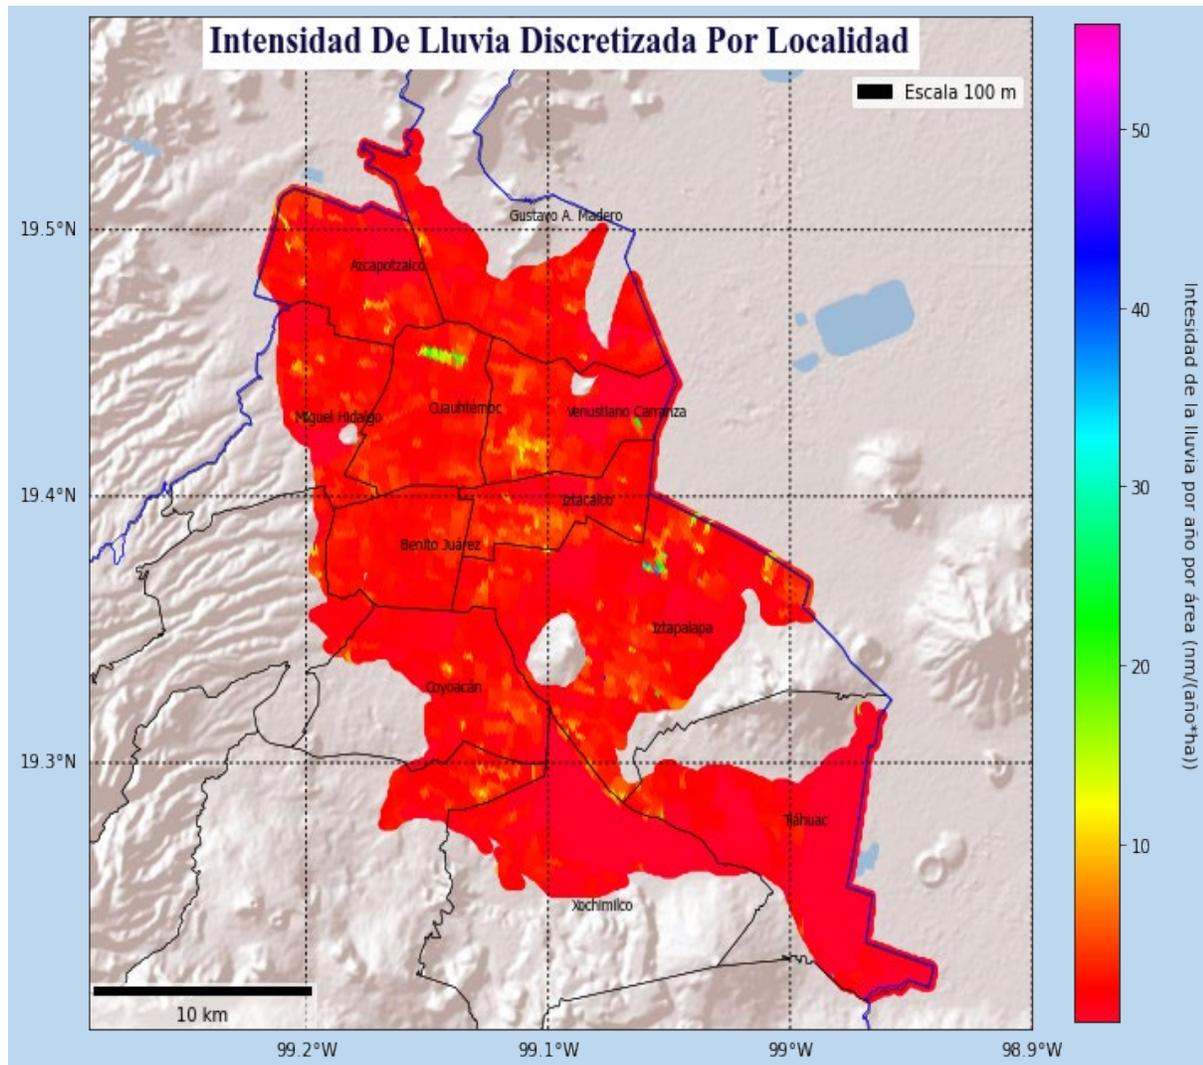


Figura 5-33: Interpolación de la intensidad de lluvia discretizada en toda el área de estudio.

### 5.2.3.6. Caudal de extracción puntual

Es la última de las variables escogidas para sustituir la carga de preconsolidación. La información es extraída del servicio web de la Comisión del agua (REPDA, 2021). La consulta genera una tabla con la ubicación de cada pozo en la ciudad y el caudal de extracción permitido para cada uno. Los datos son interpolados a la zona de estudio, enlazando el caudal de extracción al punto de la grilla más cercano, los demás puntos del dominio se les asigna un valor de caudal cero. La metodología aplicada para esta variable no es la mejor, puesto que cada pozo no solo afecta al punto en donde se construye, sino que, además,

desarrolla un radio de afectación, sin embargo, establecer un radio de afectación para cada pozo, todos con caudales de extracción distintos, algunos incluso con hasta 5 órdenes de magnitud de diferencia, no es una tarea sencilla, impactando los plazos presupuestados para abordar toda la investigación. Se sugiere aplicar un radio de afectación a los pozos, a fin de comprobar las conclusiones que se dan sobre este predictor.

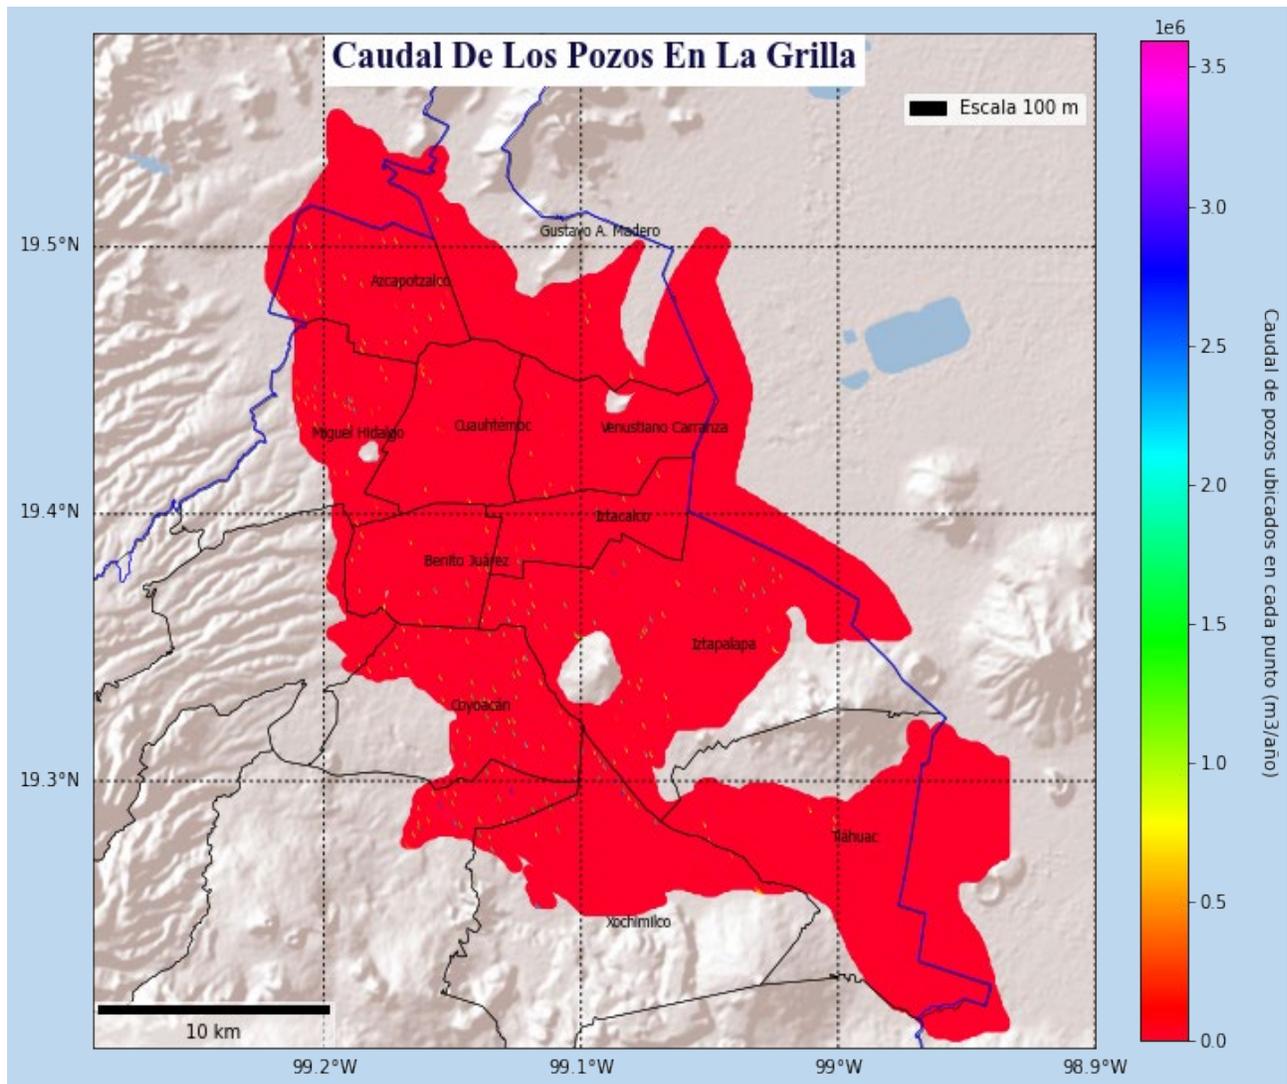


Figura 5-34: Interpolación de los caudales de extracción en toda la zona de investigación.

### 5.2.3.7. Correlaciones

Los modelos de deep learning básicos no aceptan que dos o más variables de entrada mantengan una relación de dependencia lineal. En vista del número elevado de variables que se incorporan al modelo para suplir la carga de preconsolidación, y dado que todas ellas provienen de la misma fuente, y están extensamente enlazadas, es necesario estudiar las correlaciones entre las parejas de este conjunto.

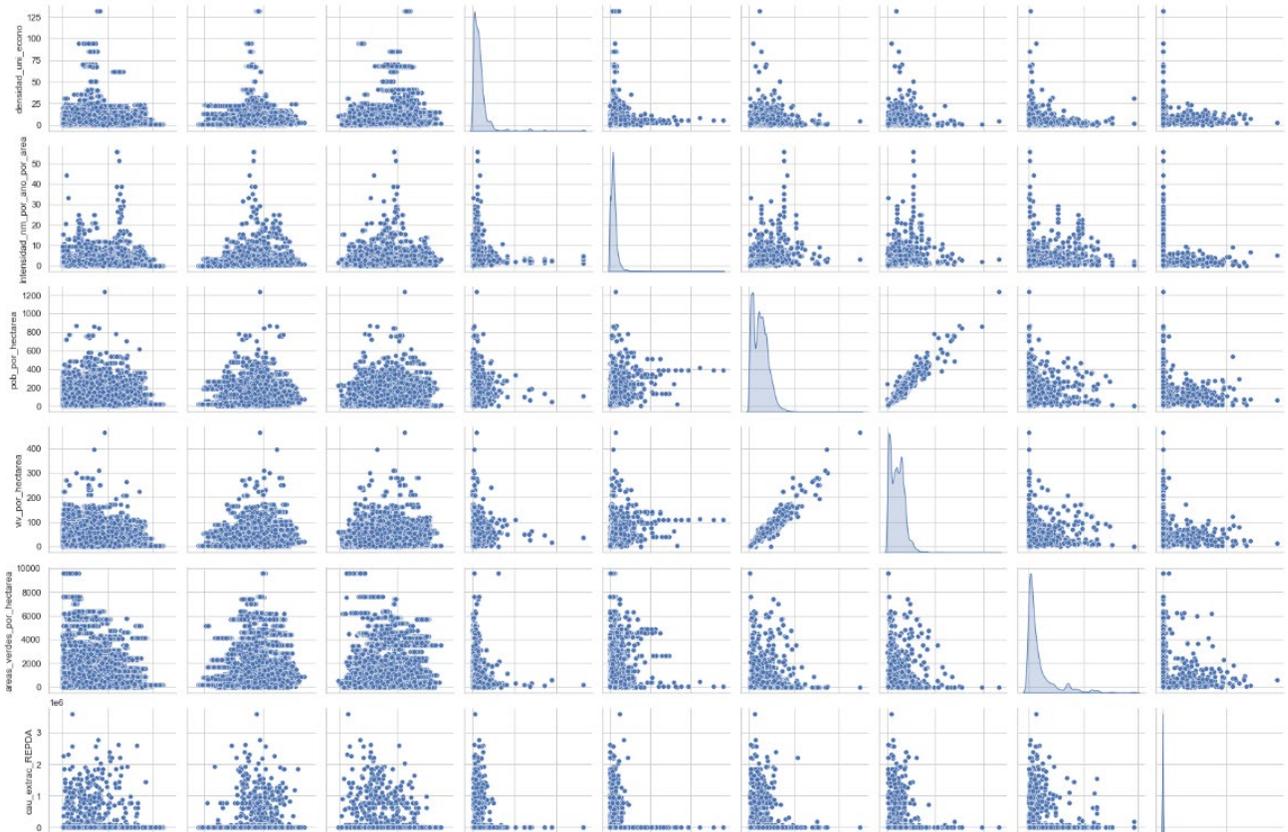


Figura 5-35: Diagrama con múltiples gráficas, cada una representa la relación entre cada par de variables que conforman el grupo sustituto para la carga de preconsolidación

Solo el número de viviendas y la cantidad de habitantes exhiben un comportamiento casi lineal, es por ello, que solo una de las dos variables puede ser anexada al modelo. Las pequeñas variaciones entre ambas puede ser el detonante de una diferencia importante en el modelo de subsidencia, en consecuencia, se entrenarán modelos con ambas variables por separado, y se escogerá el que produzca las mejores estadísticas.

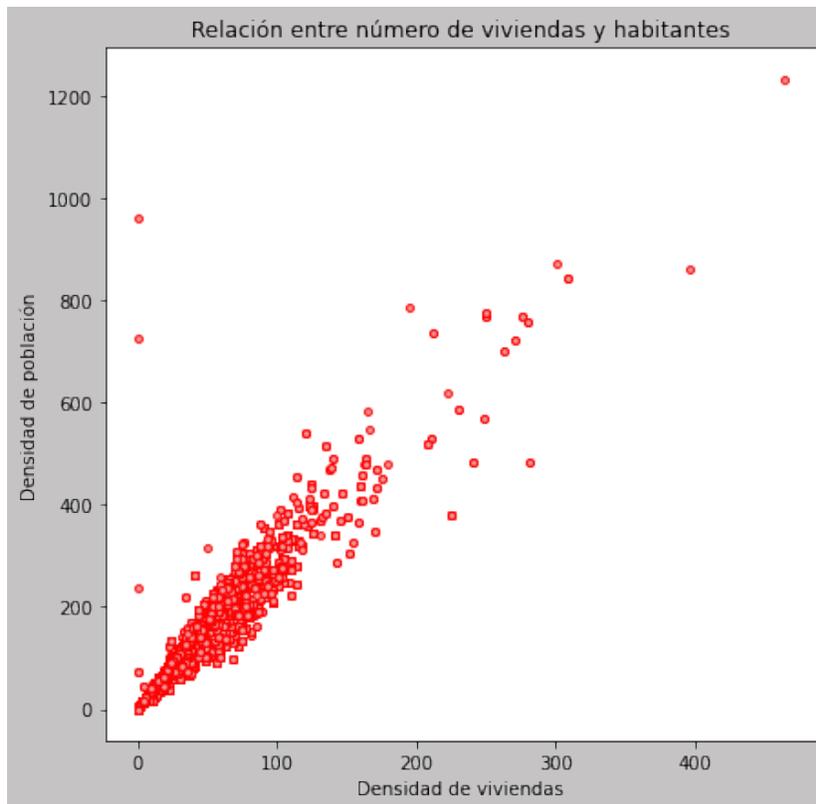


Figura 5-36: Relación entre la densidad de habitantes y la densidad de viviendas.

#### 5.2.4. Litología

Es una variable sugerida en la literatura para reemplazar al coeficiente de compresibilidad. Esta aseveración será puesta a prueba en este trabajo. El conjunto de datos de esta propiedad se construye con el mapa litológico propuesto por (Vazquez & Jaimes, 1989). La escala del mapa es de 1:100.000. Cada unidad litológica se le asigna un número natural distinto antes de ser ingresada a la red neuronal.

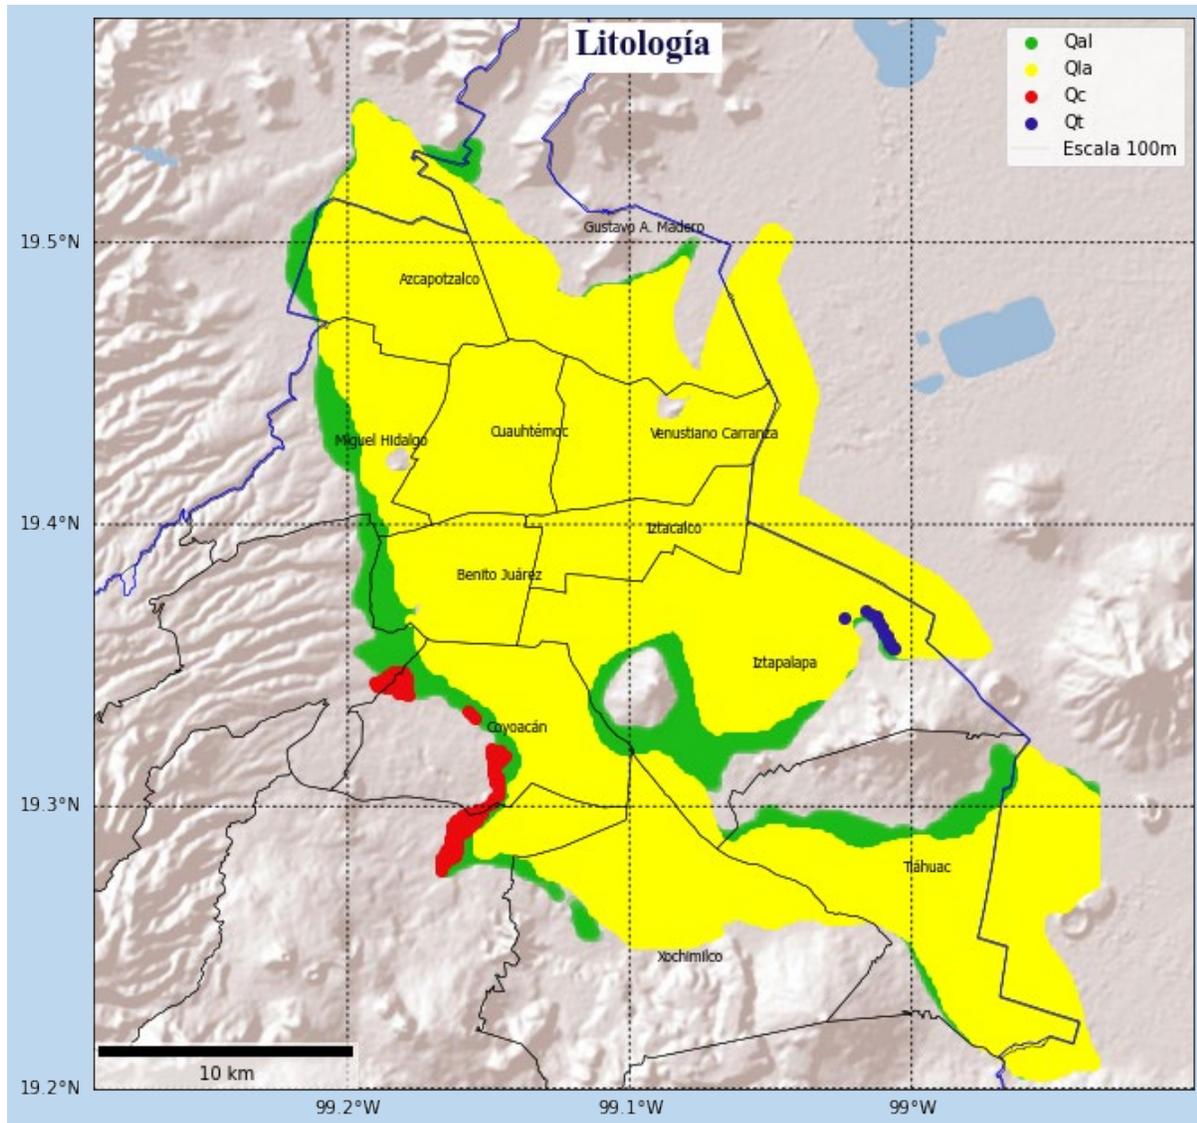


Figura 5-37: Interpolación de la litología en el área de estudio.

### 5.2.5. Abatimiento

Para calcular este predictor se emplea el nivel piezométrico del acuífero superior, este subyace al acuitardo del que hace parte la hidrofacies A. El nivel piezométrico esta medido para una gran parte del Valle de México en los años 1997, 2002, 2007, 2012 y 2017 con escala de 1000 m. Este conjunto de datos es aportado para esta investigación por (Herrera, 2021).

## APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Los abatimientos se computan como las diferencias entre los niveles piezométricos de dos años diferentes, para esta investigación, consecutivos, aunque se podría probar con otra combinación de tiempo en futuras investigaciones.

La interpolación consiste en reducir la escala de los datos a una de 100 m de longitud, de modo que, se hace uso del mismo interpolador bilineal para llevar a cabo la reducción. Esta metodología se percibe como buena debido a la escasa variación entre puntos vecinos del conjunto de datos de abatimientos, no obstante, puede ser importante considerar algunos otros tipos de interpoladores a futuro.

Los abatimientos van a comprender 4 periodos que son: 1997 a 2002, 2002 a 2007, 2007 a 2012 y 2012 a 2017.

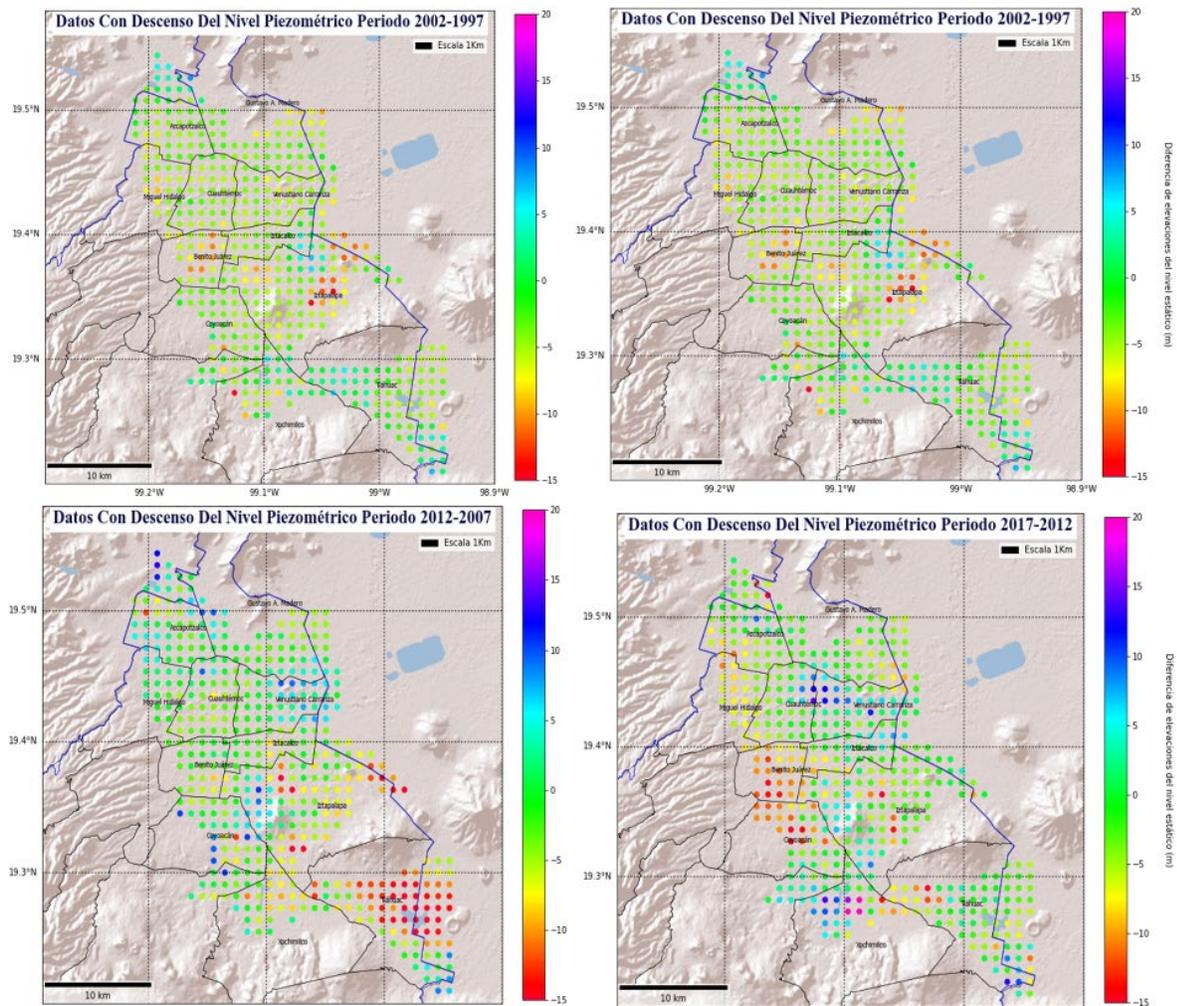


Figura 5-38: Ubicación de los puntos de abatimiento medido en cada periodo de tiempo.

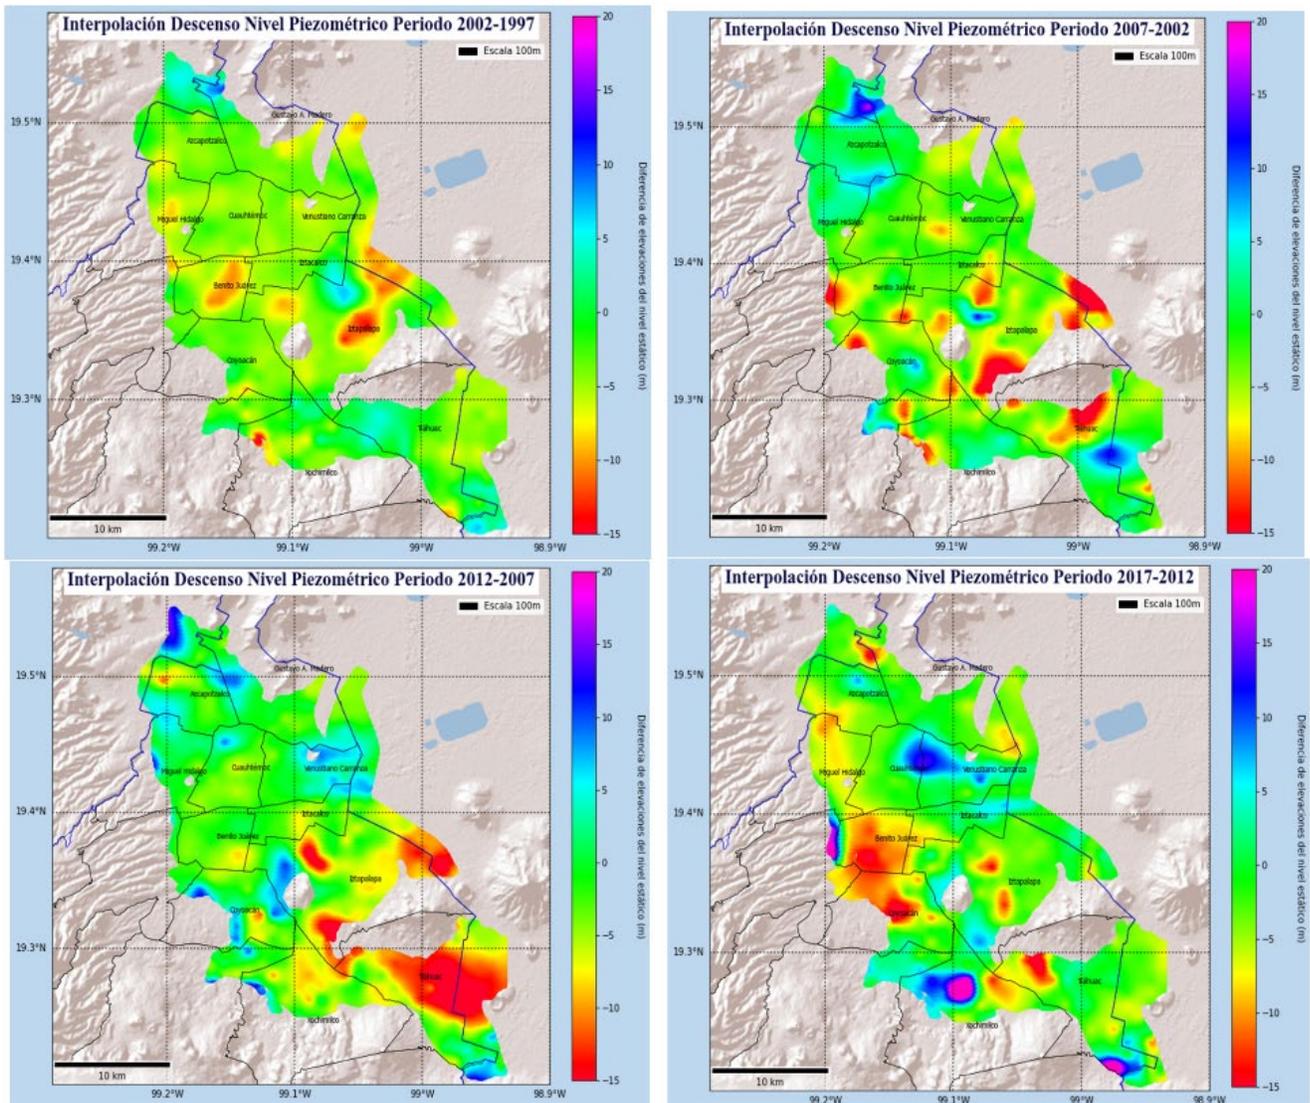


Figura 5-39: Interpolación del abatimiento a escala 100 m en toda el área de estudio.

### 5.2.6. Tasa de hundimiento

La tasa de hundimiento representa la variable de salida del modelo, el valor a predecir, sin embargo, para entrenar el modelo se requiere conocer este valor en algunos puntos del dominio, requisito necesario para un entrenamiento supervisado de una red neuronal.

La tasa de hundimiento se obtiene en la literatura estudiada de datos de GPS o por medio del procesamiento de imágenes satelitales de INSAR. Esta investigación consume información de dos fuentes diferentes, datos de la red de bancos y datos de INSAR.

#### **5.2.6.1. Usando INSAR**

El procesamiento de datos de INSAR (Fernández, y otros, 2022) suministra una malla de valores de velocidad de hundimiento en el Valle de México para el periodo 2014 a 2021. La escala de los datos es de 80 m. Para reescalar la variable a la grilla de 100 m se hace uso de un interpolador lineal. Los demás puntos que no hacen parte del área de investigación son desechados. El modelo que resultará luego de entrenar la red no solo predice el valor de subsidencia en la zona de estudio, producto que ya proporciona el procesamiento con INSAR, sino que, además, cuantifica el peso de cada variable en el modelo. La predicción de subsidencia con redes neuronales puede ser una buena alternativa para complementar a la técnica INSAR en las zonas donde las condiciones climáticas impiden obtener buenos resultados. Incluso puede ser considerada la primera opción, gracias a su rápido despliegue, si ya fue entrenada, y a una posible mejora en la precisión, esto dependerá de cómo se entrene, de la calidad de los datos de entrada y de qué fuente se use para calibrar el modelo, las mejores resoluciones se alcanzan con datos de GPS.

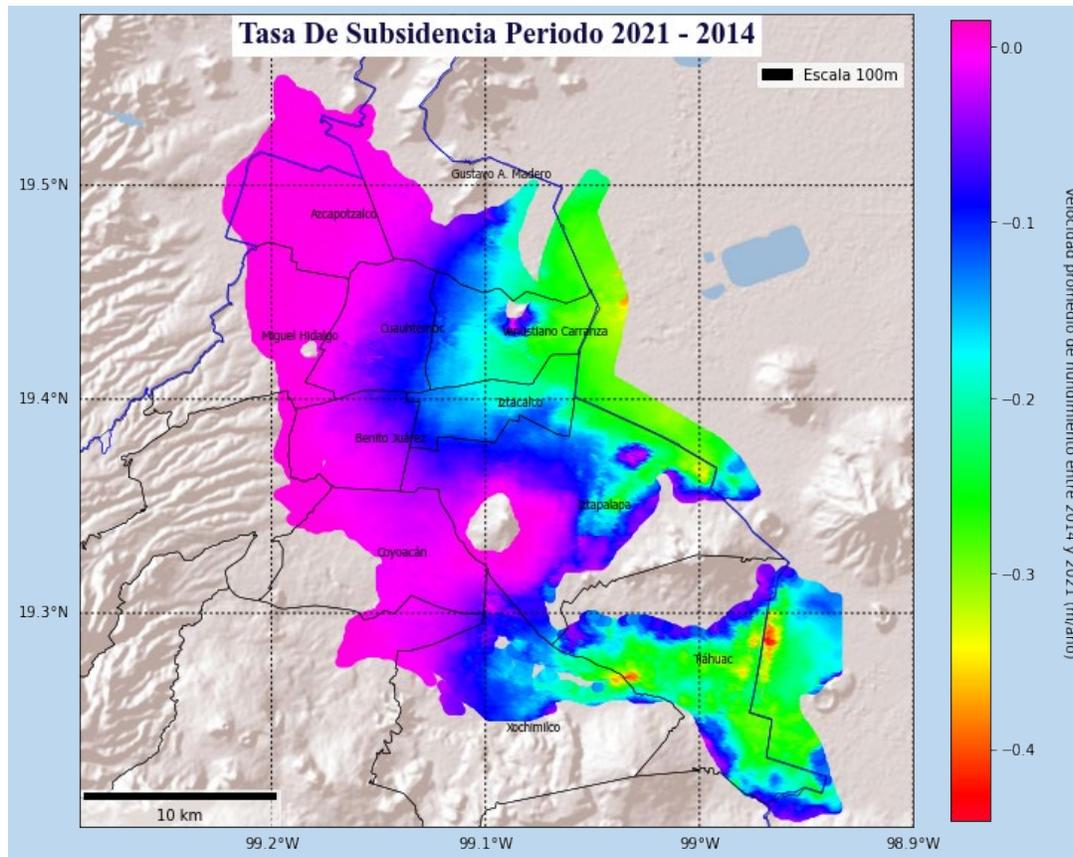


Figura 5-40: Interpolación de la velocidad de hundimiento sobre el área de estudio a escala 100 m. Se obtiene de datos de INSAR.

### 5.2.6.2. Usando la red de Bancos

El sistema de Evolución del Hundimiento y Espectros de Diseño Sísmico (SEHEDIS) implementó un aplicativo web con la base de datos de los bancos con que cuenta la CDMX. Con la información de estos bancos (Libertad, 2018) analizó el comportamiento del hundimiento en cada banco y propuso una serie de funciones para cada uno. La base de datos producto del anterior trabajo es facilitada para esta investigación (Libertad, 2021). En cada banco se tienen registros de los niveles superficiales del terreno en varios años, no obstante, como las medidas del abatimiento solo se recopilaron para años después de 1997, los únicos años de interés son los posteriores a dicha fecha, estos son: 2000, 2002, 2005, 2007 y 2016. Los años 2020, 2025, 2030 y 2035 también se tienen en cuenta, aunque sus registros no provienen de mediciones directas sino de las predicciones de (Libertad, 2018). Las tasas de hundimiento se calculan al restar los niveles superficiales de pares de años consecutivos y dividirlo por el tiempo, este proceso se

computa en cada base de datos de cada banco. Finalmente, se interpolan los datos a la escala de 100 m empleando un interpolador lineal. Al tener varios periodos de hundimiento, y no solo uno como sucede con los datos de INSAR, es posible calibrar de mejor manera el retardo. Esta fuente también es útil para analizar la subsidencia de manera temporal al poder encontrar para cada periodo de abatimiento, el correspondiente periodo de hundimiento sobre el que se tiene mayor influencia.

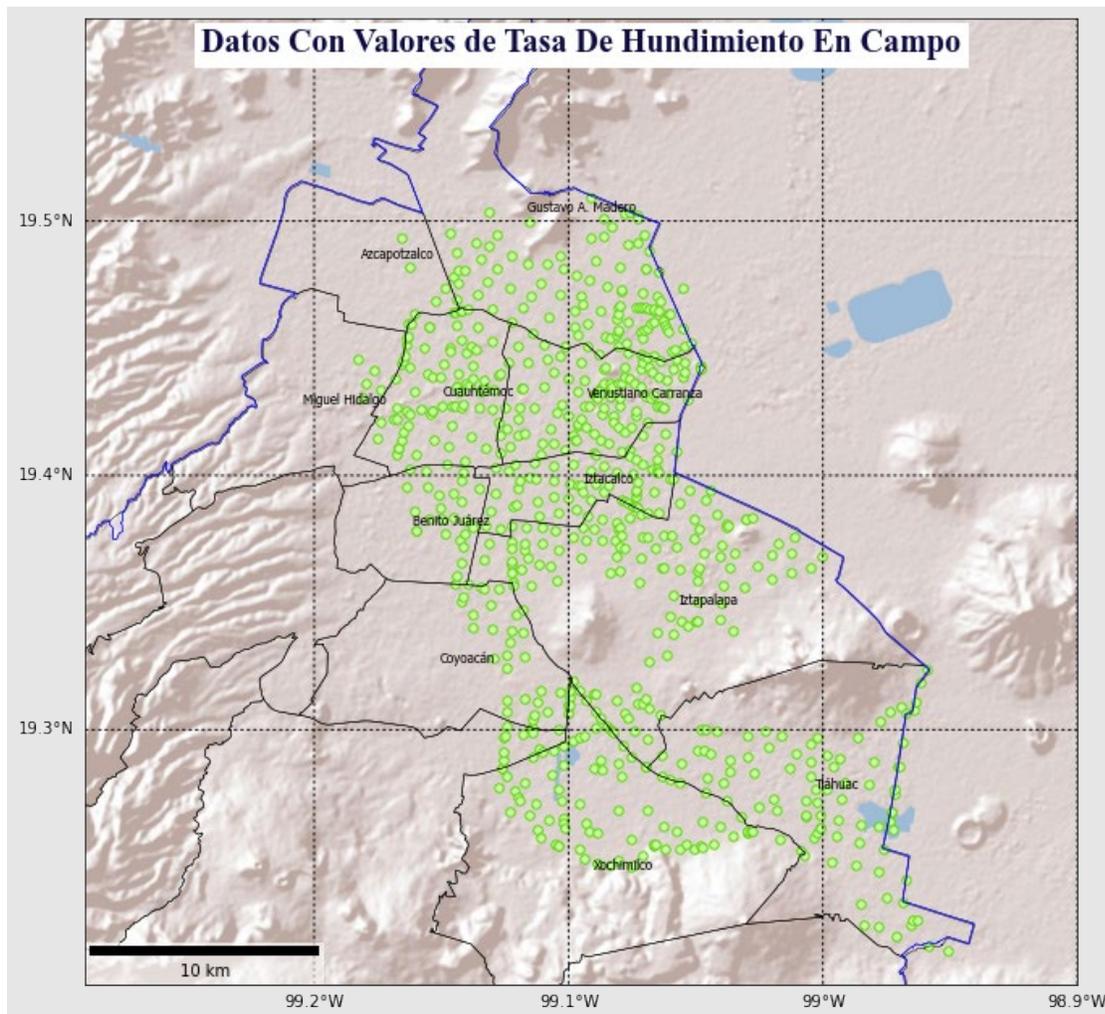


Figura 5-41: Ubicación de los bancos con medidas de hundimiento disponibles.

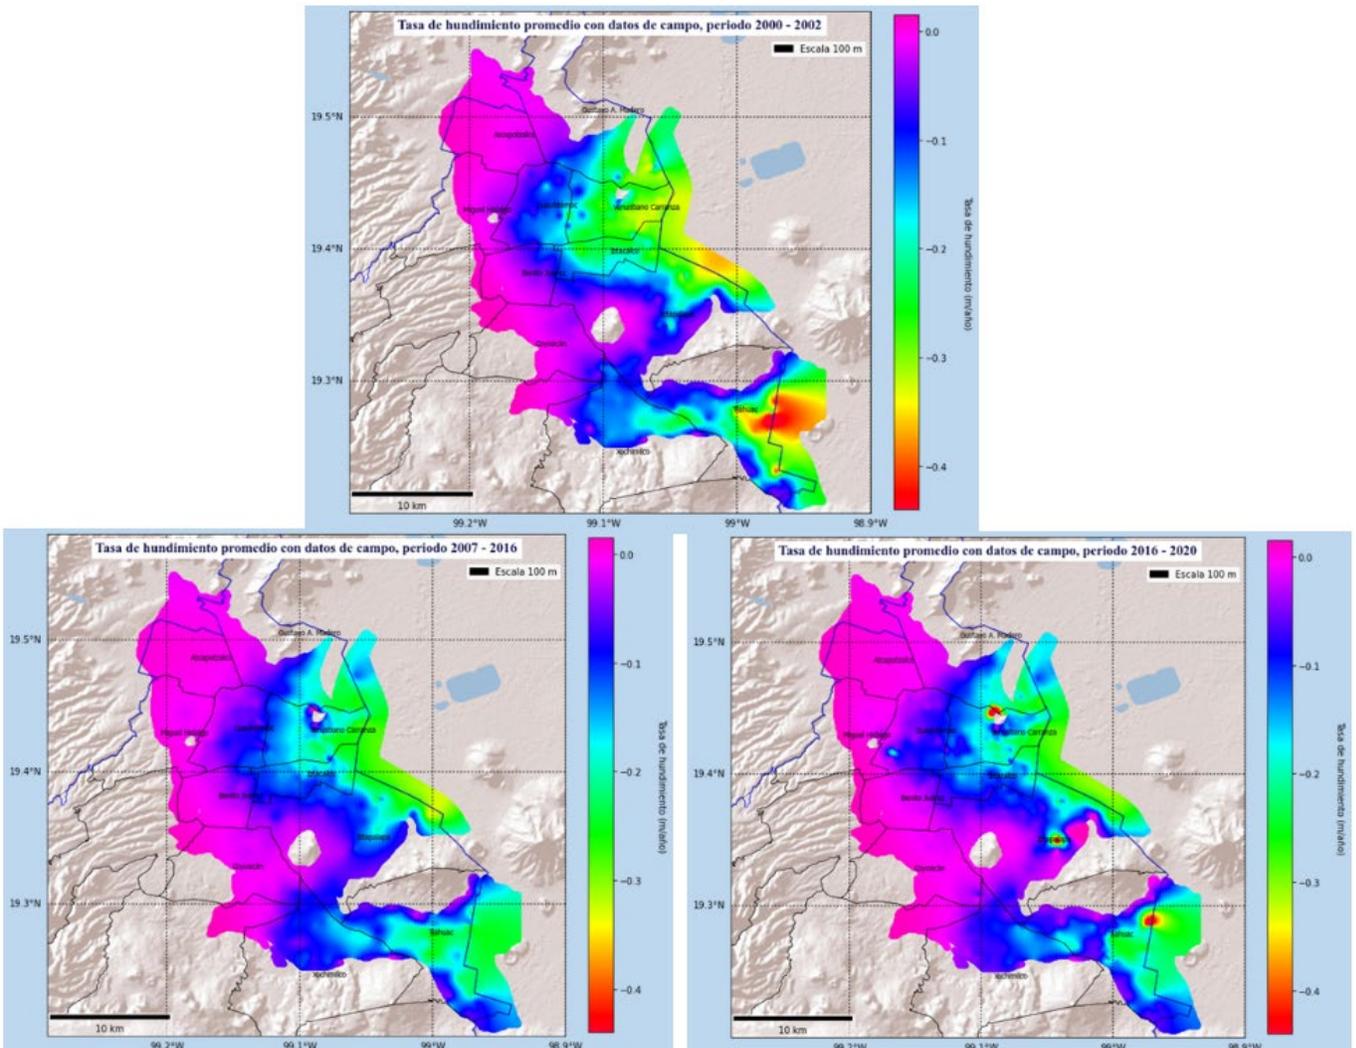


Figura 5-42: Interpolación de la tasa de hundimiento usando la información de la red de bancos. Se grafican los valores para los periodos 2000 - 2002, 2007-2016 y 2016-2020. Los periodos 2002-2005, 2005-2007, 2020-2025, 2025-2030 y 2030-2035 no se grafican por simplicidad.

### 5.2.7. Retardo

El retardo debería ser, como los demás predictores, un valor por cada elemento del dominio, sin embargo, se requiere conocer los parámetros hidráulicos del terreno en cada punto, y luego aplicar alguna ecuación que calcule el retraso, información no disponible en toda la región.

Esta problemática se afronta en toda la literatura consultada de la misma manera, se toma un solo valor de retraso para todo el dominio. Todas las variables de entrada temporales, para nuestro caso, solo el

abatimiento, se evalúan en un mismo periodo de tiempo, por otro lado, la variable de calibración, tasa de hundimiento, se computa en un periodo de tiempo posterior; la diferencia entre estos dos lapsos de tiempo es lo que se fija como la magnitud del retraso, un valor que debe ser calibrado.

Aunque se postula al abatimiento como la única variable de entrada con un componente temporal, otras variables como la carga de preconsolidación, el espesor y el coeficiente de compresibilidad también pueden exhibir mínimos a moderados cambios a lo largo del tiempo, pese a esto, no es posible tener en cuenta estos cambios debido a la falta de bases de datos en diferentes años. Se espera que el impacto de esta simplificación no afecte significativamente al modelo, suponiendo que las variaciones en estas otras propiedades son mucho menores.

#### **5.2.7.1. Usando tasa de hundimiento promedio**

En la primera etapa de los resultados se calibran los modelos con los datos de INSAR. Este conjunto de datos solo contiene un periodo de tiempo que va del 2014 a 2021. Por otro lado, la base de datos de los abatimientos cuenta con cuatro periodos: 1997 a 2002, 2002 a 2007, 2007 a 2012 y 2012 a 2017. Para calcular el retraso se toma el valor medio de cada franja temporal tanto de las variables de entrada como la de salida, enseguida, se resta el valor medio del periodo de la tasa de hundimiento con respecto a cada valor medio del periodo de abatimiento, los valores producidos forman el arreglo de posibles opciones para el retraso homogéneo de toda la zona.

Con base en el funcionamiento de los algoritmos de machine learning, el periodo del abatimiento que produce el modelo con el mejor rendimiento es el que más influye en las observaciones del hundimiento del único intervalo temporal entrenado, en consecuencia, será este periodo del abatimiento el que establezca el valor del retraso. Una red neuronal es desplegada para cada opción del abatimiento con el fin de llevar a cabo la validación del mejor modelo.

Tabla 5-2: Retrasos según la temporalidad de los predictores, en nuestro caso solo es el abatimiento, y la variable a predecir, la tasa de hundimiento. La base de datos de hundimientos procede de INSAR

predictores	tasa de hundimiento	retraso
1997-2002	2014-2021	18
2002-2007	2014-2021	13
2007-2012	2014-2021	8
2012-2017	2014-2021	3

#### 5.2.7.2. Usando tasa de hundimiento por intervalos

Al hacer uso de la base de datos de la red de bancos, 5 intervalos temporales se consiguen para la tasa de hundimiento. Bajo la premisa de que cada periodo del abatimiento solo tiene su máxima influencia en un periodo del hundimiento, es necesario iterar cada base de datos del abatimiento contra cada una del hundimiento, de esta forma, un retraso es calibrado para cada periodo del abatimiento. Al final, y suponiendo que las propiedades de las rocas que componen la ciudad permanecen casi constantes en estos pocos años, todos los retrasos calibrados deben ser similares. Una respuesta más exacta se esperaría si se tuvieran más periodos del abatimiento y del hundimiento en intervalos regulares. En el proceso de iteración, solo se examinan los periodos de hundimiento con un valor medio superior al valor medio del periodo de abatimiento que se esté analizando. Por falta de datos de hundimiento en años recientes, el último periodo del abatimiento no es integrado en este ciclo.

## APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

---

Tabla 5-3: Retrasos según la temporalidad de los predictores, en nuestro caso solo es el abatimiento, y la variable a predecir, la tasa de hundimiento. La base de datos de hundimientos procede de la red de bancos.

predictores	tasa de hundimiento	retraso
1997-2002	2000 -2002	1.5
	2002-2005	4
	2005-2007	6.5
	2007-2016	12
	2016-2020	18.5
2002-2007	2005-2007	1.5
	2007-2016	7
	2016-2020	13.5
	2020-2025	18
	2025-2030	23
2007-2012	2007-2016	2
	2016-2020	8.5
	2020-2025	13
	2025-2030	18
	2030-2035	23

## 6. RESULTADOS

### 6.1. ETAPA 1

En la primera fase de entrenamiento se persigue responder:

- Cuál de las dos escalas, 100 m o 1000 m, es la que produce los mejores resultados.
- Entre la litología, los coeficientes de compresibilidad por capas o su ponderado, cuál es el mejor predictor para describir las propiedades de la roca.
- Cuál es la mejor estrategia para representar el historial de esfuerzos en las rocas de la zona, la carga de preconsolidación por capas o su ponderado.
- Cuál es el intervalo temporal del abatimiento que más influye en los hundimientos promedio calculados usando INSAR y originados entre 2014 y 2021.

Las bases de datos que guiarán el proceso de acondicionamiento de todos los modelos son, el espesor de la hidrofacies A, los abatimientos en sus cuatro periodos, los coeficientes de compresibilidad en cada formación y su ponderado, la carga de preconsolidación en cada formación y su ponderado, y, para calibrar el modelo, los datos de INSAR. Los retardos son los descritos en la Tabla 5-2. La hidrofacies A destinada para esta etapa es la que se predice con el modelo básico que no hace uso de la litología, esto con el fin de dejar libre a esta variable para que pueda formar parte de los predictores en la red que modela subsidencia.

La primera serie de redes entrenadas se construyen con los datos escalados en una malla de 1000 m, los parámetros e hiperparámetros de la red se sintetizan en la tabla 6-1.

Tabla 6-1: Parámetros con los que se diseñan las redes neuronales en la primera etapa

Parámetros en la red	
Parámetro	Valores posibles
Número de capas	3
Neuronas por capas	64,8,1
función de pérdida	mse
Alg. Optimización	Adam
Normalización	Batch o estándar
Épocas	2000 a 5000
set train - validación	80% - 10%
set test	10%

## APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Un subconjunto de estas redes se elige para inspeccionar el comportamiento del modelo al elegir el coeficiente de compresibilidad por capas, el coeficiente de compresibilidad ponderado o la litología, las demás variables permanecen fijas, elegidas al azar entre una de sus opciones. Algunas bases de datos en esta primera etapa no son confiables para latitudes menores a 19.36°N, todos estos registros son producto de una extrapolación o una interpolación con muy pocas medidas, por tanto, se descartan en las redes de esta primera etapa.

Tabla 6-2: Descripción de todas las bases de datos empleadas para entrenar la red.

Red escala 1000 m para determinar mejor predictor para coef. Compresibilidad		
Variable	descripción	latitud
Esesor	Hidrofacies A	> 19.36°N
Abatimiento	periodo 1997 a 2002	
coef. Compresibilidad	Total, separado o litología	
carga preconsolidación	Total	
Tasa hundimiento	periodo 2014 a 2021	

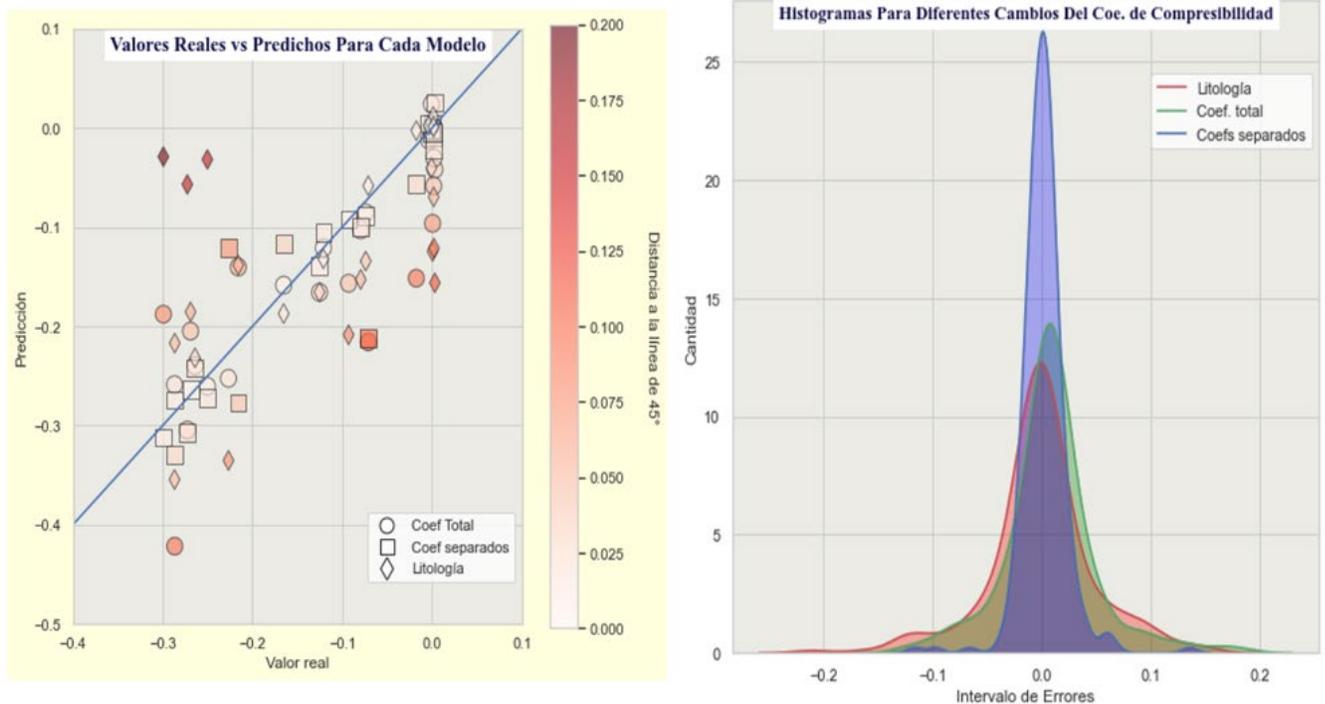


Figura 6-1: Comportamiento de los valores reales contra los predichos (a la izquierda), y de las diferencias en la predicción (derecha).

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Los modelos que incorporan los coeficientes de compresibilidad por capas ostentan las mejores estadísticas, en contraste, la litología reproduce los más pobres resultados.

Partiendo de la conclusión previa, se separa un subgrupo de redes para evaluar las alternativas para la carga de preconsolidación.

Tabla 6-3: Descripción de todas las bases de datos empleadas para entrenar la red.

Red escala 1000 m para determinar mejor predictor para carga preconsolidación		
Variable	descripción	latitud
Espesor	Hidrofacies A	> 19.36°N
Abatimiento	periodo 1997 a 2002	
coef. Compresibilidad	separado	
carga preconsolidación	Total o separado	
Tasa hundimiento	periodo 2014 a 2021	

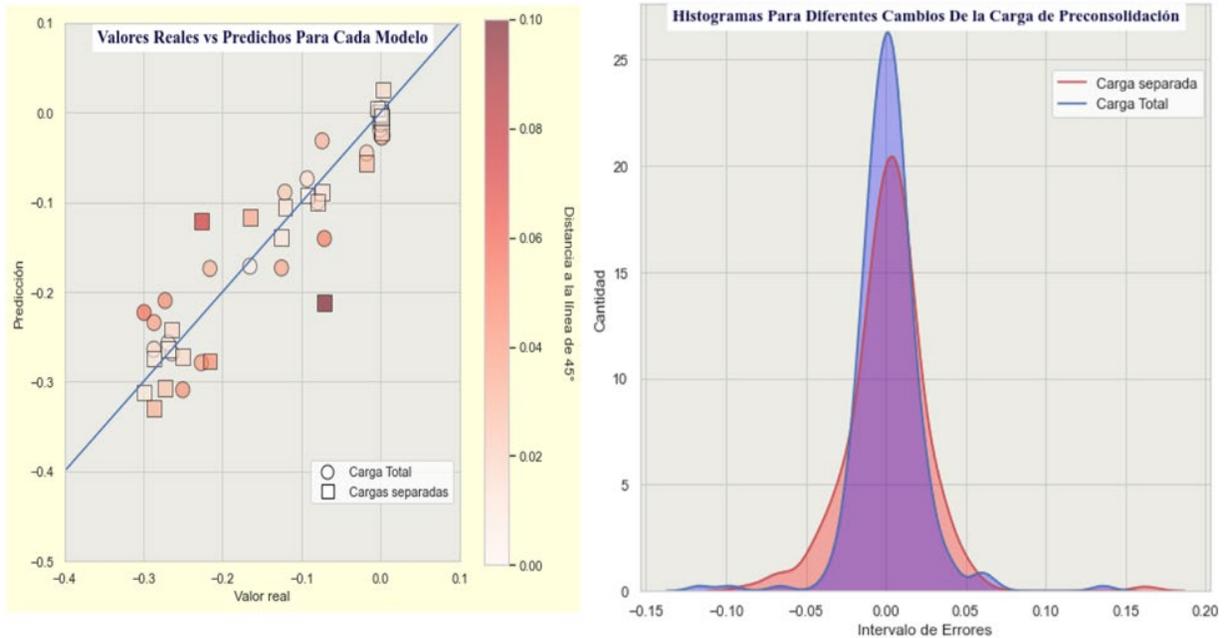


Figura 6-2: Comportamiento de los valores reales contra los predichos (a la izquierda), y de las diferencias en la predicción (derecha).

A diferencia de lo que ocurre con el coeficiente de compresibilidad, la carga de preconsolidación es mejor representada si se toman sus valores por capa, no de manera individual sino como un único valor ponderado.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

El siguiente grupo de redes reúne las derivaciones de los anteriores procesamientos y los incorpora para revelar el periodo de abatimiento con la mayor tasa de aciertos en la predicción de subsidencia.

Tabla 6-4: Descripción de todas las bases de datos empleadas para entrenar la red.

Red escala 1000 m para determinar mejor predictor para el retraso		
Variable	descripción	latitud
Espesor	Hidrofacies A	> 19.36°N
Abatimiento	periodo 1997 a 2002, 2002 a 2007, 2007 a 2012 o 2012 a 2017	
coef. Compresibilidad	separado	
carga preconsolidación	total	
Tasa hundimiento	periodo 2014 a 2021	

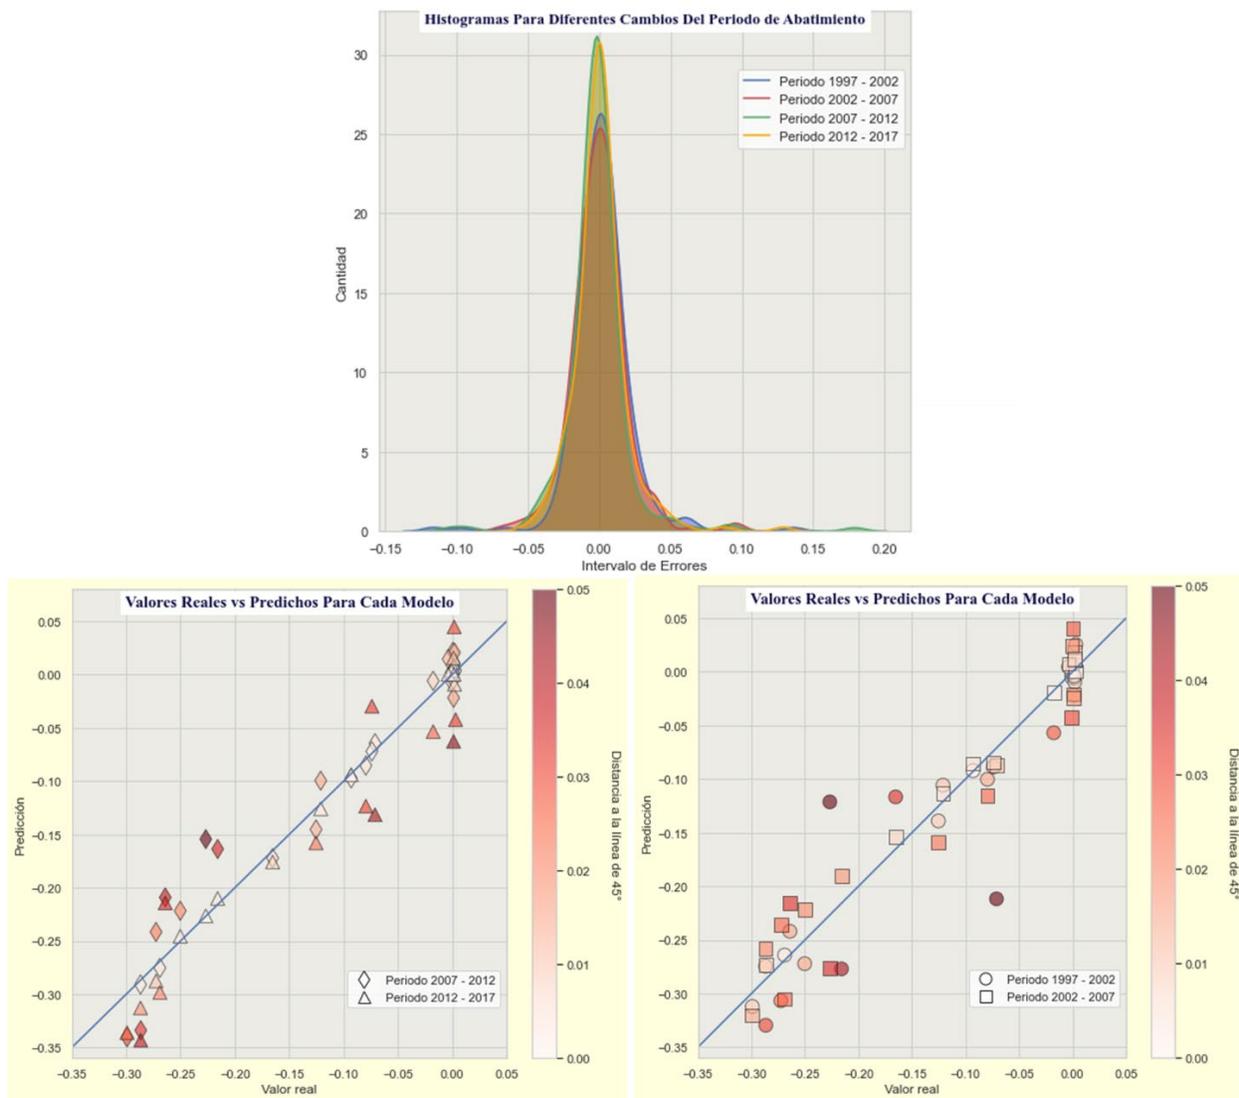


Figura 6-3: Comportamiento de los valores reales contra los predichos (abajo), y de las diferencias en la predicción (arriba).

El periodo con los mejores resultados es el de 2007-2012, seguido muy de cerca por el periodo 2012-2017, en consecuencia, el retardo homogéneo en la región está entre 8 y 3 años.

Una ventaja de esta técnica de modelación es poder conocer el peso que cada predictor ejerce sobre el modelo, por lo tanto, se compone una gráfica que sintetiza todos los pesos para cada una de las redes que varían el abatimiento.

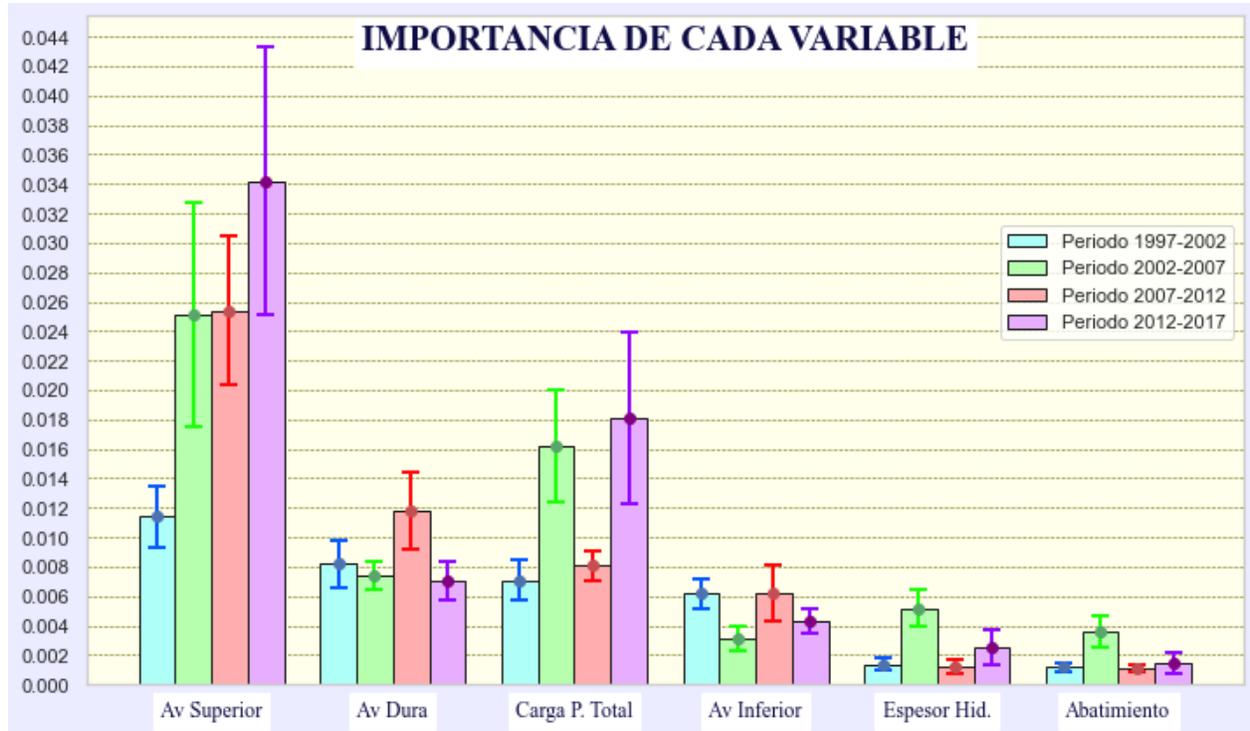


Figura 6-4: Peso de cada predictor en cada modelo que usa un diferente conjunto de datos temporal del abatimiento. Las líneas sobre cada barra representan el margen de incertidumbre.

La variable más importante según los pesos obtenidos es el coeficiente de compresibilidad de la Arcilla Superior. Con menos relevancia está el grupo conformado por el coeficiente de la Capa Dura y la carga de preconsolidación total, por último, y con una menor participación, el coeficiente de compresibilidad de la Arcilla Inferior, el espesor de la hidrofacies A y el abatimiento.

La misma secuencia que se ejecutó con la escala de 1000 m es desarrollada con la escala de 100 m. Las deducciones sobre el mejor predictor para la carga de preconsolidación y el coeficiente de compresibilidad también se alcanzan con esta nueva escala, sin embargo, el  $R^2$ , indicador del poder predictivo del algoritmo, es más alto cuando se trabaja con la escala de 100 m como se resume en la Tabla 6-5.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Tabla 6-5: R2 de los modelos desplegados por cada escala.

Modelo	R2 escala 1000 m	R2 escala 100 m
Mejor opción para el Coeficiente de compresibilidad	0.78	0.901
Moejor opción para la carga de Preconsolidación	0.82	0.912

La última conclusión interpretada con los modelos a escala de 1000 m no es semejante a lo observado con los modelos a 100 m, el periodo de abatimiento con mayor influencia es el comprendido entre 2012 y 2017, por consiguiente, el retraso revelado es de 3 años.

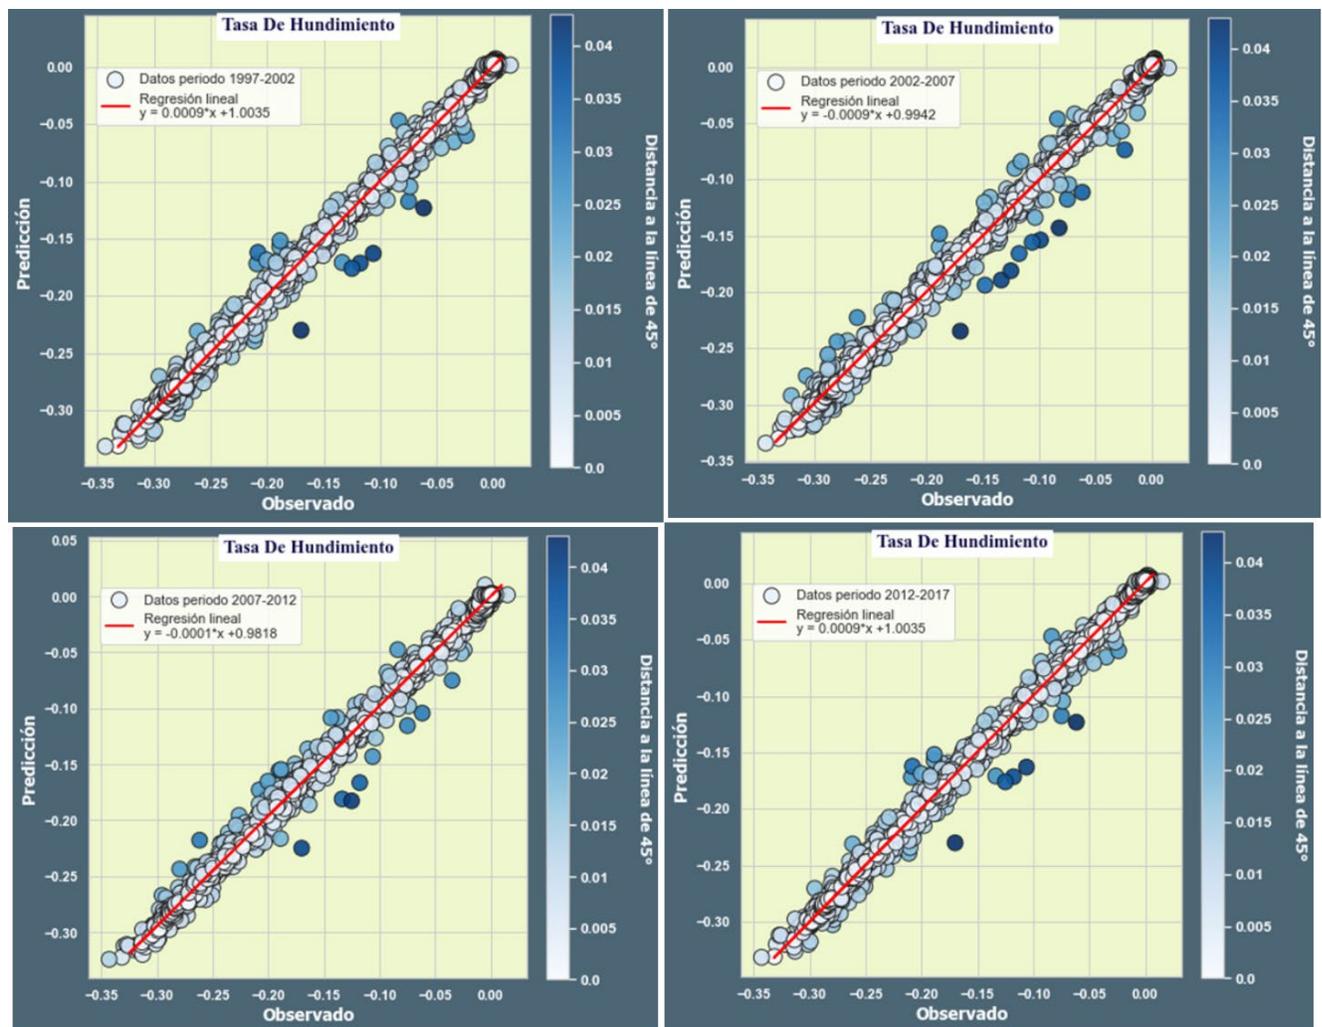


Figura 6-5: Comportamiento de los valores reales contra los predichos para cada periodo del abatimiento, escala 100 m.

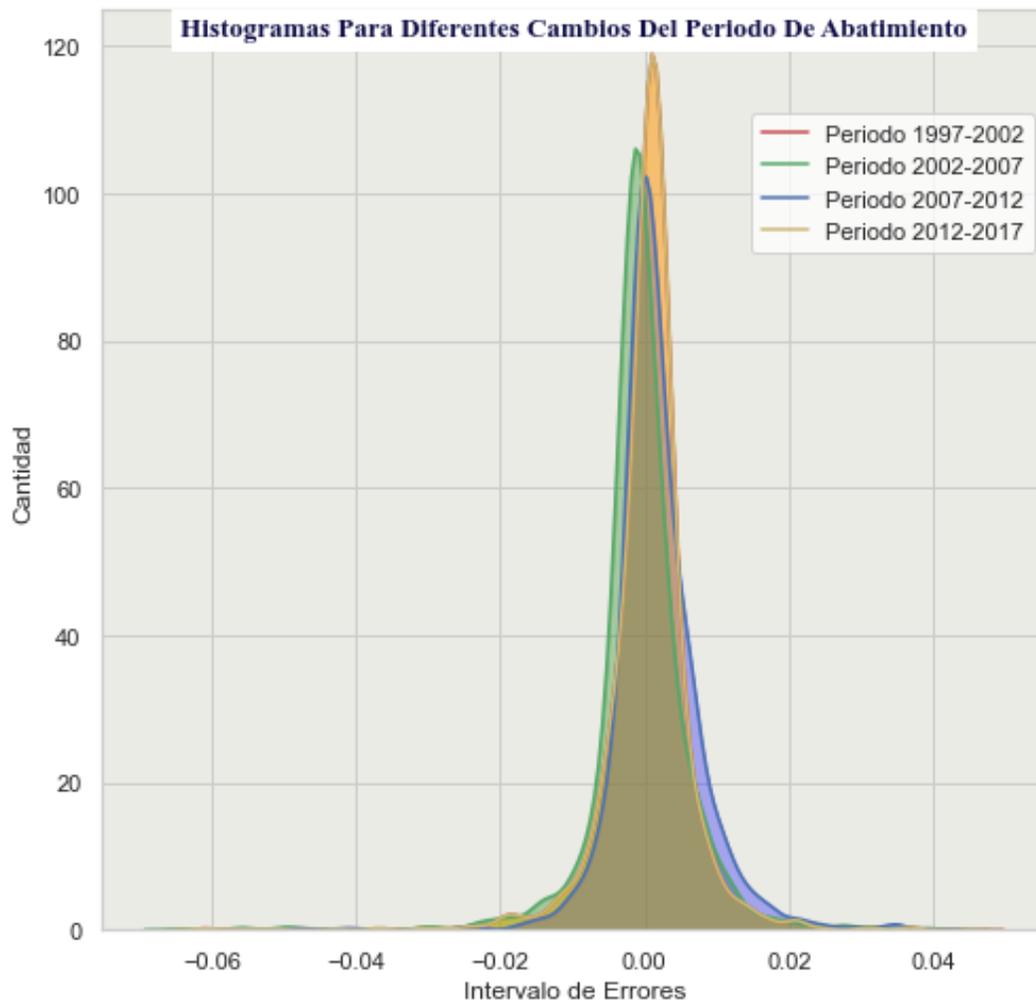


Figura 6-6: Histograma de las diferencias en las predicciones por cada periodo, escala 100 m.

El gráfico de los pesos de los predictores por cada periodo del abatimiento también se analiza en esta escala, además, se estudia la distribución de los errores en la predicción en busca de anomalías en toda el área de estudio.

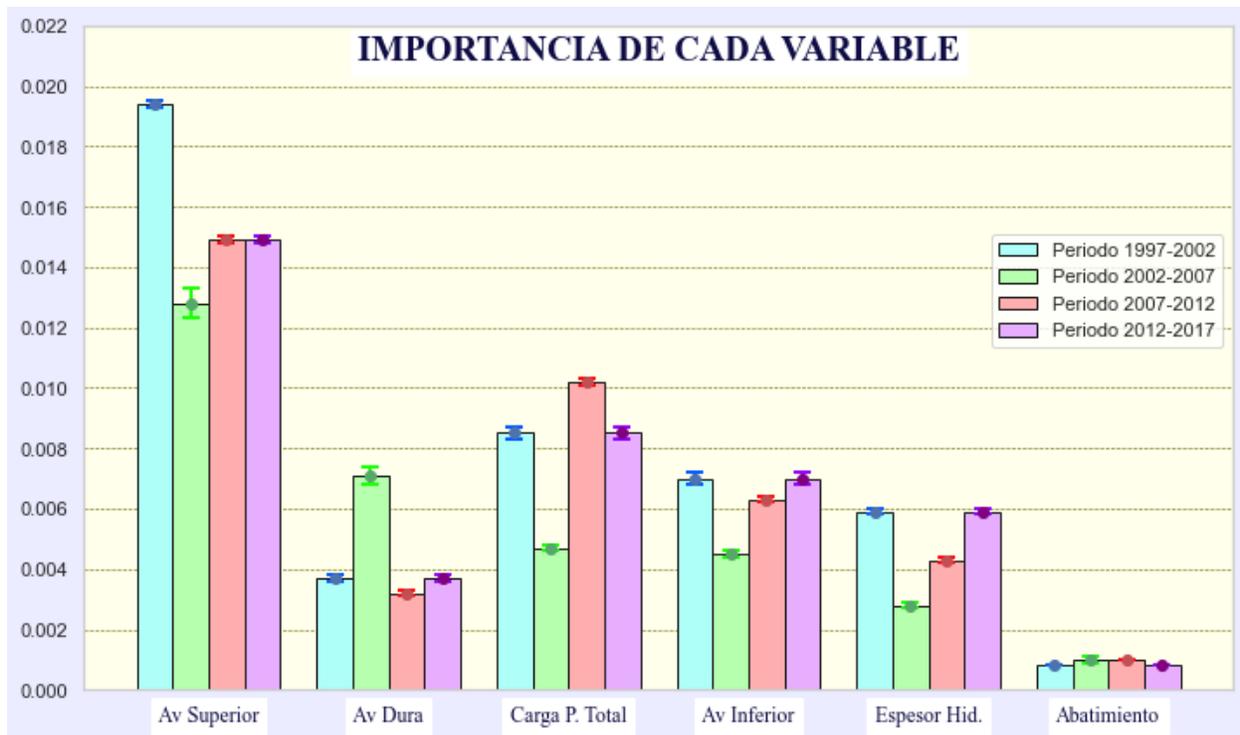


Figura 6-7: Peso de cada predictor en cada modelo que usa un diferente conjunto de datos temporal del abatimiento. Las líneas sobre cada barra representan el margen de incertidumbre, escala 100 m.

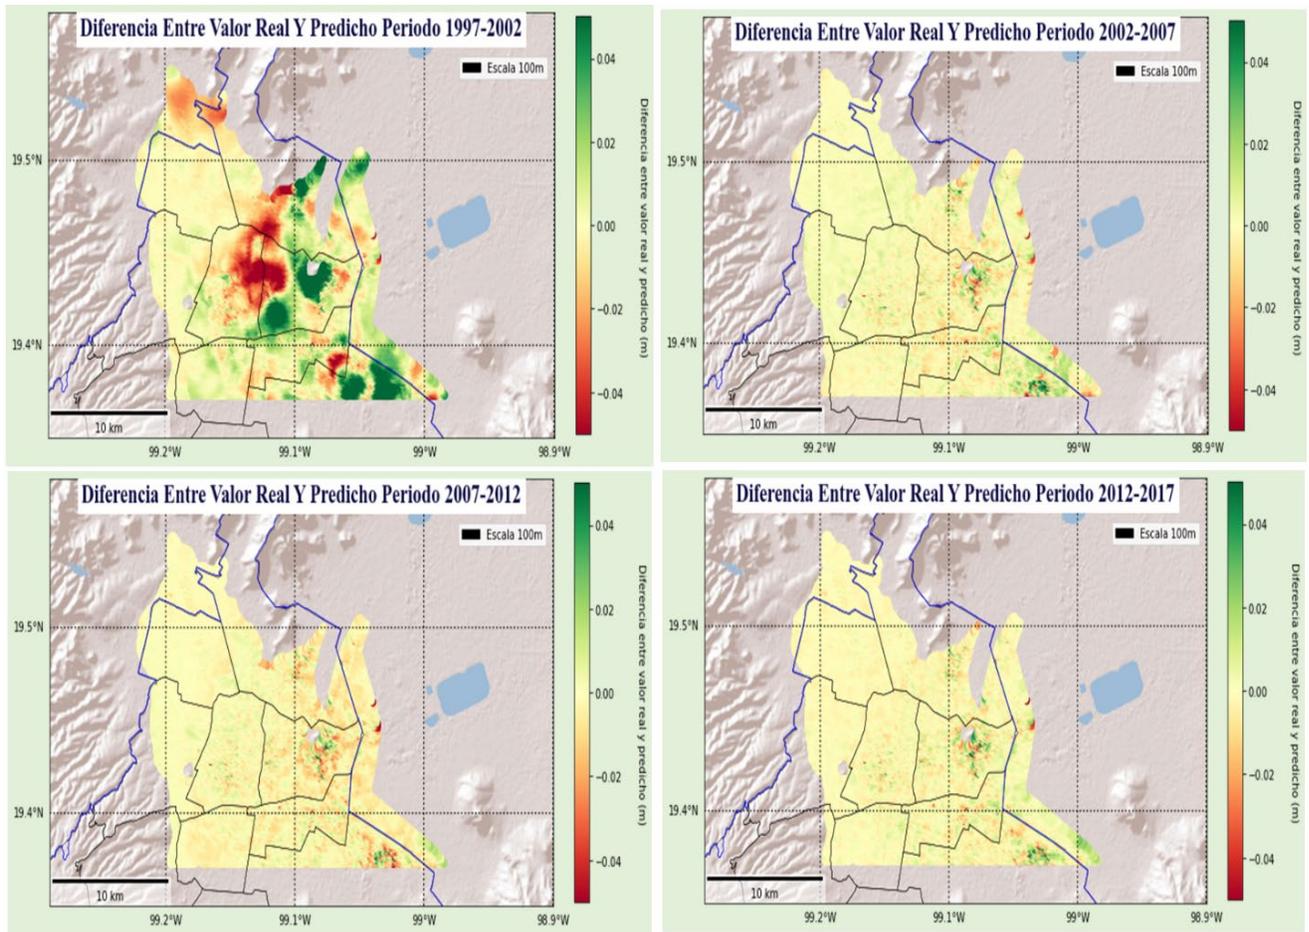


Figura 6-8: Distribución de los errores en la región por cada periodo.

De la misma forma que ya se había visto a la escala de 1000 m, el coeficiente de compresibilidad de la Arcilla Superior es el predictor que más aporta al modelo, seguido por los demás coeficientes, la carga de preconsolidación y el espesor de la hidrofacies A. Extrañamente, el abatimiento, detonante de todo este fenómeno, es la variable con menor peso en la predicción, una condición que se podría estar acentuando debido a la falta de calidad en los conjuntos de datos utilizados. Por otra parte, las distribuciones de los errores muestran que, las zonas que concentran el grueso del error se ubican más al oriente de la región, lo que coincide con los lugares en donde se tiene un menor muestreo en muchas de las bases de datos.

Las gráficas de entrenamiento del mejor modelo a escala 1000 m, periodo 2007-2012, y del mejor modelo a escala 100 m, periodo 2012-2017, se confrontan con el fin de corroborar la mejor escala, en este caso, no cabe duda de que la escala a 100 m produce los modelos más confiables, no solo porque los errores

son mucho menores en magnitud, sino porque sus curvas de entrenamiento y validación se sobreponen, una señal necesaria para asegurar la calidad en el algoritmo.

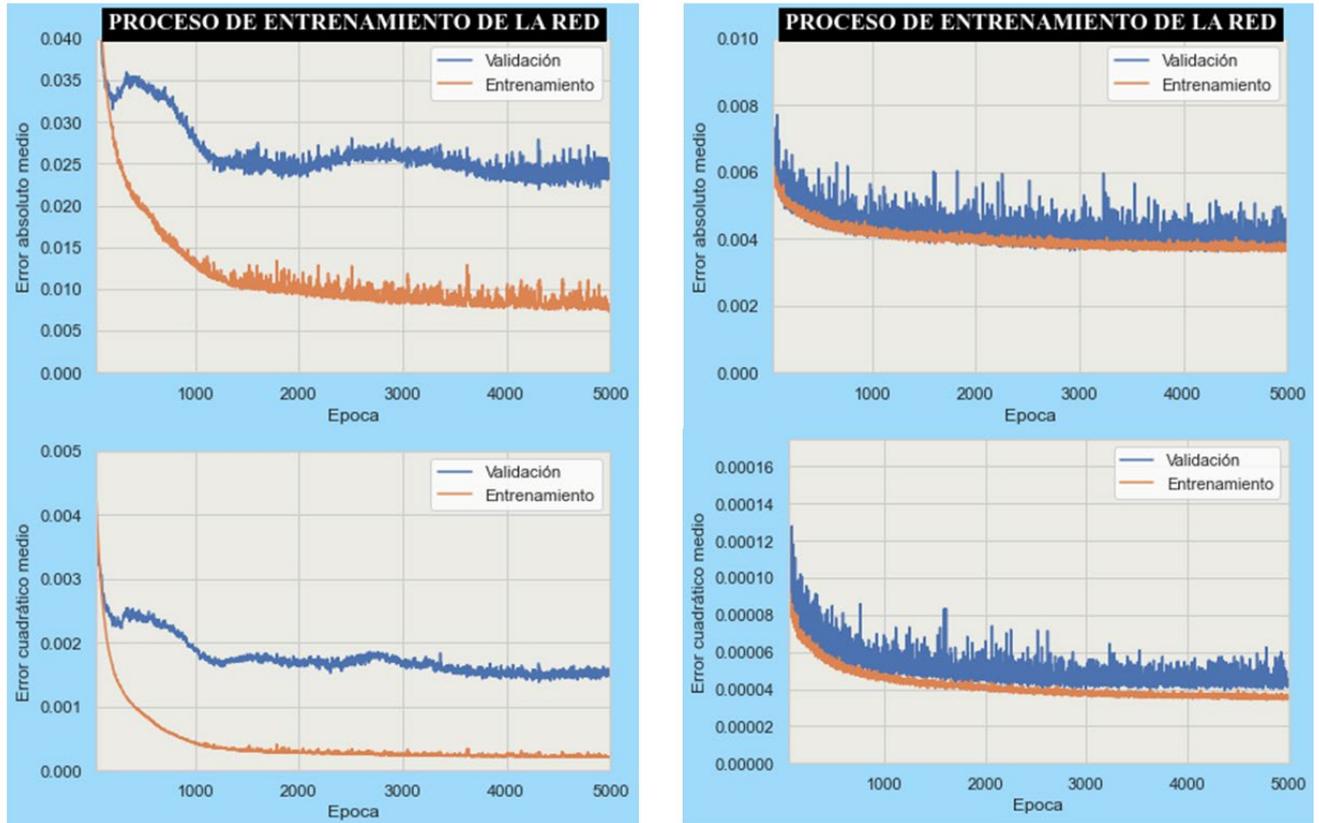


Figura 6-9: Curvas de entrenamiento del mejor modelo a escala 1000 m (izquierda) contra las curvas de entrenamiento del mejor modelo a escala 100 m (derecha).

Conclusiones preliminares de esta etapa:

- El retardo en el área de estudio es de 3 años.
- Se recomienda trabajar en escala de 100 m y no en la escala de 1 km
- Los coeficientes de compresibilidad generan peores modelos al incorporarlos por separado y no como un solo valor para el acuitardo.
- La carga de preconsolidación es más eficaz si se representa como un solo valor promedio para todo el acuitardo y no un valor por cada una de las tres formaciones.
- La variable más importante para predecir subsidencia es el coeficiente de compresibilidad en la arcilla superior. Enseguida, en orden de importancia están la carga total, el coeficiente de

compresibilidad para la arcilla inferior y el espesor de la hidrofacies A. Finalmente, con menor peso están el coeficiente de la Capa Dura y el abatimiento

- El modelo solo ajusta para datos con latitud mayor a 13.6°N.
- Usar la litología para predecir el espesor de la hidrofacies A, ya que no es una variable que pueda reemplazar el valor del coeficiente de compresibilidad en la red que predice subsidencia. No es posible usarla en los dos modelos debido a que se requiere cumplir con la independencia lineal de todas las variables en un modelo de deep learning básico.
- Los valores elevados de  $R^2$  en los modelos se deben a la reducción del área de estudio a la mitad de su extensión, cuando se manipula el conjunto de datos completo, los valores del  $R^2$  disminuyen por debajo de 0.7

Las únicas conclusiones que se tienen en cuenta en la segunda etapa son la escala recomendada, 100 m, y la de emplear la litología en la predicción de la hidrofacies A, en vista de que no es una variable que pueda reemplazar al coeficiente de compresibilidad.

## 6.2. ETAPA 2

Se diseña bajo un esquema de mejora incremental, esto es, cada uno de los predictores se irá actualizando, uno a la vez. A la par, se registrarán los valores del  $R^2$  para cada modelo desplegado, lo que permitirá visualizar el perfeccionamiento del modelo, o si fuese el caso, el mal desempeño de la actualización de una variable.

La primera transformación parte del espesor de la hidrofacies A, una nueva propuesta nombrada como hidrofacies A mejorada reemplaza al anterior conjunto de datos de espesores. Una alternativa diferente, y también evaluada, es emplear el espesor del acuitardo superior.

APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Tabla 6-6: Resultados al reemplazar la hidrofacies A por la hidrofacies A mejorada. El mejor modelo se señala en rojo. Cada modelo, numerados con un número, registra una x en el espacio de cada uno de los predictores que utiliza.

Valores de R2 para diferentes modelos usando espesor hidrofacies A, zona mayor a 19.36°N						
Modelos/ Variables	1	2	3	4	5	6
Carga total	x	x	x	x	x	x
Coefficientes separados			x	x	x	x
Promedio de coeficientes	x	x				
Abatimiento 1997-2002	x		x			
Abatimiento 2002-2007				x		
Abatimiento 2007-2012					x	
Abatimiento 2012-2017		x				x
R2	0.9376	0.9573	0.9925	0.9922	0.9926	0.9904

Tabla 6-7: Resultados al reemplazar la hidrofacies A por el espesor del acuitardo (espesor geofísico). El mejor modelo se señala en rojo.

Valores de R2 para diferentes modelos usando espesor geofísico, zona mayor a 19.36°N						
Modelos/ Variables	1	2	3	4	5	6
Carga total	x	x	x	x	x	x
Coefficientes separados			x	x	x	x
Promedio de coeficientes	x	x				
Abatimiento 1997-2002	x		x			
Abatimiento 2002-2007				x		
Abatimiento 2007-2012					x	
Abatimiento 2012-2017		x				x
R2	0.9731	0.9781	0.9933	0.993	0.9941	0.9936

Aún cuando los resultados con la mejora en la hidrofacies A son superiores a los anteriores, los modelos con el espesor del acuitardo tienen un mejor ajuste. Los valores de R<sup>2</sup> en este primer incremento siguen siendo considerados sobre una sola parte del área de estudio, por lo que no deben ser contrastados con los de los siguientes pasos. Hasta el momento todos los algoritmos han sido inestables, lo que significa que al reiterar la ejecución del código, los pesos de las variables se modifican en una gran proporción.

La segunda reforma se produce sobre la carga de preconsolidación, un nuevo conjunto de datos de seis variables reemplaza a este predictor. Los nuevos modelos van haciendo uso de las mejoras previas.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Tabla 6-8: Resultados al reemplazar la carga de preconsolidación por el nuevo conjunto de datos de seis variables relacionadas. Los mejores modelos se señalan en rojo.

Valores de R2 para diferentes modelos usando espesor geofísico																							
Modelos/ Variables	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	22
Población	x		x						x	x				x	x	x	x	x		x		x	
Vivienda		x		x	x	x	x	x					x									x	
Unidades económicas	x	x			x	x	x	x	x		x				x			x	x	x	x	x	x
áreas verdes	x	x	x	x	x	x	x	x	x					x			x			x	x	x	x
intensidad de lluvia	x	x	x	x														x	x	x	x	x	x
Caudal extracción	x	x	x	x																			x
Coefficientes separados	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
Abatimiento 1997-2002					x																		
Abatimiento 2002-2007						x																	
Abatimiento 2007-2012	x	x	x	x				x		x	x	x	x	x	x	x	x	x	x	x	x	x	x
Abatimiento 2012-2017								x															
R2	0.9293	0.915	0.9047	0.9085	0.9413	0.9418	0.9446	0.9449	0.9359	0.867	0.8614	0.8655	0.8656	0.9017	0.8959	0.9359	0.8927	0.9079	0.908	0.925	0.9212	0.8981	0.8913

Como se puede extraer de la Tabla 6-8, la intensidad de lluvia y los caudales de extracción no son relevantes en el modelo, la explicación puede radicar en la construcción de estas bases de datos. La población y el número de viviendas no se pueden considerar en un mismo modelo al ser variables linealmente dependientes. Finalmente, la combinación de parámetros que mejor sustituyen a la carga de preconsolidación se alcanza al unir la densidad de viviendas, la densidad de unidades económicas y la densidad de áreas verdes.

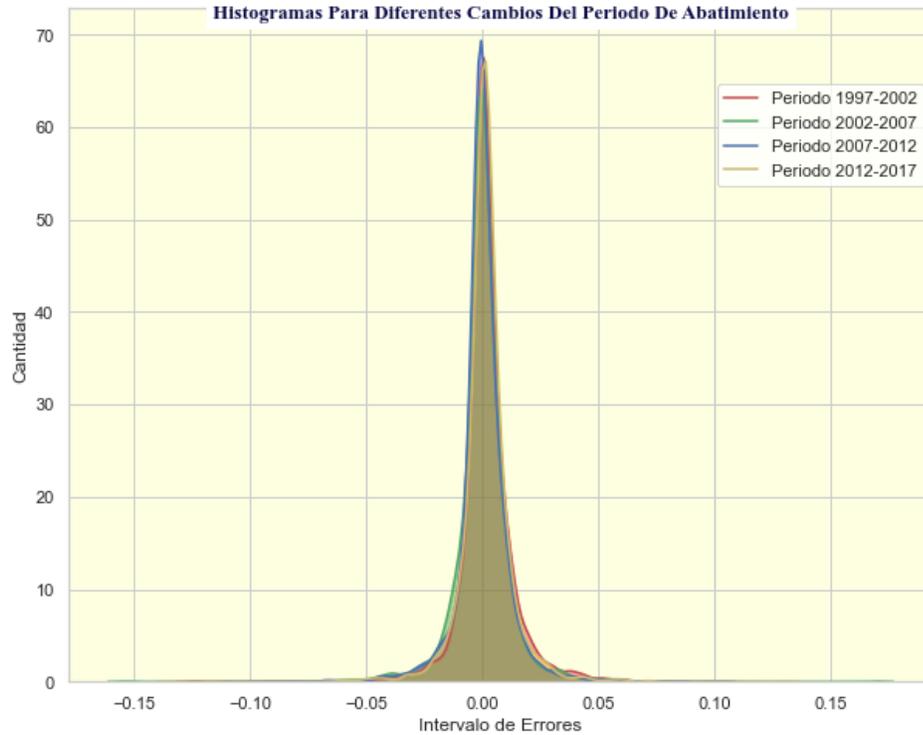


Figura 6-10. Histogramas de los cuatro mejores modelos luego de reemplazar la carga de preconsolidación.

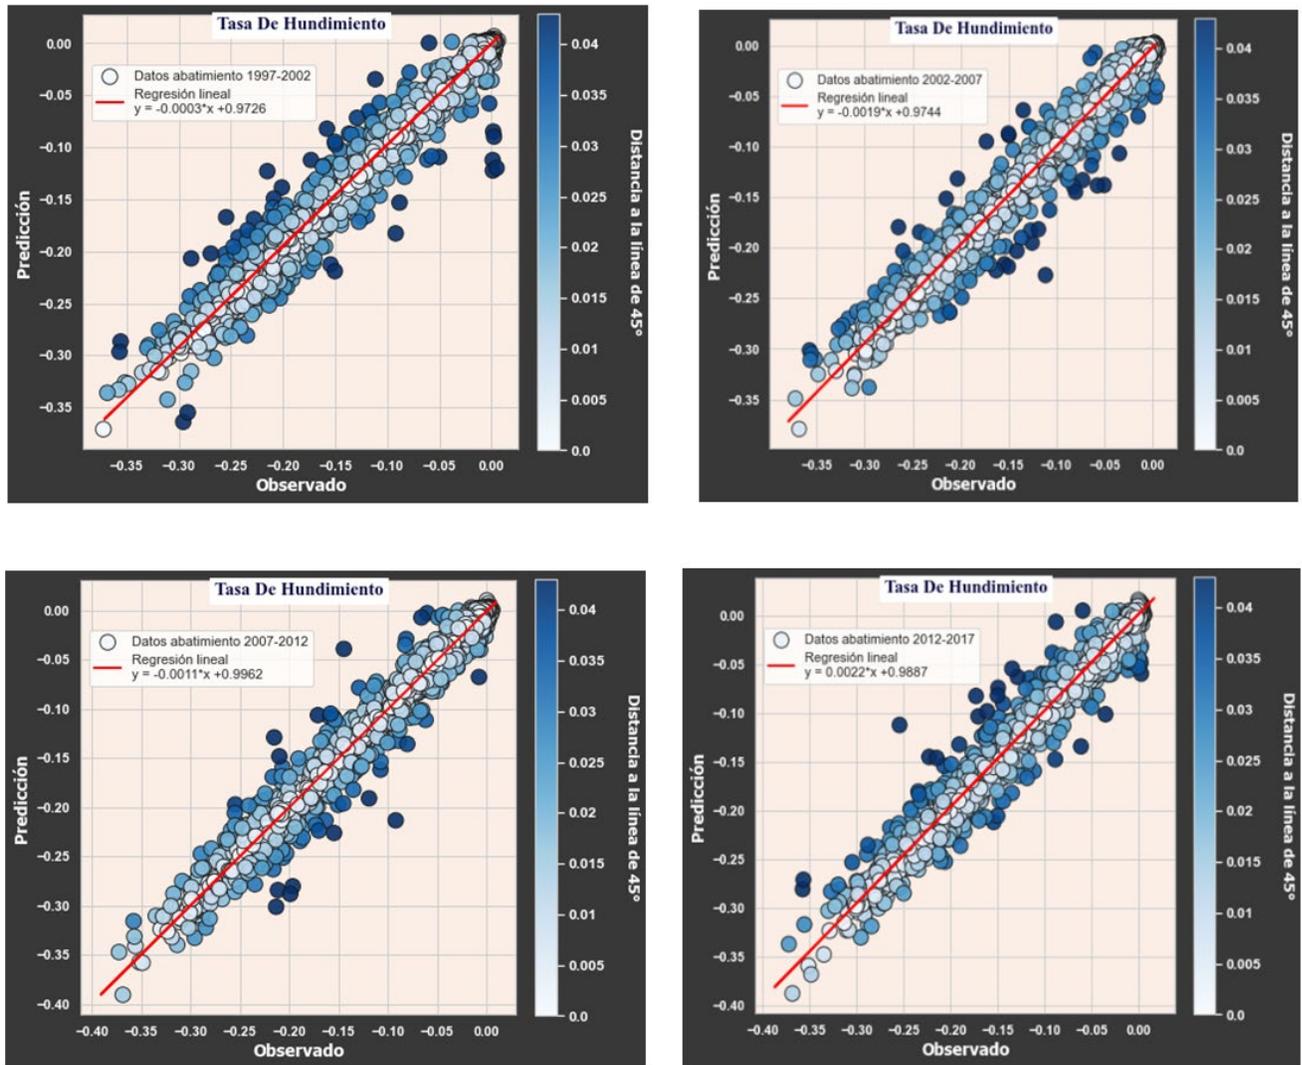


Figura 6-11: Valores predichos contra valores reales de los cuatro mejores modelos luego de reemplazar la carga de preconsolidación

Aunque en la Tabla 6-8 se resaltan los 4 mejores modelos, el que sobresale por el mejor ajuste es el del 2012 al 2017, no obstante, también se analizará el segundo mejor, 2007-2012, ya que el censo de las variables que reemplazan a la carga de preconsolidación es llevado a cabo en un año dentro de este intervalo.

Al reemplazar el coeficiente de compresibilidad por el índice de compresión no solo se genera un conjunto de datos más robusto y menos controlado por el interpolador, además, se elimina una fuente de error no

conocida hasta este momento, la fuerte relación lineal entre el coeficiente de compresibilidad de la Arcilla Inferior y la Capa Dura.

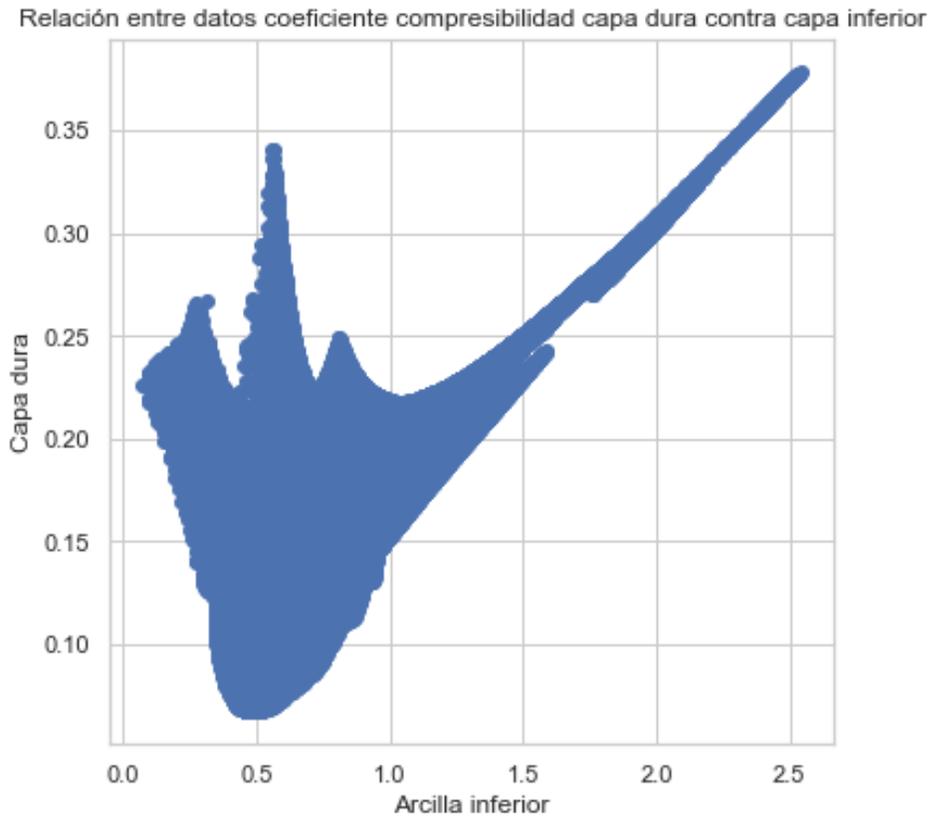


Figura 6-12: Relación entre los coeficientes de compresibilidad de la Capa Dura y la Arcilla Inferior.

Como no se tiene en cuenta el espesor de la hidrofacies A sino el del acuitardo superior, los espesores de cada una de las formaciones que conforman la hidrofacies A pueden ser añadidos al catálogo de predictores. La razón por la que no pueden ser parte de un mismo inventario junto a la Hidrofacies A, es que al sumar los tres espesores se obtiene la hidrofacies A, por lo que se rompería el requisito de independencia lineal.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Table 6-9: Resultados al reemplazar el coeficiente de compresibilidad por el índice de compresión. Los mejores modelos se señalan en rojo.

R2 para diferentes modelos usando espesor geofísico, más capas, más épocas												
Modelos/ Variables	1	2	3	4	5	6	7	8	9	10	11	12
Población												
Vivienda	x	x	x	x	x	x	x	x	x	x	x	x
Unidades económicas	x	x	x	x	x	x	x	x	x	x	x	x
áreas verdes	x	x	x	x	x	x	x	x	x	x	x	x
intensidad de lluvia												
Caudal extracción												
Cc ponderado		x						x				
Cc Arcilla Superior	x		x	x	x	x	x		x	x	x	x
Espesor Arcilla Superior			x	x					x	x		
Cc Capa Dura			x	x	x	x			x	x	x	x
Espesor Capa Dura			x	x					x	x		
Cc Arcilla Inferior				x		x				x		x
Espesor Arcilla Inferior				x						x		
Abatimiento 1997-2002												
Abatimiento 2002-2007												
Abatimiento 2007-2012							x	x	x	x	x	x
Abatimiento 2012-2017	x	x	x	x	x	x						
R2	0.9835	0.9825	0.9903	0.9908	0.9873	0.9879	0.9844	0.9833	0.9911	0.9912	0.9901	0.9904

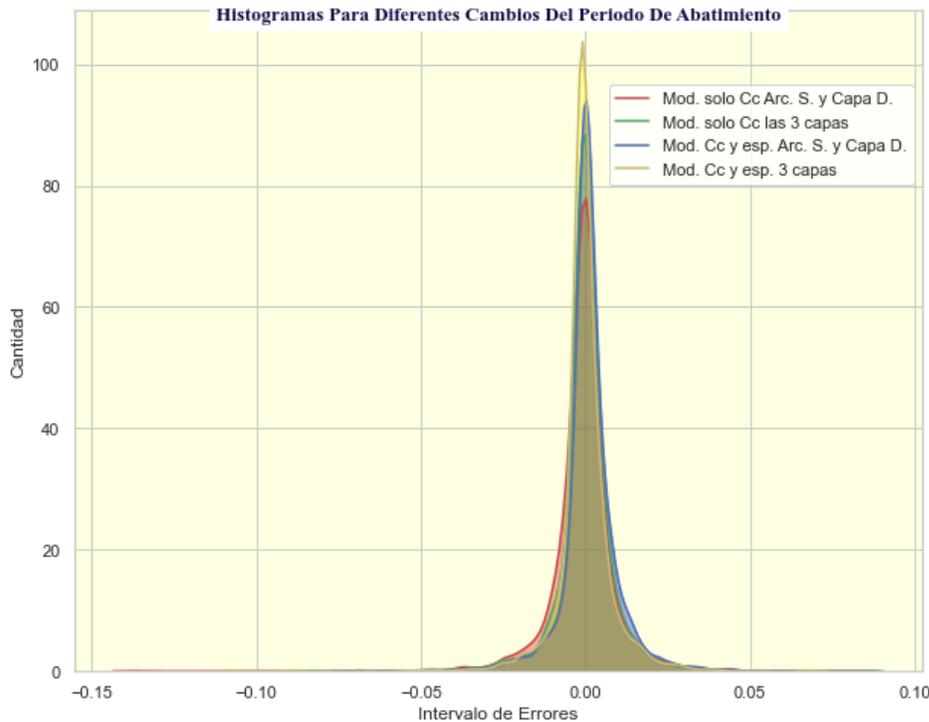


Figura 6-13: Histogramas de los cuatro mejores modelos. En rojo, el modelo que solo usa el Cc de la Arcilla Sup. y Capa Dura, en verde, el modelo con los Cc de las tres capas, en azul, el modelo con los Cc y espesores de la Arcilla Superior y Capa Dura, y en amarillo, el modelo que usa los Cc y espesores de las tres capas.

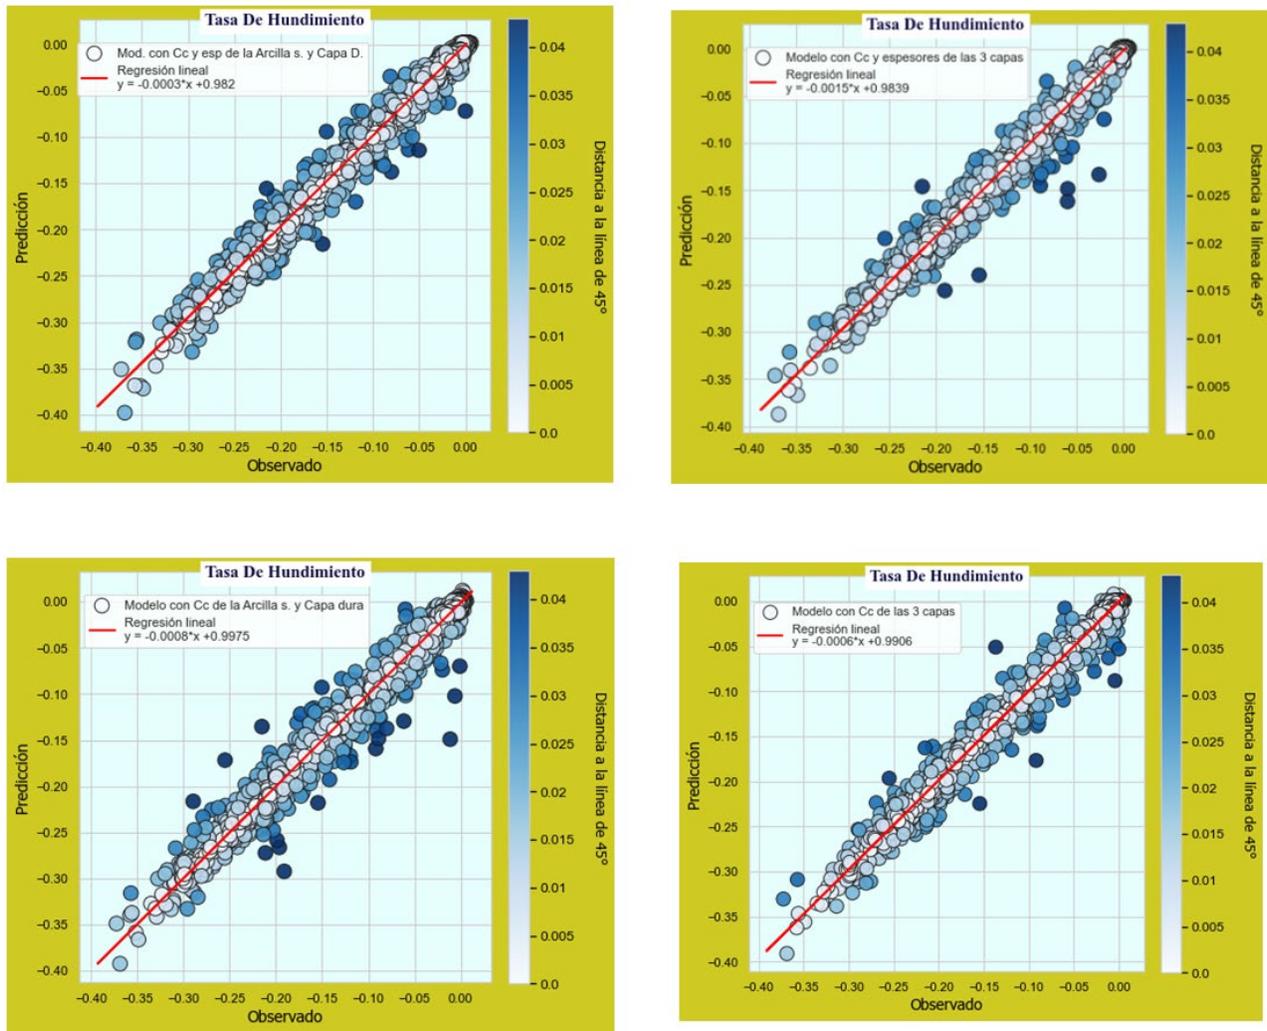


Figura 6-14: Valores predichos contra valores reales de los cuatro mejores modelos luego de reemplazar el coeficiente de compresibilidad.

En la Table 6-9 se indican los mejores cuatro modelos, no obstante, los que agregan el índice de compresión de la arcilla inferior son muy inestables. Con el fin de averiguar el origen de la inestabilidad se plotean todas las variables en parejas, encontrando que el índice de la Arcilla inferior exhibe una relación casi lineal con la tasa de hundimiento, por lo cual, las demás variables pierden peso ante la presencia de los valores de la Arcilla Inferior. Una probable explicación se debe al tipo de interpolador implementado y a la falta de datos de índice de compresión de la Arcilla Inferior en el lado oriental del área de estudio.

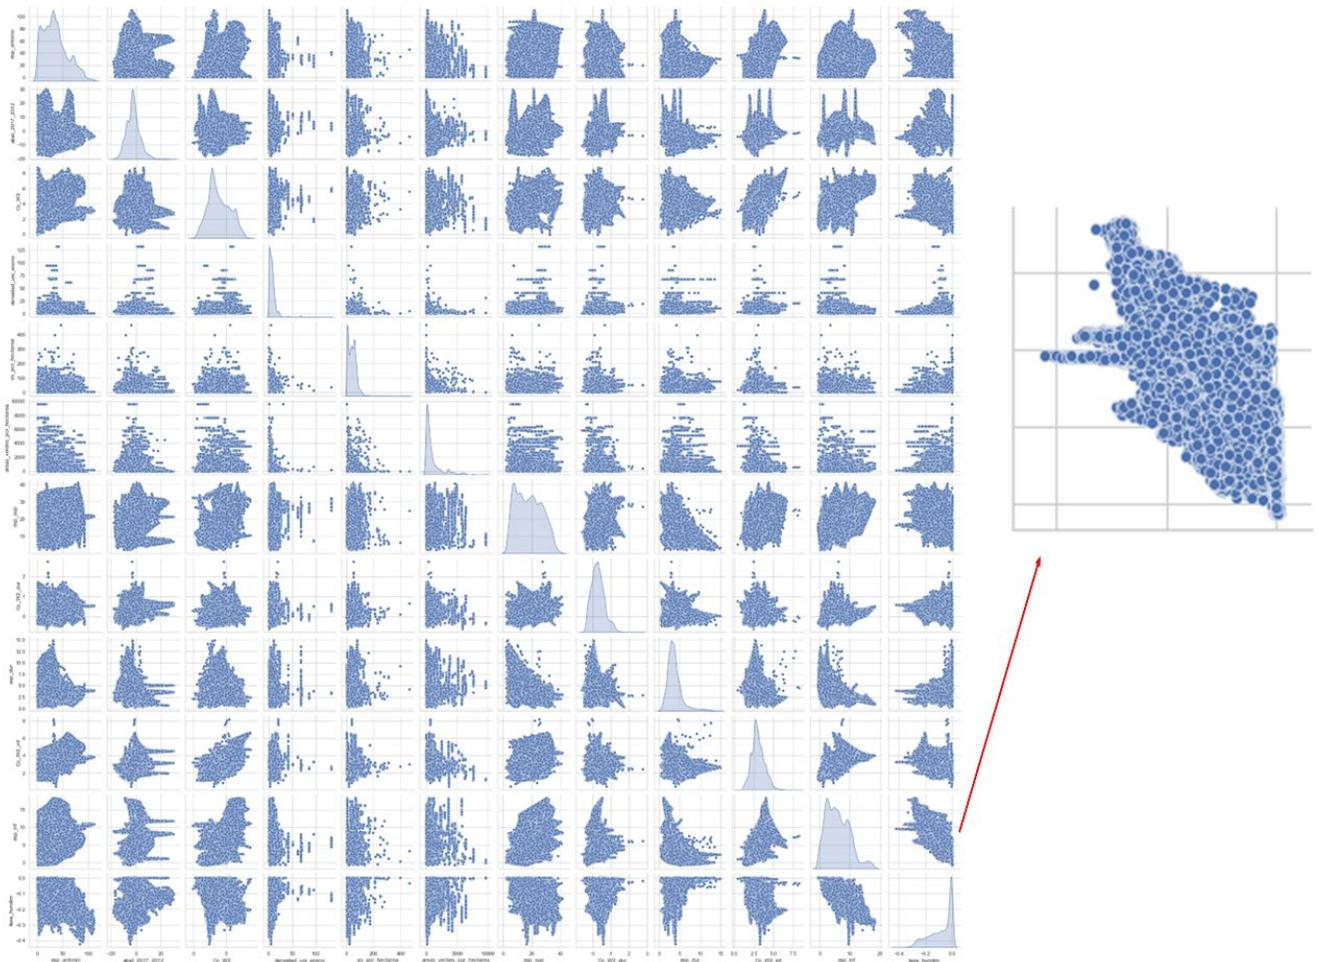


Figura 6-15: Gráfico de cada pareja de variables. A la derecha se extrae la relación entre el índice de la Arcilla Inferior y la tasa de hundimiento.

A raíz de las apreciaciones expuestas sobre el índice de compresión de la Arcilla inferior, los modelos que integran esta variable son descartados. Los dos modelos restantes se examinan a detalle.

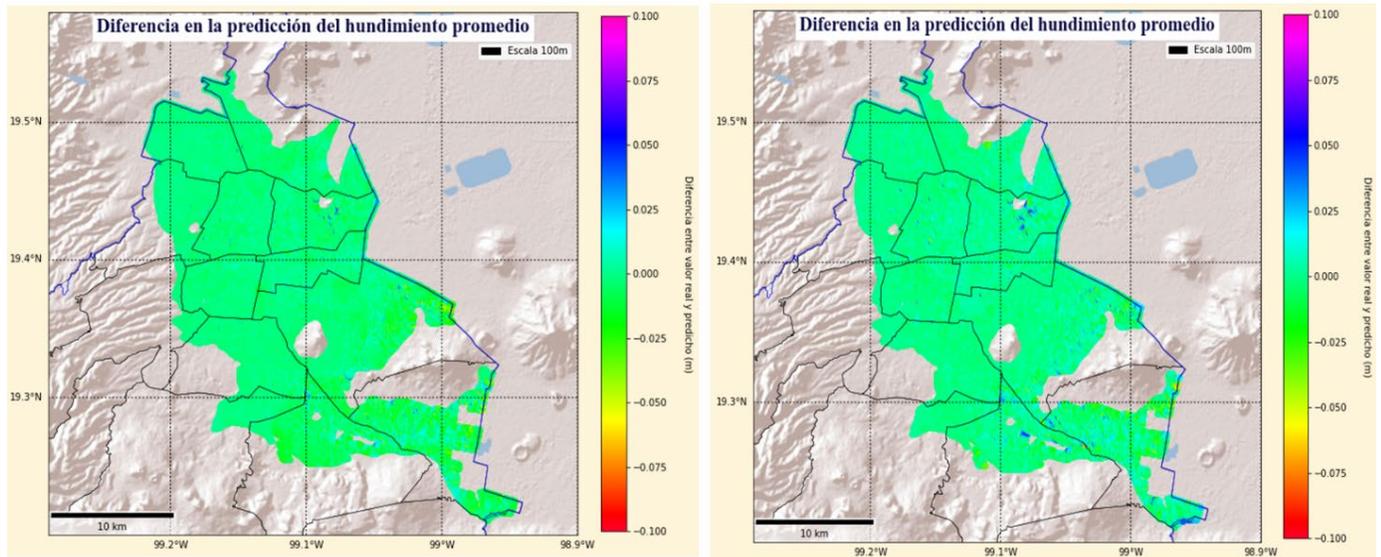


Figura 6-16: Distribución de los errores en el área de estudio. A la izquierda, los errores del modelo que usa el  $C_c$  y el espesor de la Arcilla Superior y la Capa Dura. A la derecha, los errores del modelo que usa el  $C_c$  de la Arcilla Superior y la Capa Dura.

Con base en la Figura 6-14, Figura 6-15 y Figura 6-16, el modelo 9 de la Table 6-9 es el que predice los hundimientos con mejor ajuste, el escogido, sin embargo, el modelo 11 es un poco más estable. Los niveles más altos de error se siguen agrupando en el flanco oriental del dominio de estudio.

Los pesos de los predictores se grafican para los 4 modelos sugeridos en la Table 6-9, pese a esto, se demostró la poca conveniencia de los modelos que añaden el índice de compresión de la Arcilla inferior, definidos con color verde y morado en la Figura 6-17.

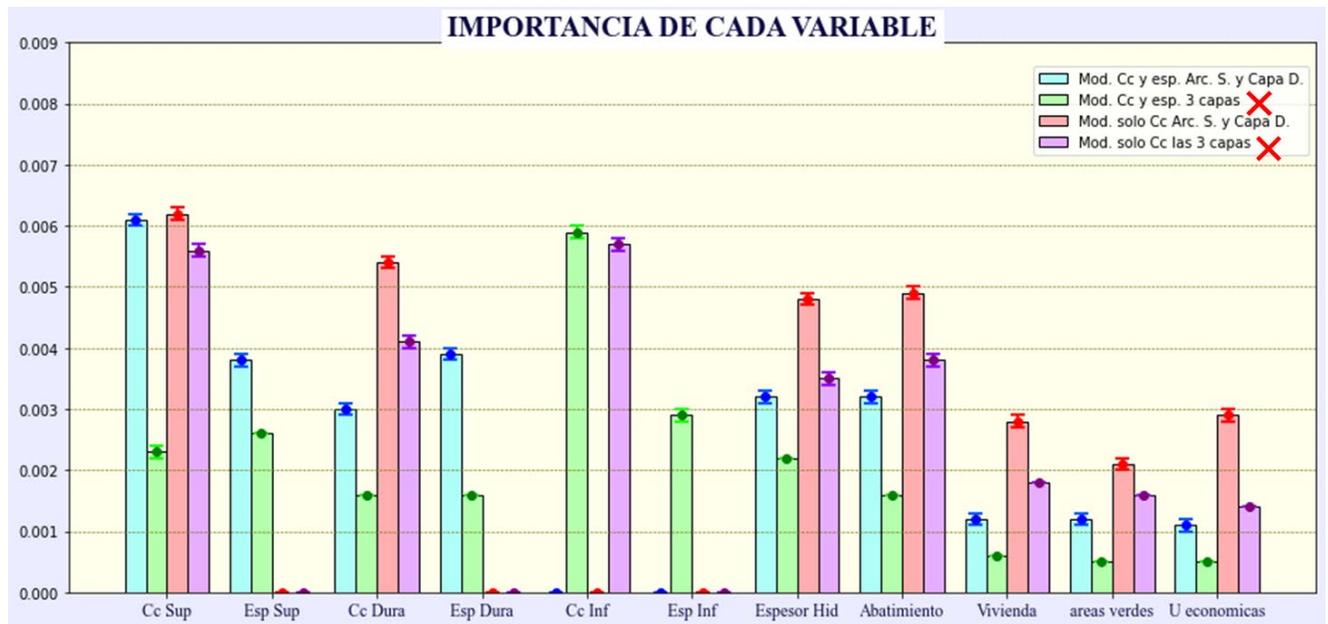


Figura 6-17: Peso de cada predictor para cada uno de los mejores modelos luego de cambiar el coeficiente de compresibilidad. Las líneas sobre cada barra representan el margen de incertidumbre.

Con los cambios propuestos hasta este punto, el retraso en la zona sigue estando entre 3 y 8 años, por su parte, los predictores más influyentes en orden de importancia son: índice de compresión de la Arcilla superior, espesor de la Arcilla Superior, espesor de la Capa Dura, índice de compresión de la Capa Dura, Espesor del acuitardo, abatimiento, densidad de viviendas, densidad de áreas verdes y densidad de unidades económicas.

Finalmente, la tasa de hundimiento que proveniente de datos de INSAR es suplida por la base de datos de la red de bancos. Un valor de hundimiento es calibrado para cada uno de los tres primeros periodos del abatimiento. El modelo empleado en los siguientes algoritmos es aquel con los mejores resultados hasta este punto, ese es, el modelo 9 de la Table 6-9.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Tabla 6-10: R2 de varios modelos al reemplazar la tasa de hundimiento promedio por la base de datos de la red de bancos. El mejor modelo para cada abatimiento es marcado en rojo.

R2 para diferentes modelos usando espesor geofísico, más capas, más épocas															
Modelos/ Variables	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Población															
Vivienda	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
Unidades económicas	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
áreas verdes	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
intensidad de lluvia															
Caudal extracción															
Cc ponderado															
Cc Arcilla Superior	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
Espesor Arcilla Superior	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
Cc Capa Dura	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
Espesor Capa Dura	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
Cc Arcilla Inferior															
Espesor Arcilla Inferior															
Abatimiento 1997-2002	x	x	x	x	x										
Abatimiento 2002-2007						x	x	x	x	x					
Abatimiento 2007-2012											x	x	x	x	x
Abatimiento 2012-2017															
T. Hundimiento 2000-2002	x														
T. Hundimiento 2002-2005		x													
T. Hundimiento 2005-2007			x			x									
T. Hundimiento 2007-2016				x			x				x				
T. Hundimiento 2016-2020					x			x				x			
T. Hundimiento 2020-2025									x				x		
T. Hundimiento 2025-2030										x				x	
T. Hundimiento 2030-2035															x
R2	0.9969	0.9971	0.9966	0.9962	0.9944	0.9968	0.9957	0.9945	0.9948	0.995	0.9977	0.9948	0.9968	0.9966	0.9967

El mejor periodo de tasa de hundimiento se escoge, con base en los  $R^2$ , para cada periodo del abatimiento. Las filas vacías en la Tabla 6-10 muestran las variables que no aporta al modelo. Luego de varias ejecuciones, se comprueba el progreso en la estabilidad de los pesos. Los predictores destacados en la Tabla 6-10 son los que mejor describen el fenómeno, al único que se le valora un sustituto es al espesor del acuitardo por medio de la hidrofacies A mejorada.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

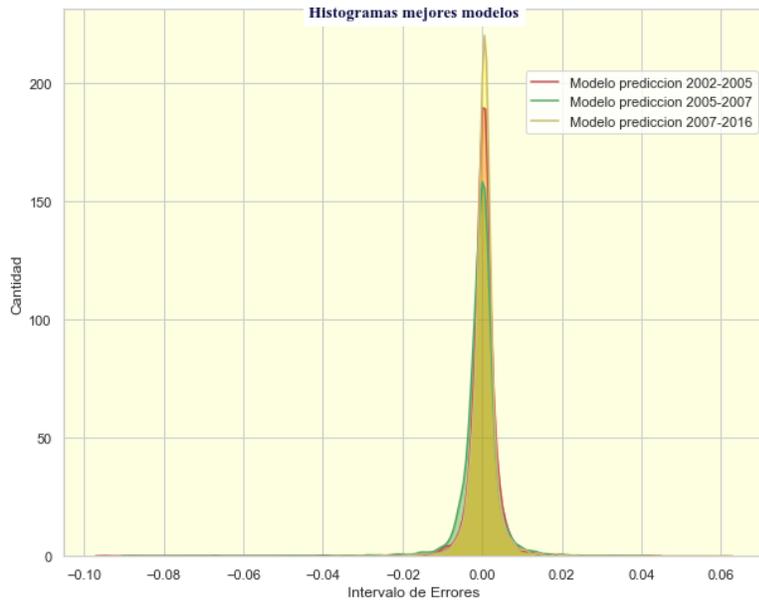


Figura 6-18: Histograma de los tres mejores modelos, uno para cada periodo del abatimiento

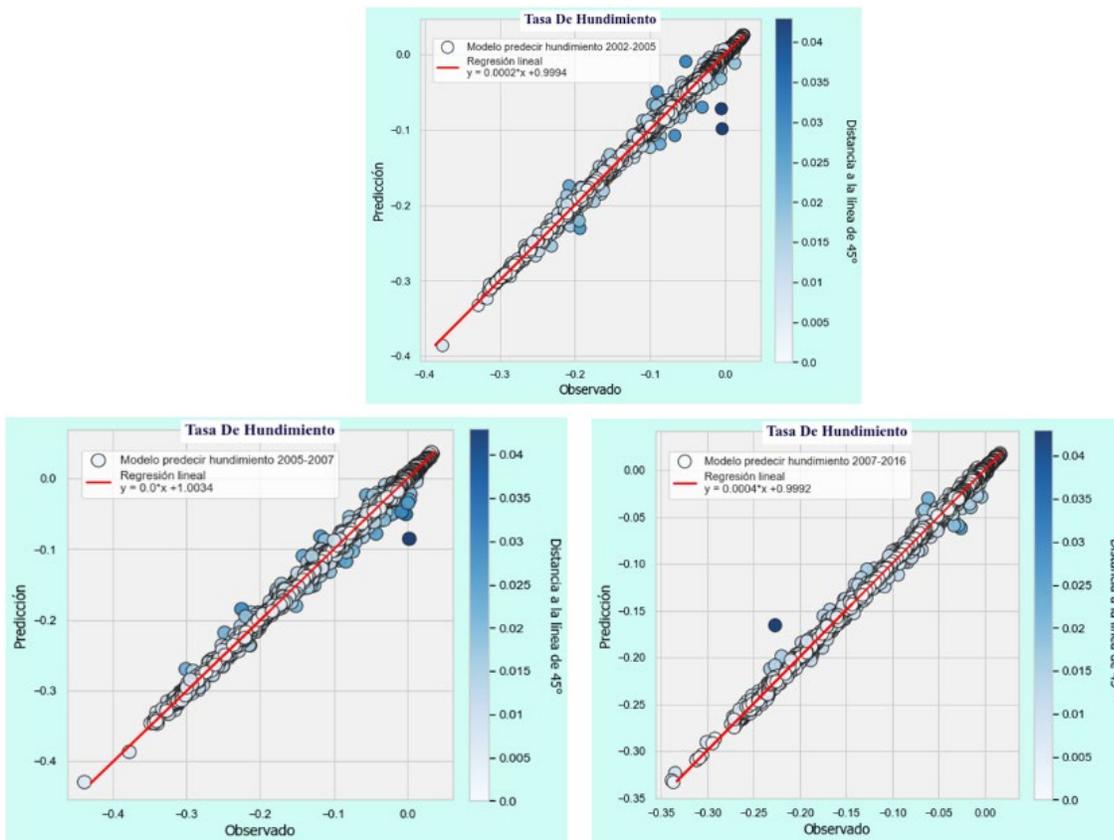


Figura 6-19: Valores de las predicciones contra los valores reales de los tres mejores modelos, uno para cada periodo del abatimiento

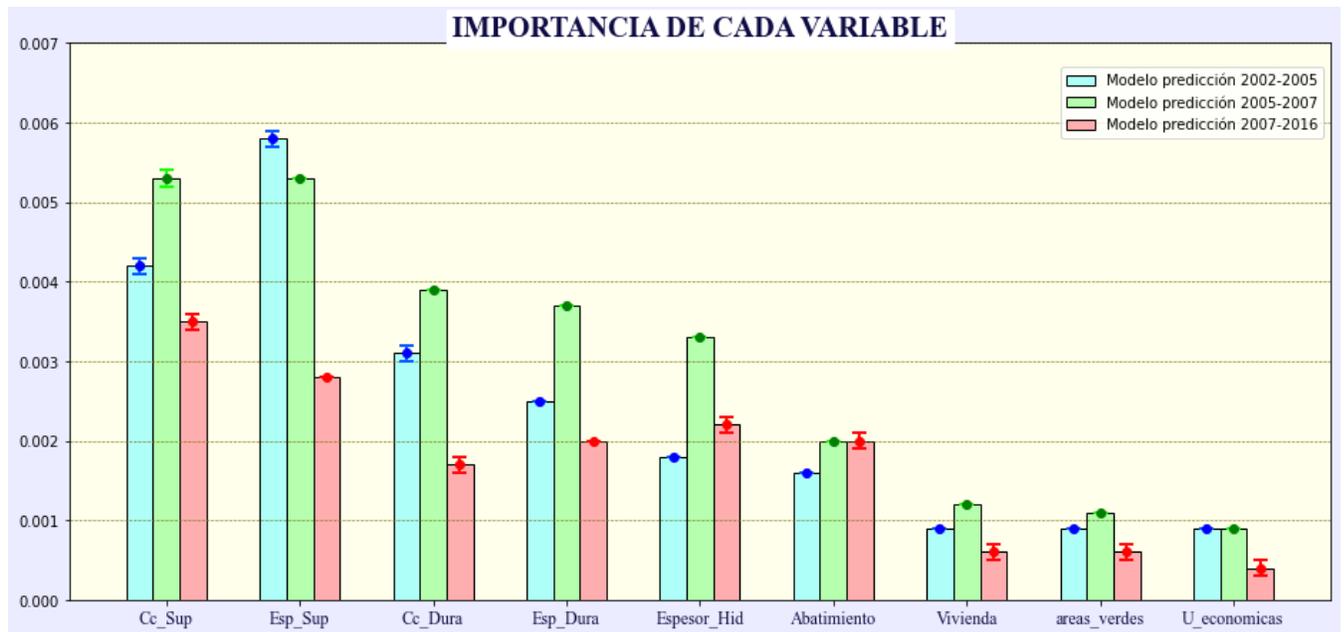


Figura 6-20: Peso de cada predictor en cada uno de los mejores modelos luego de sustituir la tasa de hundimiento promedio de INSAR. Las líneas sobre cada barra representan el margen de incertidumbre

En la exploración del estudio temporal de la subsidencia, hasta ahora no ahondado en la literatura, y bajo la hipótesis de que los tres mejores algoritmos podrían ser equiparados, pues describen el mismo fenómeno en la misma área, una sola red debe tener la capacidad de predecir los hundimientos producto del abatimiento en cualquier periodo. En consecuencia, se elige el modelo con los mejores estadísticos con el fin de cotejar este supuesto.

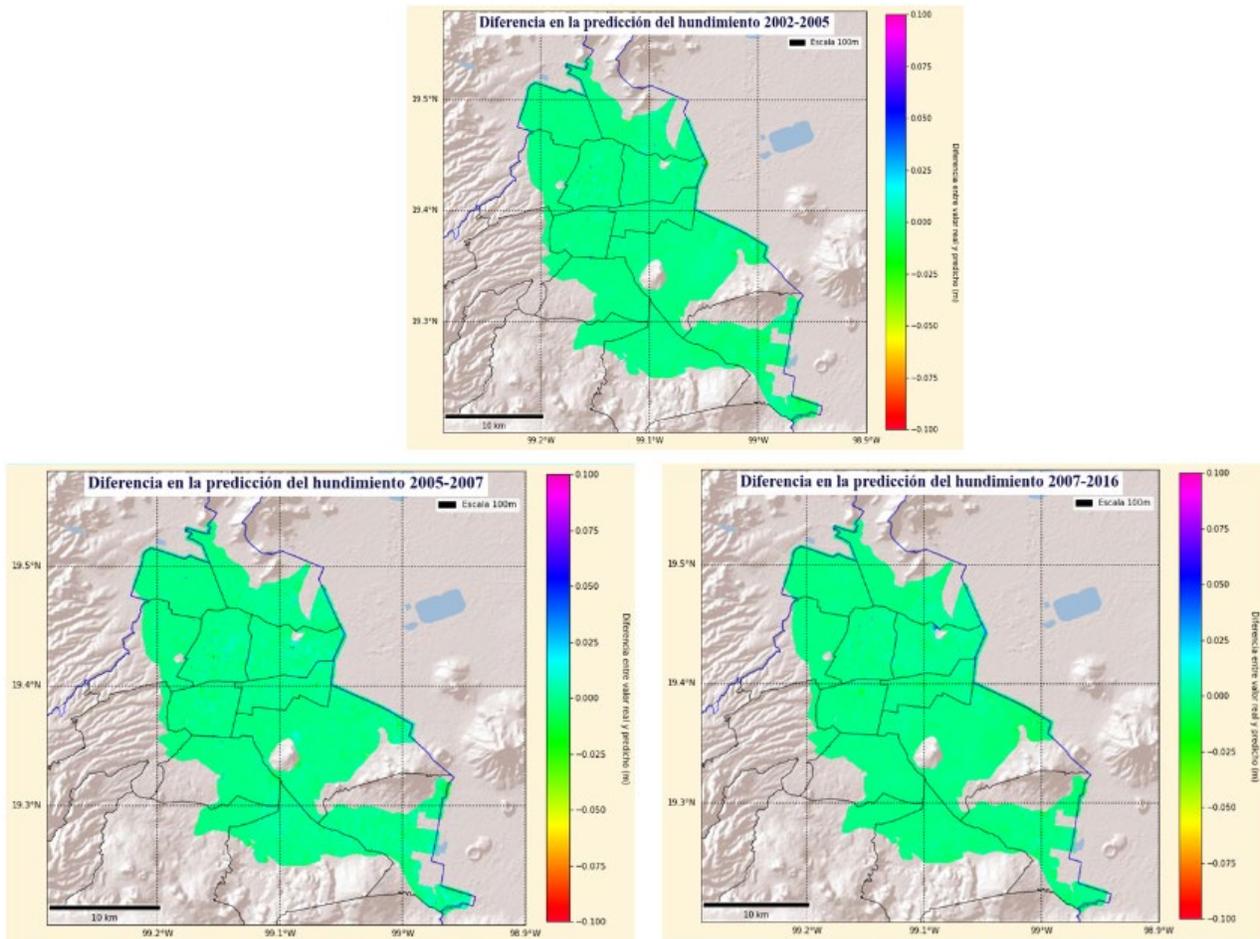


Figura 6-21: Distribución de los errores en el área de estudio por cada modelo.

El modelo para el periodo de abatimiento del 2007-2012, que se retribuye como el mayor aportante a los efectos causados a la tasa de hundimiento en el intervalo 2007-2016, es el que tiene las mejores estadísticas, parte fundamental para augurar un buen comportamiento al describir los otros dos periodos de subsidencia que se extrajeron de los principales modelos restantes. Como evidencia del buen ajuste del modelo escogido se retratan sus curvas de entrenamiento, en ellas, se comprueban sus bajos errores y alto valor del  $R^2$ , también se demuestra la cercanía entre sus curvas de preparación y el requisito de que su curva de entrenamiento siempre sea superior a su curva de validación.

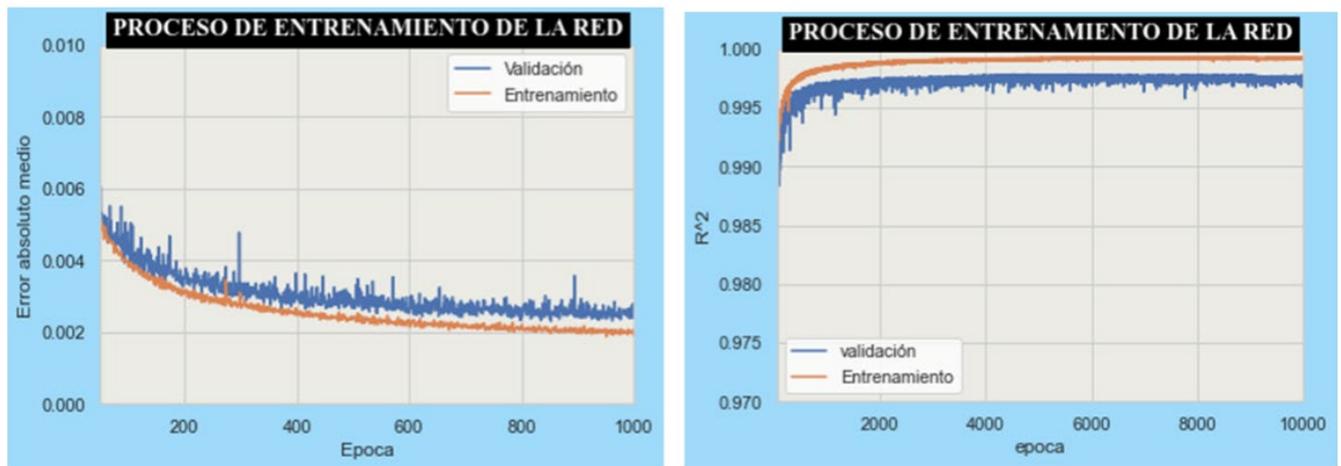


Figura 6-22: Curva de entrenamiento del modelo destacado.

Aun cuando el que se describe es el mejor modelo producido con la base de datos adquirida, la estabilidad del modelo no se alcanza completamente, reflejando ligeras variaciones en los pesos de las variables entre diferentes ejecuciones del algoritmo. En la Figura 6-23 se resumen los resultados del modelo destacado.

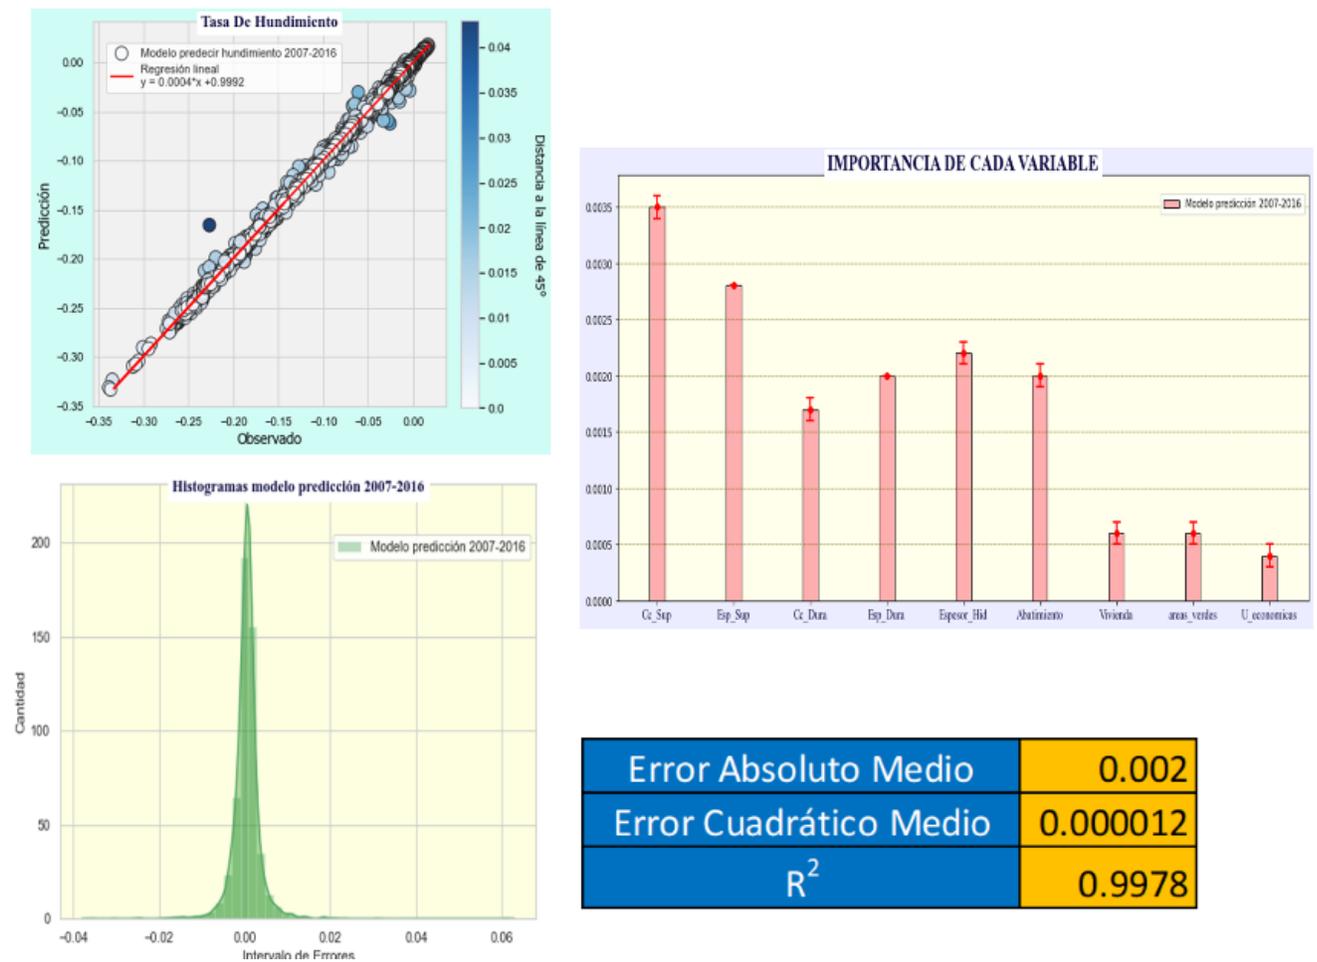


Figura 6-23: Resumen estadístico del mejor modelo, aquel que predice la subsidencia entre 2007-2016 integrando los abatimientos medidos entre 2007 y 2012.

Esta red neuronal entrenada se usa para predecir las tasas de hundimiento de los demás años con los que no fue preparada, de esta manera, se busca evaluar su desempeño para predecir subsidencia temporalmente, y no solo espacialmente. La Figura 6-24 se construye para valorar años anteriores, su pasado. Por su parte, la Figura 6-25 analiza su rendimiento en eventos siguientes, su futuro.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

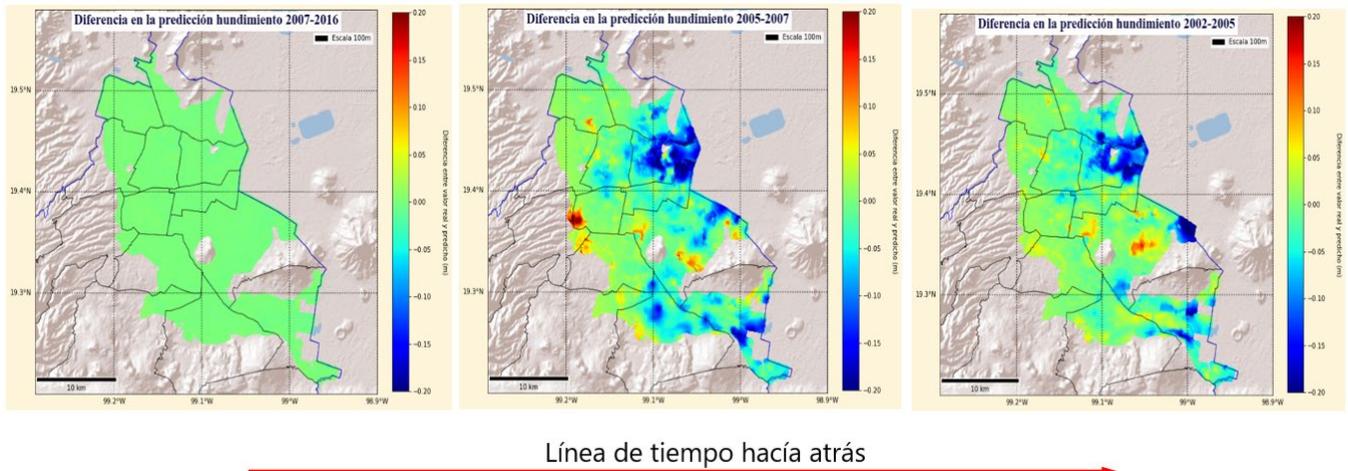


Figura 6-24 Comparación de la distribución de los errores aplicando el modelo a periodos anteriores

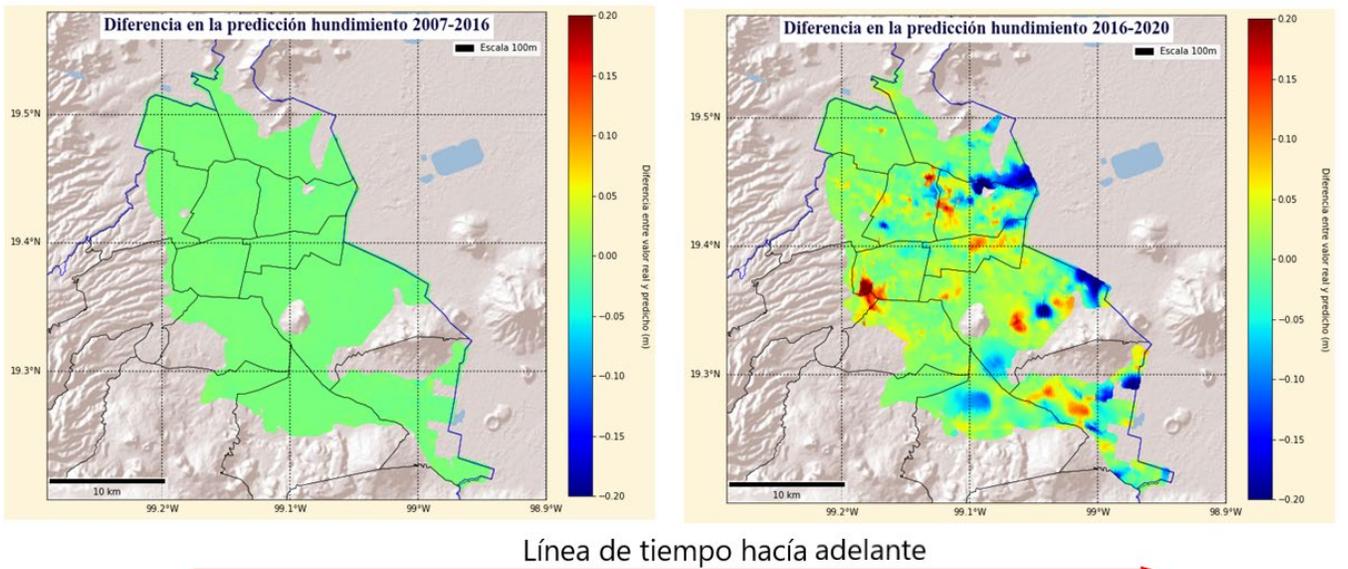


Figura 6-25: Comparación de la distribución de los errores aplicando el modelo a un periodo posterior.

Los grupos de errores altos se tienden a concentrar en las mismas regiones para todos los años, por lo que se descarta la falta de capacidad de esta metodología para pronosticar los cambios, si fuese así, se esperaría una distribución arbitraria del error entre distintos años. La explicación de estas zonas de error puede deberse a la falta de información en algunas bases de datos, sobre todo en la zona oriental del

modelo, o algún fenómeno físico no considerado, más que nada en la parte occidental de la zona, en donde si se cuenta con un volumen alto de muestreo. El valor más alto de error en la parte occidental se debe a un valor anómalo en el banco de nivel utilizado para calibrar el modelo.

Con el fin de averiguar la razón de los errores en las zonas donde se cuenta con mayor densidad de datos, se compara el modelo con las medidas provenientes de InSAR.

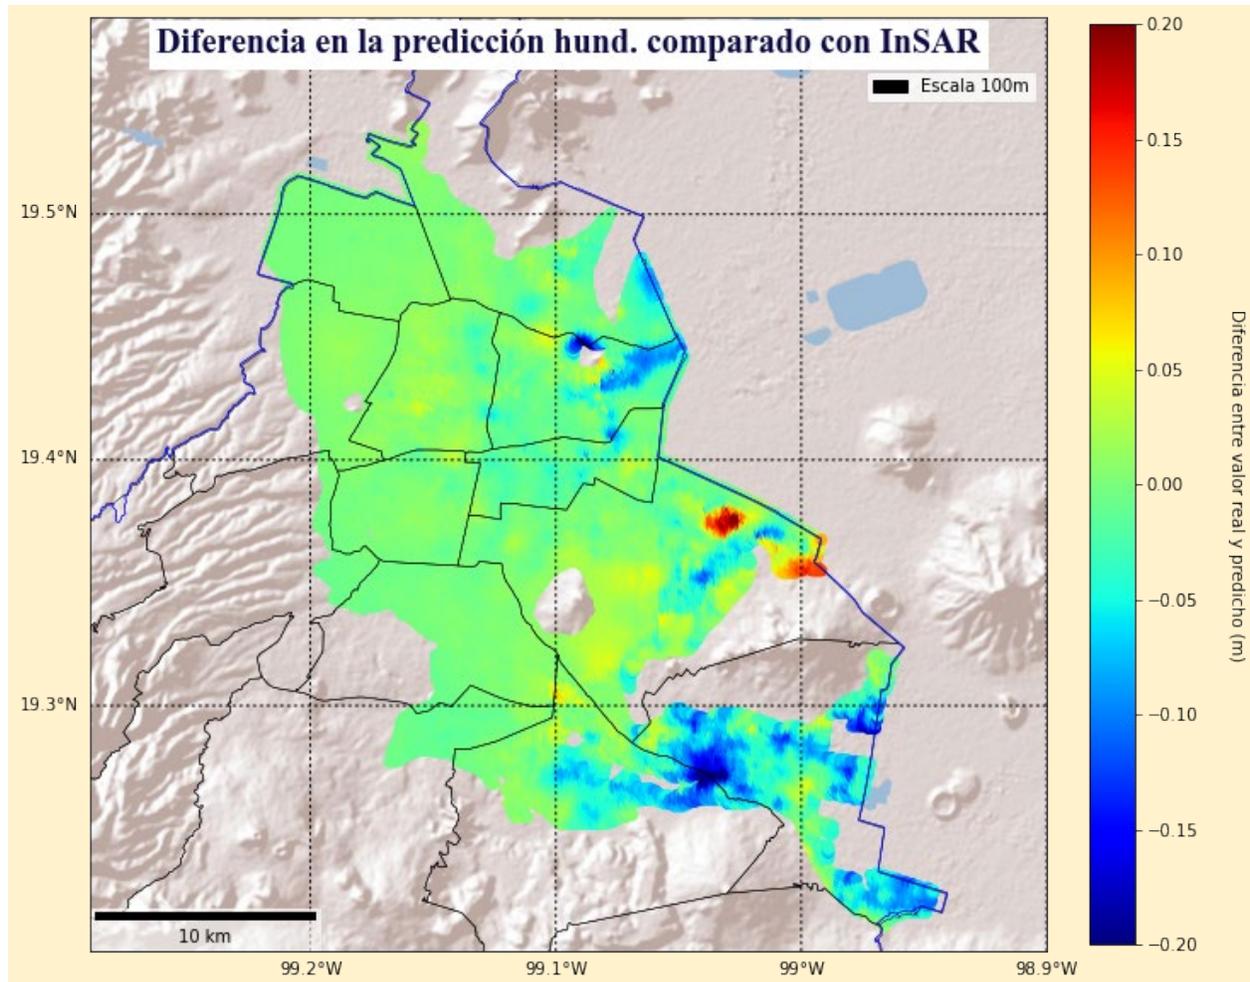


Figura 6-26: Residuales entre el modelo predicho y las medidas de InSAR

En la Figura 6-26 los errores de la zona occidental desaparecen, todas las nubes de incertidumbre se concentran en las áreas con menor densidad de datos, de esta manera, se comprueba como los errores en algunos bancos de nivel y la falta de mayor densidad de ellos en algunas zonas, son el causante de los errores en las zonas occidentales al comparar las predicciones del modelo propuesto para años posteriores y anteriores.

---

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Un procesamiento equivalente se despliega al intercambiar el espesor del acuitardo por el espesor de la hidrofacies A modificada. El razonamiento obtenido es de la misma forma, similar, aunque sus estadísticas entrevén mucha más incertidumbre.

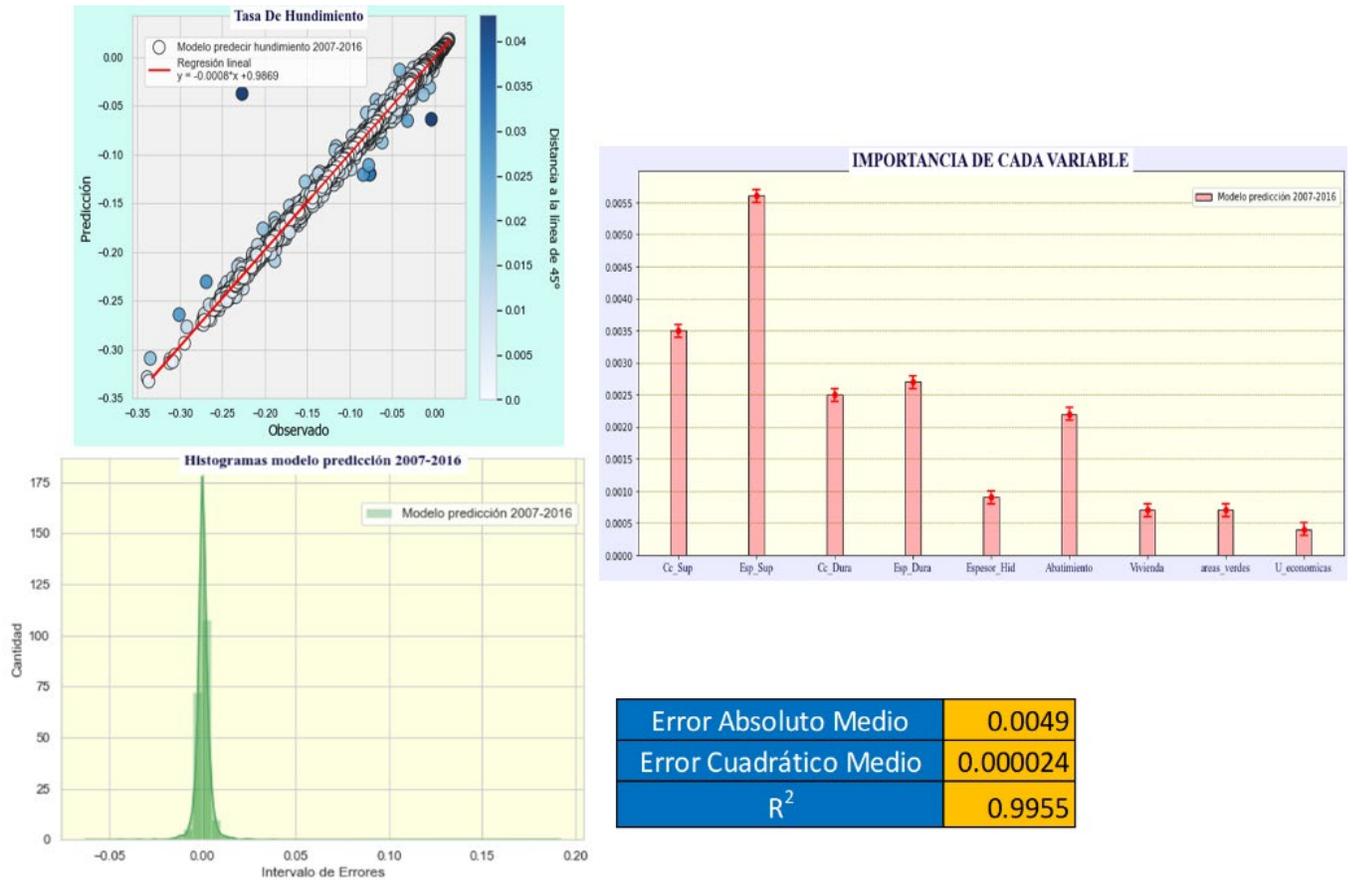


Figura 6-27: Resumen estadístico del mejor modelo sustituyendo el espesor del acuitardo por el espesor de la hidrofacies A.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

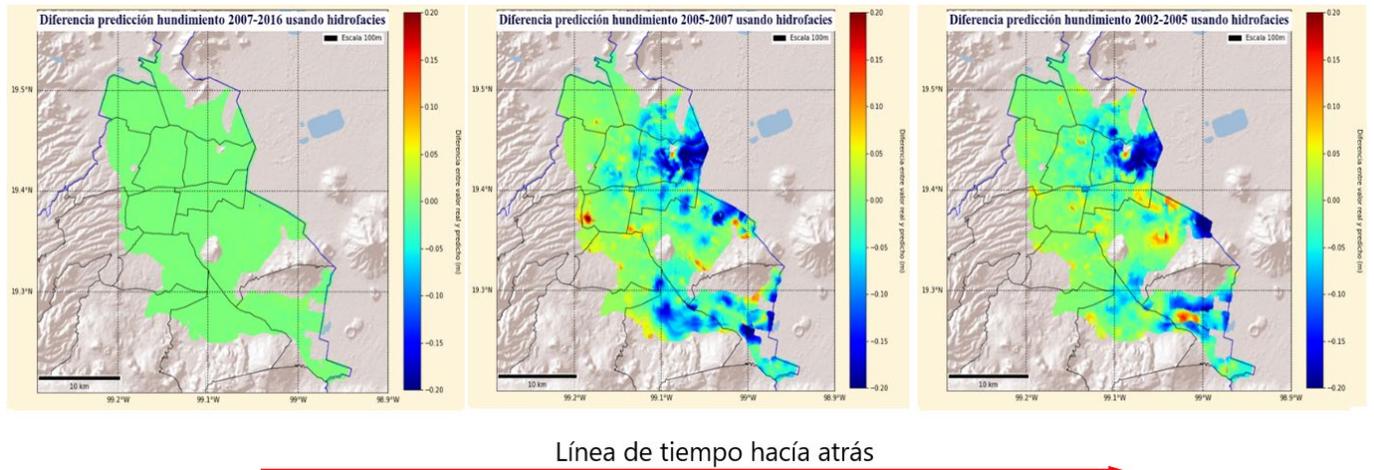


Figura 6-28: Comparación de la distribución de los errores aplicando el modelo a periodos anteriores

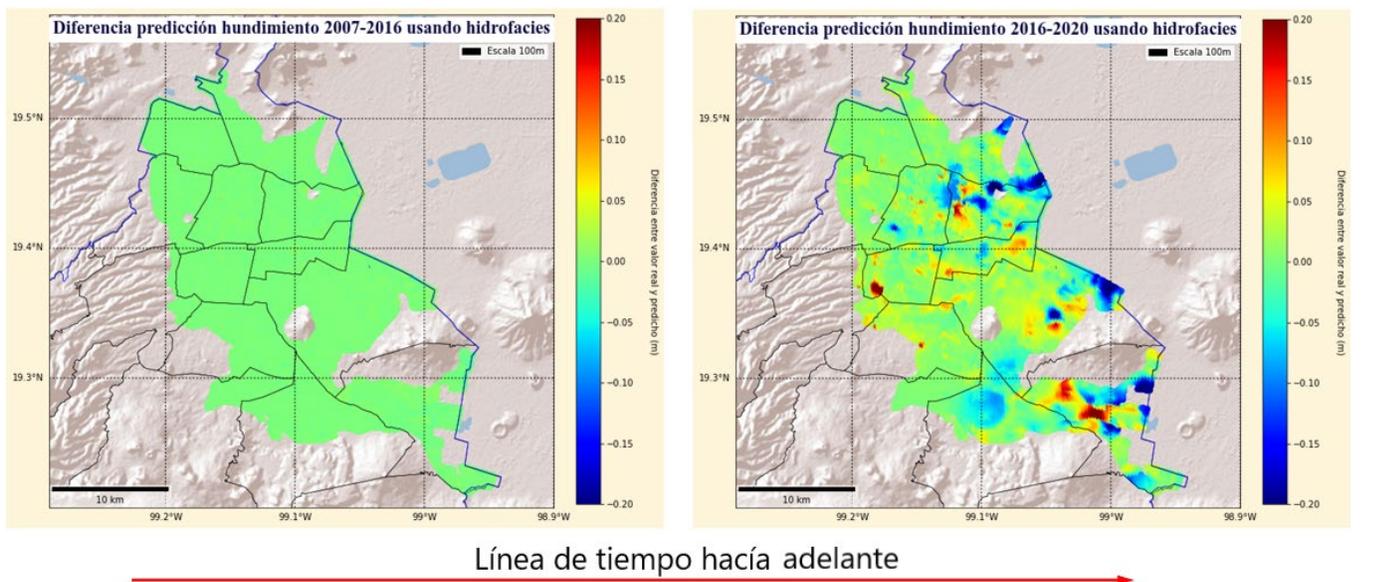


Figura 6-29: Comparación de la distribución de los errores aplicando el modelo a un periodo posterior.

## 7. DISCUSIONES Y RECOMENDACIONES

A lo largo del trabajo se mencionan una serie de recomendaciones para mejorar el modelo, las más importantes son:

- Considerar el retardo no de manera homogénea.
- Reducir los intervalos de abatimiento por medio de nuevos conjuntos de datos a menor escala.
- Recalcular los espesores del acuitado luego de cada periodo de abatimiento, el hundimiento disminuye su valor.
- El índice de compresión puede variar en el tiempo
- Las variables que reemplazan a la carga de preconsolidación se renuevan con el tiempo, buscar censos en la Ciudad para distintos años.
- Se toma un solo valor por cada propiedad de una capa de roca, analizar si un promedio básico, como el usado en este trabajo, representa bien cada propiedad, es el caso del índice de compresión en la Arcilla Superior, para proporcionar un solo valor para esta capa fue preciso promediar todas las medidas verticales de esta propiedad.
- Variar el tipo de interpolador empleado para interpolar o extrapolar los datos, solo se hizo uso del interpolador bilineal.
- El enfoque del retardo homogéneo podría dar resultados más precisos si se tuviera una base de datos de hundimiento a menor escala temporal, quizá por cada año.
- Una fuente de gran incertidumbre es la falta de datos en la zona oriental del modelo, además, se añade más imprecisión al tener que combinar fuentes de datos de diferentes fechas y con archivos en distintos formatos (tablas con valores promediados, archivos físicos y digitales e imágenes).
- Tomar un radio de afectación para cada pozo de extracción.
- Las unidades económicas pueden no ser una medida exacta para medir el nivel de construcciones en una región, datos provenientes de un catastro donde se consignen la cantidad de pisos construidos es un mejor aproximador.

- Las redes neuronales implementadas solo estiman el periodo de mayor influencia sobre la tasa de hundimiento, sin embargo, una perturbación en el abatimiento genera un efecto continuo, por lo que una arquitectura distinta de redes neuronales como las redes recurrentes o las redes de grafos pueden dar mejores resultados, cualquiera de las dos requiere establecer un tiempo cero en donde empieza a ser importante la subsidencia.
- Incorporar otro tipo de variables como los parámetros hidráulicos, relacionados con el retraso, podrían servir para responder las dudas acerca de las zonas en donde se concentran los errores.

El impacto de algunas de estas recomendaciones puede ser explorado si se implementa un modelo sintético. Es posible hacer uso de modelos que estiman la subsidencia, como el desarrollado por (Zapata, Morales, & Herrera, 2017), para valorar las repercusiones en el modelo al efectuar algunas de las anteriores sugerencias. La Tabla 7-1 compara las variables que se tuvieron en cuenta en cada una de las etapas de desarrollo de este trabajo junto con las sugeridas para un modelo sintético.

# APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL MODELADO DE SUBSIDENCIA EN LA CIUDAD DE MÉXICO

Tabla 7-1: Variables utilizadas en cada modelo propuesto.

Correlación datos trabajados			
Variable	Este trabajo	Mejoras a este trabajo	Datos sintéticos
Espesor sedimento	Espesor hidrofacies A predicho con: espesor acuitado, litología y posición x y y	Espesores hidrofacies A predicho con: espesor acuitado, litología y posiciones x, y, más puntos de control. O espesor del acuitado	Espesor hidrofacies A únicamente zona A (Iztacalco, Benito Juárez), o espesor del acuitado.
Abatimiento	Abatimiento en el acuífero inferior	Abatimiento en el acuífero inferior	Abatimiento en el acuífero inferior
Compresibilidad	Coefficiente de compresibilidad	Índice de compresión	Índice de compresión y/o otra serie de variables relacionadas
Historial de esfuerzos	Carga de preconsolidación	Dataset de variables que sustituyen la carga de preconsolidación	carga de preconsolidación o dataset relacionado o valor de la porosidad más esfuerzo efectivo
Retardo	3, 8, 13 0 18 años	1.5, 2, 4, 6.5, 7, 8.5, 12, 13, 13.5, 18, 18.5 y 23 años	Añadir coeficiente de almacenamiento y conductividad hidráulica para determinar un retraso en cada punto
Tasa de hundimiento	Tasa de hundimiento INSAT	Tasa de hundimiento INSAT y red de bancos	Estimación utilizando un modelo que calcule hundimientos

## 8. CONCLUSIONES

Los tiempos de retardo según cada modelo escogido para cada tiempo del abatimiento son de, 4, 1.5 y 2 años. En promedio, se puede inferir que el tiempo de retraso para la zona es de 2.5 años. No obstante, cuando se analizan los resultados de los modelos que usan INSAR el retraso calculado está entre 3 y 8 años. El rango tan amplio de valores se explica por las restricciones en los periodos, para el abatimiento los intervalos son de 5 años, mientras que para la tasa de hundimiento son variables, van desde 2 hasta 9 años. Una falta de escalas más precisas y constantes condiciona de antemano las cantidades producidas. Una segunda aclaración que se debe resaltar es el error cometido al forzar el modelo a manifestar un retraso homogéneo, cuando por la naturaleza del fenómeno se espera una distribución heterogénea. Pese a esto, es posible sugerir que cerca de los 4 años puede ser el periodo de retraso homogéneo para las rocas de la cuenca estudiadas, en caso de requerir una única cantidad que describa toda la zona.

El modelo con el mejor ajuste se logró al alimentar la red con el abatimiento de 2007 a 2012, y ajustarlo con ayuda de los datos de la tasa de hundimiento de 2007 a 2016, registros procedentes de la red de bancos. Una razón que explica el por qué este periodo de abatimiento produce las mejores predicciones radica en el origen de los demás predictores tomados como estáticos, en su mayoría, sobre todo los que reemplazan a la carga de preconsolidación, se censan en años dentro del intervalo temporal de este abatimiento. Con base en este modelo, el almacenamiento de agua perdido se estima en  $3.1 \text{ Km}^3/\text{año}$  en el periodo 2007 a 2016. Según datos de (Chaussard, Havazli, Cabral-Cano, & Solano, 2021) el almacenamiento perdido en estos años es cerca de  $1.73 \text{ Km}^3/\text{año}$ , la diferencia no solo radica en la extensión que cada trabajo abarcó, por el contrario, el cálculo de (Chaussard, Havazli, Cabral-Cano, & Solano, 2021) se basa en la información de pozos registrados por CONAGUA, dejando por fuera los pozos que no son inscritos ante esta agencia del Estado.

De todos los modelos también es posible inferir que, aunque el abatimiento sea la fuerza motora para generar los hundimientos, esta no es la variable más influyente en el modelo. El segundo motor que impulsa este fenómeno es el aumento en la carga de preconsolidación en el terreno, variable que tampoco tiene el peso más grande en el modelo, sin embargo, al sumar la contribución de estos dos factores, se tiene el mayor peso, permitiendo inferir que los generadores de la subsidencia si cobran la mayor importancia, aunque por separado, cada uno cobra una importancia menor.

Por la complejidad que entraña estudiar la subsidencia, implementar una red neuronal que extraiga patrones precisos de este fenómeno requiere una base de datos a una escala menor a 1 km, la escala a 100 m produjo un buen desempeño.

Las variables más importantes para predecir la tasa de hundimiento en orden de importancia son:

1. Cc Arcilla Superior, Cc Capa Dura y los respectivos espesores de estas capas.
2. Abatimiento y espesor del acuitardo superior.
3. Densidad de viviendas, densidad de unidades económicas y densidad de áreas verdes.

En cuanto a la capa de Arcilla Inferior, se precisa una base de datos más robusta para poder estimar su contribución, el análisis actual hace creer que su efecto en los modelos desplegados se debe en su mayoría al interpolar.

Los mejores resultados de la red se obtuvieron usando una normalización estándar y 10000 épocas.

La intensidad de lluvia no es una variable destaca, una parte de este resultado se explica debido a que la base de datos que se tomó no es precisa, discretiza los valores, no obstante, la gran superficie urbanizada de esta región puede ser la causante de la falta de efecto recarga que cumple la intensidad de lluvias sobre el acuífero, sumado a la presencia de un acuitardo en la parte más superficial del terreno.

Los caudales de extracción no tienen una contribución significativa en el modelo, seguramente por no contemplar un radio de afectación, o quizás, no tienen una gran trascendencia para el pronóstico porque algún otro predictor ya está aportando la información de su efecto.

El modelo desplegado demuestra ser una buena aproximación para predecir subsidencia, por lo menos como parte de un primer acercamiento a predicciones futuras; los resultados muestran un buen comportamiento, sobre todo en las zonas donde se concentra la mayor densidad de información que alimenta el modelo, por su parte, las zonas con menor densidad, concentra las mayores incertidumbres, un hecho necesario para un modelo que aprende de los datos.

## 9. REFERENCIAS

- Abdollahi, S., Pourghasemi, H., Ghanbarian, G., & Safaeian, R. (2019). Prioritization of effective factors in the occurrence of land subsidence and its susceptibility mapping using an SVM model and their different kernel functions. *Bulletin of Engineering Geology and the Environment*, 78(6), 4017-4034. doi:<https://doi.org/10.1007/s10064-018-1403-6>
- Acevedo, M., & Vargas, K. (2017). Machine learning: algoritmos de clasificación y sus aplicaciones en el análisis de datos. *Facultad de Estudios Superiores Acatlán, UNAM*.
- Alanis, R. (2003). Caracterización geotécnica del ex lago de Texcoco. *Tesis de Maestría UNAM*.
- Ayala, K. (2013). Influencia de las propiedades índice en el índice de compresión en las arcillas del Valle de México. *Tesis de Maestría, Instituto de Ingeniería, UNAM*.
- Barzegar, R., Asghari, A., Adamowski, J., & Fijani, E. (2017). Comparison of machine learning models for predicting fluoride contamination in groundwater. *Stochastic Environmental Research and Risk Assessment*, 31(10), 2705–2718. doi:<https://doi.org/10.1007/s00477-016-1338-z>
- Bui, D., Shahabi, H., Shirzadi, A., Chapi, K., Pradhan, B., Chen, W., . . . Saro, L. (2018). Land subsidence susceptibility mapping in South Korea using machine learning algorithms. *Sensors (Switzerland)*, 18(8). doi:<https://doi.org/10.3390/s18082464>
- Calvo, M., & Durán, D. (2013). DETERMINACIÓN DEL ÍNDICE DE COMPRESIBILIDAD E INDICE DE EXPANSION DE LOS SUELOS COHESIVOS BLANDOS EN LA ZONA DE TONSUPA EN LA PROVINCIA DEESMERALDAS. *PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR*.
- Camacho, S., & Garzón, A. (2014). Análisis en la variación de esfuerzos efectivos para distintas geometrías de taludes por efectos de filtraciones de agua. *Pontificia Universidad Javeriana*.
- Carrasco, G. (1985). Estudio Geológico del Volcán Popocatepetl. *Inédita*.
- Castillo, I. (2019). Efecto de NanoSiO<sub>2</sub> sobre los límites de consistencia en arcillas del exLago de Texcoco. *Tesis, Facultad de Ingeniería UNAM*.
- Chaussard, E., Havazli, E., Cabral-Cano, E., & Solano, D. (2021). Over a Century of Sinking in Mexico City: No Hope for Significant Elevation and Storage Capacity Recovery. *Journal of Geophysical Research: Solid Earth*.
- Chen, B., Gong, H., Chen, Y., Li, X., Zhou, C., Lei, K., . . . Zhao, X. (2020). Land subsidence and its relation with groundwater aquifers in Beijing Plain of China. *Science of the Total Environment*, 735, 139111. doi:<https://doi.org/10.1016/j.scitotenv.2020.139111>
- Cigna, F., & Tapete, D. (2021). Present-day land subsidence rates, surface faulting hazard and risk in Mexico City with 2014–2020 Sentinel-1 IW InSAR. *Remote Sensing of Environment* 253 .

- Darabi, H., Choubin, B., Rahmati, O., Haghighi, A., Pradhan, B., & Klove, B. (2018). Urban flood risk mapping using the GARP and QUEST models : A. *Journal of Hydrology*. doi:<https://doi.org/10.1016/j.jhydrol.2018.12.002>
- Duque, G., & Escobar, C. (2016). *Geomecánica*. Manizales: Universidad Nacional De Colombia.
- Ebrahimi, H., Feizizadeh, B., Salmani, S., & Azadi, H. (2020). A comparative study of land subsidence susceptibility mapping of Tasuj plane, Iran, using boosted regression tree, random forest and classification and regression tree methods. *Environmental Earth Sciences*, *79*(10), 1–12. doi:<https://doi.org/10.1007/s12665-020-0>
- Espejel, J. (2019). La Zona Metropolitana del Valle de México: arreglos formales y fragmentación. *Economía, sociedad y territorio. SCIELO*. doi:<https://doi.org/10.22136/est20191335>
- Espriu, A. (2021). Dase de datos con información del espesor del acuitardo superior con resolución de 100 m para la Ciudad de México. Ciudad de México, México.
- Fernández, E., Cabral, E., Novelo, D., D, S., Havazli, E., & Salazar, L. (2022). Risk assessment of land subsidence and associated faulting in Mexico City using InSAR. *Natural Hazards*, v. *112*, 37-55.
- Fregosa, E. (2012). Identificación de transmisividad y coeficiente de almacenamiento en un acuífero confinado y la aproximación de Galerkin. *CIMAT, Maestría en Matemática aplicada*.
- Fries, C. (1960). Geología del estado de Morelos y de partes adyacentes de México y Guerrero, región central meridional de México. *Boletín 60*, 236.
- Fries, C. (1962). Resumen de la Geología de la Hoja Pachuca, Estados de Hidalgo y México. Hoja Pachuca 14 Q c 11. *Inst Geol, UNAM, México, D.F.*
- Geotest. (2019). Informa técnico de la empresa Geotest, Geotecnia y Supervisión Técnica S.A. de C.V.
- Giraldo Sierra, M. (1996). Evaluación de un modelo elasto-plástico para predecir el comportamiento de la arcilla de la Ciudad de México. *Tesis de Maestría UNAM*.
- GOBIERNO\_CDMX, G. d. (2021, 08 01). *Portal de datos abiertos, gobierno de la Ciudad de México*. Retrieved from <https://datos.cdmx.gob.mx/dataset/>
- Heisinger, S., & González, L. (2015, Diciembre 10). *centrourbano*. Retrieved from <https://centrourbano.com/opinion/blog-de-urbanismo/crecimiento-de-la-mancha-urbana-de-la-ciudad-de-mexico/>
- Herrera, G. (2021). Informe de niveles piezométricos en el Valle de México.
- IGECEM. (1999). *Instituto de Información e Investigación Geográfica, Estadística y Catastral del Estado de México*. Retrieved from <https://paot.org.mx/centro/libros/proaire/cap02.pdf>
- Juárez, M. (2015). Análisis geoestadístico del subsuelo de la zona lacustre del Valle de México. *UNAM, Tesis de Doctorado*.

Lei, J. a. (2016). Layer normalization.

Lei, J., Ryan, J., & Hinton, G. (2016). Layer normalization.

Libertad, Y. (2018). EVOLUCIÓN DE LA RESPUESTA SÍSMICA DE LA CIUDAD DE MÉXICO. *TESIS DE MAESTRÍA, UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO.*

Libertad, Y. (2021). Base de datos del hundimiento en cada banco de la red de la CDMX y sus alrededores.

López, O. (2002). Compresibilidad unidimensional de la arcilla de la Ciudad de México bajo diferentes condiciones de carga y determinación del coeficiente  $K_0$ . *Tesis de maestría UNAM.*

Luna, C. G. (2014). Respuesta hidrogeofísica del acuitardo de la ciudad de México. *Tesina ingeniería geológica Universidad Nacional Autónoma de México .*

Mánica, M., Ovando, E., Botero, E., Gens, A., & Vaunat, J. (2021). Marco teórico para la modelación numérica de arcillas blandas estructuradas. *XXX Reunión Nacional de Ingeniería Geotécnica. Soc. mexicana de ingeniería geotécnica.*

Marshal, R., & Mazari, M. (1959). *El subsuelo de la Ciudad de México.* Ciudad de México: Instituto de ingeniería UNAM.

Medina, P. (2016). Modelo geoestadístico de hidrofacies y parametrización hidrogeológicas de una porción del acuífero aluvial de la Ciudad de México. *Tesis de maestría Universidad Nacional Autónoma de México.*

Mooser, F. (1975). Los ciclos del vulcanismo que formaron la Cuenca de México. *memorias del XX Congreso Geológico Internacional, Vulcanología del Cenozoico, 337-348.*

Muñoz, S., Sánchez, W., & García, J. (2020). Consolidation theory, a review of the literature. *Rec. Ingeniería, Ciencia, Tecnología e Innovación.*

Narasimhan, T., & Witherspoon, P. (1977). Numerical Model for saturated-unsaturated flow in deformable porous media. *Water resources research.*

ONU. (2018, septiembre 7). *ONU HABITAT.* Retrieved from ONU.ORG.MX: <https://onuhabitat.org.mx/index.php/superficie-de-cdmx-crece-a-ritmo-tres-veces-superior-al-de-su-poblacion>

Ossa, A. (2004). Modelo elastoviscoplastico (EVP) para el estudio de la consolidación unidimensional de los suelos. *Tesis de Maestría UNAM.*

Ovando, E. (2011). Some geotechnical properties to characterize Mexico City clay. *CGS Geotechnical Conference.*

Ovando, E. (2021). Propiedades de las arcillas de la Cuenca de México. *XXV Conferencia Nabor Carrillo. México, Soc. Mexicana de Ingeniería Geotécnica.*

- Ovando, S. (2021). Propiedades de las arcillas de la Cuenca de México. *Conferencia Nabor Carrillo, Soc. Mexicana de Ingeniería Geotécnica*.
- Peña, J. (2020). Pronósticos con algoritmos de aprendizaje automático. Estudio comparativo. *Facultad de Ingeniería, UNAM*.
- Pescador, J. (2016). ANÁLISIS DE LAS CONDICIONES DE FRONTERA EN LA MODELACIÓN DEL FLUJO ENTRE TRES ACUÍFEROS DE LA CUENCA DE MÉXICO. *Repositorio tesis Universidad Nacional De Colombia*.
- Pradilla, E. (2005). Zona Metropolitana Del Valle De México: megaciudad sin proyecto. *Ciudades 9*, 88-104.
- Rahmati, O., Choubin, B., Fathabadi, A., Coulon, F., Soltani, E., Shahabi, H., . . . Tien, D. (2019). Predicting uncertainty of machine learning models for modelling nitrate pollution of groundwater using quantile regression and UNEEC methods. *Science of the Total Environment*, 688, 855–866. doi:<https://doi.org/10.1016/j.scitotenv.2019.06.320>
- Rahmati, O., Falah, F., Amir, S., Biggs, T., Soltani, M., Deo, R., . . . Tien, D. (2018). Science of the Total Environment Land subsidence modelling using tree-based machine learning algorithms. *Science of the Total Environment*, 672, 239–252. doi:<https://doi.org/10.1016/j.scitotenv.2019.03.496>
- REPDA. (2021, 08 10). *Base de datos del REPDA, Comisión Nacional del Agua*. Retrieved from <https://app.conagua.gob.mx/ConsultaRepda.aspx>
- Resendiz, D., Springall, G., Rodriguez, J., & Esquivel, R. (1970). INFORMACIÓN RECIENTE SOBRE LAS CARACTERÍSTICAS DEL SUBSUELO Y LA PRÁCTICA DE LA INGENIERÍA DE CIMENTACIONES EN LA CIUDAD DE MÉXICO. *UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO*.
- Schlaepfer, C. (1968). Hoja México 14Q-h(5), con resumen de la geología de la hoja México, Distrito Federal, Estado de México y Morelos. *Universidad Nacional Autónoma de México, Instituto de Geología, Carta Geológica de México, Serie de 1:100,000*.
- Smith, R., & Majumdar, S. (2020). Groundwater Storage Loss Associated With Land Subsidence in Western United States Mapped Using Machine Learning. *Water Resources Research*, 56(7), 0-12. doi:<https://doi.org/10.1029/2019WR026621>
- Sun, J., Cao, X., Liang, H., Chen, Z., & Li, Z. (2020). New Interpretations of Normalization Methods in Deep Learning. *The Thirty-Fourth AAAI Conference on Artificial Intelligence*.
- Vazqu ez, E., & Jaimes, R. (1989). Geología de la Cuenca de México. *Universidad Nacional Autónoma de México, Geofísica Internacional 28*, 133-190.
- Wang, J., Keming, Y., Wei, X., Shi, X., & Yao, S. (2022). Prediction of Longwall Progressive Subsidence Basin Using the Gompertz Time Function. *Rock Mechanics and Rock Engineering*, 55, 379-398. doi:<https://doi.org/10.1007/s00603-021-02664-z>

- Wilson, B., Hernandez, J., & Meave, T. (1955). Un Banco Calizo del Cretácico en la parte oriental del Estado de Querétaro, México. *sociedad de Geología Mexicana , Boletin 18*.
- Yang, X., Jia, Y., Liu, H., & Shan, H. (2009). Characteristics and causes of the preconsolidation stress of soils in the Yellow River Delta. *Journal of Ocean University of China*.
- Yousefi, S., Pourghasami, H., Emami, S., Pouyan, S., Eskandari, S., & Tiefenbacher, J. (2020). A machine learning framework for multi-hazards modeling and mapping in a mountainous area. *Scientific Reports, 10(1)*, 1–15. doi:<https://doi.org/10.1038/s41598-020-69233-2>
- Zamanirad, M., Sarraf, A., Sedghi, H., Saremi, A., & Rezaee, P. (2020). Modeling the Influence of Groundwater Exploitation on Land Subsidence Susceptibility Using Machine Learning Algorithms. *Natural Resources Research, 29(2)*, 1127–1141. doi:<https://doi.org/10.1007/s11053-019-09490-9>
- Zapata, B., Morales, E., & Herrera, G. (2017). Nonlinear consolidation in randomly heterogeneous highly. *Hydrogeology Journal*.
- Zhi-xiang, T., Pei-xian, L., Li-li, Y., & Ka-zhong, D. (2009). Study of the method to calculate subsidence coefficient based on SVM. *Procedia Earth and Planetary Science 1*, 970–976.

## 10. ANEXOS

Los modelos desarrollados y el conjunto de datos utilizado se pueden obtener en: <https://github.com/Miguel-Angel-Cubillos/Aplicacion-de-inteligencia-artificial-para-estudio-de-hundimientos-en-CDMX>.