

CENTRO DE INVESTIGACIÓN Y DOCENCIA ECONÓMICAS, A.C.



DETECCIÓN DE FUGAS DE AGUA A TRAVÉS DE IMÁGENES SATELITALES Y  
APRENDIZAJE PROFUNDO

TESINA

QUE PARA OBTENER EL GRADO DE

MAESTRO EN MÉTODOS PARA EL ANÁLISIS DE POLÍTICAS PÚBLICAS

PRESENTA

ERICK GABRIEL FAJARDO MARTÍNEZ

DIRECTORA DE LA TESINA: DANIELA ALEJANDRA MOCTEZUMA OCHOA

## Agradecimientos

Quiero agradecer a:

*Mi madre por siempre apoyarme, demostrarme que con trabajo y dedicación todo se puede, que los sueños se cumplen, por ser mi compañera de vida, y por todo el esfuerzo y sacrificio que significa el que yo pueda alcanzar este grado académico.*

*A mi padre por haberme enseñado que el estudio, la disciplina y la resiliencia siempre ganan sobre todas las cosas, y por inculcarme la curiosidad y rigor científico.*

*A mis abuelitas Elsa y Adriana por siempre haberme dado todo el cariño maternal desde chico y enseñado que la nobleza y amor son más fuertes que cualquier otro mal. A mis abuelitos Arturo y Juan por enseñarme que la inteligencia y sabiduría son la llave de muchas puertas.*

*A mi compañera de vida Dani por haberme apoyado en mis decisiones desde que comenzamos a compartir nuestras vidas, por el cariño infinito y por siempre escucharme cuando más lo necesito.*

*A mis amigos que siempre me sacaron risas e hicieron que la maestría fuera un ambiente agradable, por apoyarme en momentos difíciles y por tantas anécdotas que quedan marcadas para la eternidad.*

*A la Dra. Daniela por dirigir este trabajo e impulsarme a perseguir mis sueños. Al Dr. Purón por aconsejarme y ser un gran compañero de trabajo. Al Dr. Alfonso por haber sido mi primer contacto con el sueño que persigo.*

*Por último, a Lupita y a Yahaira por haberme dado la oportunidad de conocer el mundo académico, por creer en mí y por motivarme para seguir un camino apasionante.*

## Resumen

Alrededor del 40 % del agua extraída se pierde a través de fugas de agua. Los métodos para detectar estas fugas son costosos y poco eficaces debido a que dependen de trabajo de campo, el cual es lento y no logra abarcar de manera oportuna la red de tuberías. Las imágenes satelitales representan una alternativa para la detección de fugas de agua dado que son producidas periódicamente y son capaces de captar información del espectro electromagnético con la cual es posible medir ciertas condiciones del suelo como su nivel de humedad o temperatura. En esta investigación, se utilizaron las coordenadas de las fugas detectadas y reparadas durante el periodo 2020-2022 en la ciudad de Aguascalientes, México. Por cada coordenada se descargaron 2 imágenes del satélite Sentinel-2 (S2): 1) imagen de fuga (antes de la reparación) y 2) imagen de no fuga (después de la reparación), además se añadió la temperatura del suelo (LST) como banda espectral para cada imagen de S2 mediante una estimación de LST utilizando imágenes del satélite Landsat 8. En total, 1970 imágenes fueron descargadas. Por último, se entrenaron dos modelos de Redes Neuronales Convolucionales, uno que incluye todas las bandas espectrales de S2 + LST y otro modelo que solo incluyera las bandas de S2. Los resultados obtenidos fueron de 81 % de accuracy para el modelo que incluye bandas S2 + LST y 74 % para el modelo que solo incluye las bandas S2. Estos resultados indican que sí es posible realizar la detección de fugas de agua por medio de imágenes satelitales y aprendizaje profundo.

Palabras clave:

Fugas de agua, Percepción remota, Sentinel-2, Aprendizaje profundo, Redes Neuronales Convolucionales

# Índice

<b>1. Introducción</b>	<b>1</b>
<b>2. Revisión de Literatura</b>	<b>3</b>
2.1. Percepción remota . . . . .	3
2.2. Imágenes satelitales y aprendizaje profundo . . . . .	4
<b>3. Datos y Método</b>	<b>6</b>
3.1. Descarga de imágenes . . . . .	7
3.2. Estimación de la temperatura del suelo . . . . .	10
3.3. Entrenamiento del modelo supervisado . . . . .	13
3.3.1. Modelo base . . . . .	15
3.3.2. Modelo final . . . . .	16
<b>4. Resultados</b>	<b>18</b>
<b>5. Discusión</b>	<b>21</b>
5.1. Limitaciones . . . . .	21
5.2. Recomendaciones para futuras investigaciones . . . . .	21
<b>6. Conclusión</b>	<b>23</b>
<b>7. Referencias</b>	<b>24</b>
<b>Anexos</b>	<b>27</b>
A. Bandas espectrales de Sentinel-2 . . . . .	27

## Índice de figuras

1.	Metodología para la detección de fugas de agua . . . . .	6
2.	Fugas de agua detectadas en la ciudad de Aguascalientes dentro del periodo 2020 - 2022 . . . . .	8
3.	FTA y FTC reparadas en la ciudad de Aguascalientes dentro del periodo 2020 - 2022 . . . . .	9
4.	Comparación de resolución entre imágenes de los satélites S2 y L8. Ambas imágenes capturan la misma área de influencia dentro de un radio de 1000 m. . . . .	11
5.	Distribución de RMSE de todos los modelos de $\widehat{LST}_{10m}$ estimados . . . . .	13
6.	Arquitectura de la CNN empleada . . . . .	14
7.	Desempeño del modelo en términos de accuracy . . . . .	16
8.	Desempeño del modelo en términos de pérdida . . . . .	17
9.	Desempeño del modelo sin $\widehat{LST}_{10m}$ en términos de accuracy . . . . .	19
10.	Desempeño del modelo sin $\widehat{LST}_{10m}$ en términos de pérdida . . . . .	20

## Índice de tablas

1.	Cantidad de fugas detectadas y reparadas en la ciudad de Aguascalientes durante el periodo 2020 - 2022 . . . . .	8
2.	Valores de la tasa de aprendizaje para el modelo base . . . . .	15
3.	Valores de la tasa de aprendizaje para el modelo final . . . . .	16
4.	Evaluación de los modelos entrenados. . . . .	19
5.	Información general de las bandas espectrales de Sentinel-2 . . . . .	27

# 1. Introducción

Las fugas de agua constituyen un gran problema en la ciudad de Aguascalientes, ya que alrededor del 40 % del agua extraída de los pozos se pierde mediante fugas en la red de tuberías que distribuyen dicho recurso (Esparza, 2021; SEGGOB, 2022). Esto es confirmado con información directa de las autoridades encargadas de la detección y reparación de fugas de agua<sup>1</sup> en el municipio de Aguascalientes, debido a que "se estima un índice de agua no contabilizada del 50 % el cual significa que del 100 % del agua extraída, el 50 % del agua no se factura, por lo que se estima que de ese 50 % no contabilizado alrededor del 35 % corresponde a pérdidas por fugas de agua". Las fugas pueden ser causadas por daños físicos en las tuberías, ya sea por envejecimiento, accidentes en la red de tuberías por agentes externos o cambios extremos en los niveles de presión (Agapiou et al., 2014).

De acuerdo con información de la Secretaría General de Gobierno (2022), el municipio de Aguascalientes consume cerca del 70 % del volumen de agua extraída en todo el estado de Aguascalientes, y en 2018 el volumen total producido en el municipio de Aguascalientes fue de 107,541,618 metros cúbicos que, en términos de costos de ese año, representan \$1,010,891,209.2 MXN. Considerando que el 40 % es perdido en fugas de agua, la pérdida del año 2018 en términos de costos fue de \$404,356,483.68 MXN. Aunado a lo anterior, el abatimiento y la profundización de los niveles del acuífero ha aumentado en gran medida debido a la necesidad de cubrir la demanda de agua potable, lo cual ha sido un acto de "sobreexplotación persistente durante 5 décadas de las fuentes subterráneas." (SEGGOB, 2022, p. 112); las pérdidas de agua por fugas representan un abatimiento innecesario.

Actualmente en la ciudad de Aguascalientes, se utilizan 3 métodos de detección de fugas de agua: Inyección de gas helio, inspección termográfica y detección acústica. La inyección de gas helio y la detección acústica son métodos muy efectivos, pero no son capaces de cubrir grandes extensiones de la red de tuberías, ya que, por un lado, la inyección de helio tiene una cobertura de 1 kilómetro por día (LJA, 2022), mientras que la detección acústica cuenta con una cobertura similar y solo puede ser realizada por las noches (BI Noticias, 2022). La inspección por termografía es un método de percepción remota que es aplicado con la ayuda de drones equipados con cámaras térmicas y cuenta con una mayor cobertura, logrando abarcar un área de más de 120 hectáreas en 48 horas (Newsweek, 2022).

A pesar de contar con una buena efectividad para la detección de fugas, los métodos que se utilizan actualmente en la ciudad de Aguascalientes son métodos tradicionales, costosos y que

---

<sup>1</sup> Información proporcionada en una reunión con el Subgerente de distribución y agua no contabilizada de la concesionaria de agua en el municipio de Aguascalientes.

requieren de mucho tiempo dada su naturaleza de trabajo de campo (Huang et al., 2010). Esto abre la oportunidad a la aplicación de métodos innovadores que puedan generar un análisis constante a lo largo del tiempo, abarcar grandes áreas geográficas y ser menos costosos que los métodos tradicionales. Tal es el caso de los métodos que involucran técnicas de percepción remota, específicamente al utilizar imágenes satelitales.

El presente trabajo tiene como objetivo desarrollar un método de detección de fugas de agua mediante el uso de imágenes satelitales y aprendizaje profundo. Este método hará uso de imágenes satelitales multiespectrales e información de campo sobre fugas de agua como insumo para entrenar un modelo basado en una red neuronal convolucional.

La contribución de esta propuesta es agilizar la detección de fugas de agua a partir de un monitoreo constante y a gran escala.

La estructura del trabajo es la siguiente. Primero se define el papel de la percepción remota en la detección de fugas de agua, así como las técnicas de aprendizaje profundo implementadas. Posteriormente se describe el procesamiento de las imágenes satelitales y la aplicación del algoritmo de aprendizaje profundo. Por último, se presentan los resultados del modelo entrenado y la discusión sobre la relevancia de estos resultados para la implementación de política pública.

## 2. Revisión de Literatura

### 2.1. Percepción remota

De acuerdo con Campbell et al. (2022), la “percepción remota es la práctica de derivar información de los cuerpos de agua y la superficie terrestre mediante el uso de imágenes adquiridas desde una vista aérea, utilizando la radiación electromagnética en una o más regiones del espectro electromagnético que es reflejado por la superficie terrestre.” (p. 4). La captación de la radiación electromagnética se hace a través de imágenes que son captadas por sensores acoplados a un dispositivo aéreo, desde aviones tripulados y no tripulados hasta satélites. La principal diferencia entre las imágenes captadas por aeronaves y las captadas por satélites es la resolución espacial, ya que las imágenes satelitales cuentan con una resolución menor, a cambio de cubrir un área mayor. La ventaja de esta práctica es que puede recabar información de grandes áreas geográficas de manera rápida, constante y poco costosa (Agapiou et al., 2013). Por ejemplo, las imágenes del satélite Sentinel-2 son gratuitas y son producidas cada 5 días.

La detección de fugas utilizando imágenes de percepción remota es un problema que ha sido explorado con el uso de diferentes técnicas. Por un lado, se tiene la obtención de imágenes del área de interés por medio de aeronaves tripuladas (Chatelard et al., 2018; Huang et al., 2010; Krapez et al., 2022), mientras que otros estudios utilizan imágenes satelitales (Agapiou et al., 2013; Agapiou et al., 2014; Chen et al., 2020). Ambos tipos realizan el cálculo y análisis de índices conformados por la combinación de diferentes bandas del espectro electromagnético, principalmente para detectar cambios en la humedad del suelo, la salud de la vegetación o la temperatura del suelo, los cuales deben variar, en teoría, en las zonas donde existe una fuga de agua (Agapiou et al., 2013; Agapiou et al., 2014; Chatelard et al., 2018; Chen et al., 2020; Huang et al., 2010; Krapez et al., 2022; Sheffield et al., 2018). Tales índices incluyen el Índice Normalizado de Diferencia de Vegetación (NDVI por sus siglas en inglés), Índice de Agua Superficial (LSWI por sus siglas en inglés), Índice Normalizado de Humedad del Suelo (NSMI por sus siglas en inglés), entre otros. Nguyen et al. (2020) denominan a este tipo de índices como “características espectrales artesanales” (p. 2) dado que su cálculo es manual y depende de parámetros definidos *a priori*. Sin embargo, esto no siempre es así, puesto que muchos índices tienen sustento en cuestiones físicas, como la radiación del espectro electromagnético emitida y absorbida por los objetos.

A pesar de que las imágenes captadas por aeronaves tripuladas o no tripuladas constituyen una buena fuente de información, su obtención está limitada a la cantidad de aeronaves disponibles; suelen ser costosas por la adquisición de vehículos, mantenimiento y operación; y a los planes de ejecución de las autoridades encargadas de la detección. Por lo tanto, las imágenes satelitales

representan una alternativa asequible porque tienen la capacidad de cubrir grandes áreas geográficas por largos periodos de tiempo de manera constante, “llegando a proveer información casi en tiempo real” (Sheffield et al., 2018, p. 9725).

## **2.2. Imágenes satelitales y aprendizaje profundo**

Además del uso de imágenes de percepción remota para la detección de fugas de agua, también ha habido interés en combinar la información de las imágenes satelitales con técnicas de aprendizaje profundo para extraer características importantes de dichas imágenes. Por ejemplo, para el monitoreo de deforestación y áreas de cultivo (Irvin et al., 2020; Kussul et al., 2017; Nguyen et al., 2020), estimación de la vulnerabilidad, riqueza y población de comunidades (Hu et al., 2019; Salas et al., 2021; Yeh et al., 2020), entre otras aplicaciones. Lo que tienen en común estos estudios, además del uso de imágenes satelitales, es el uso de Redes Neuronales Convolucionales (CNN por sus siglas en inglés) para la selección de las variables de interés.

Las CNN han liderado en el análisis de imágenes satelitales dada su gran capacidad para extraer las características de cada imagen que son determinantes para la correcta clasificación de elementos captados en ella (Maggiori et al., 2017; O’Shea & Nash, 2015). Este tipo de redes neuronales son preferidas en el campo del reconocimiento de patrones dada su capacidad para lidiar con la complejidad computacional que exige la información de las imágenes (Albawi et al., 2017; O’Shea & Nash, 2015).

En particular, la complejidad computacional de las imágenes satelitales surge de su naturaleza multispectral, puesto que, comparadas con las imágenes tradicionales que están compuestas por tres colores (el rango visible del espectro electromagnético), las imágenes satelitales contienen más información del espectro electromagnético (Q. Liu et al., 2017; Slavkovikj et al., 2015). Por ejemplo, en términos de “volumen de entrada” para una red neuronal, una imagen a color de  $32 \times 32$  píxeles tiene una dimensionalidad de  $32 \times 32 \times 3$  (altura, ancho, profundidad), donde la profundidad corresponde al rango visible del espectro electromagnético (Rojo, Verde y Azul), lo cual resulta en un volumen de entrada total de 3072. Por otro lado, las imágenes satelitales cuentan con una mayor profundidad debido a que los sensores satelitales pueden captar información del espectro electromagnético más allá de su rango visible. Suponiendo una imagen del satélite Sentinel-2 con la misma altura y ancho, su volumen de entrada será de 13,312 ( $32 \times 32 \times 13$ ), debido a que este satélite es capaz de captar información de 13 bandas del espectro electromagnético, lo cual es mucha más información comparado con las imágenes tradicionales que solo captan 3 bandas espectrales (Campbell et al., 2022).

Las CNN a diferencia de las Redes Neuronales Artificiales (ANN por sus siglas en inglés),

cuentan con dos tipos de capas adicionales que ayudan a filtrar y detectar las características de una imagen, y a reducir la dimensionalidad del volumen de entrada, estas capas son la capa de convolución y la capa de agrupación; también cuentan con capas completamente conectadas que son las mismas que se encuentran en las ANN (Albawi et al., 2017; O'Shea & Nash, 2015).

En general, una CNN recibe la información de los píxeles de la imagen a través de la capa de entrada, esta información pasa a la capa de convoluciones para detectar las características de la imagen y posteriormente la capa de agrupación reduce la dimensionalidad de los datos de entrada, por último, la capa completamente conectada clasifica las imágenes en diferentes categorías con base en las características extraídas (O'Shea & Nash, 2015). El uso de CNN tiene como ventaja el aprovechamiento de toda la información de la imagen para identificar las características espaciales y espectrales (Q. Liu et al., 2017).

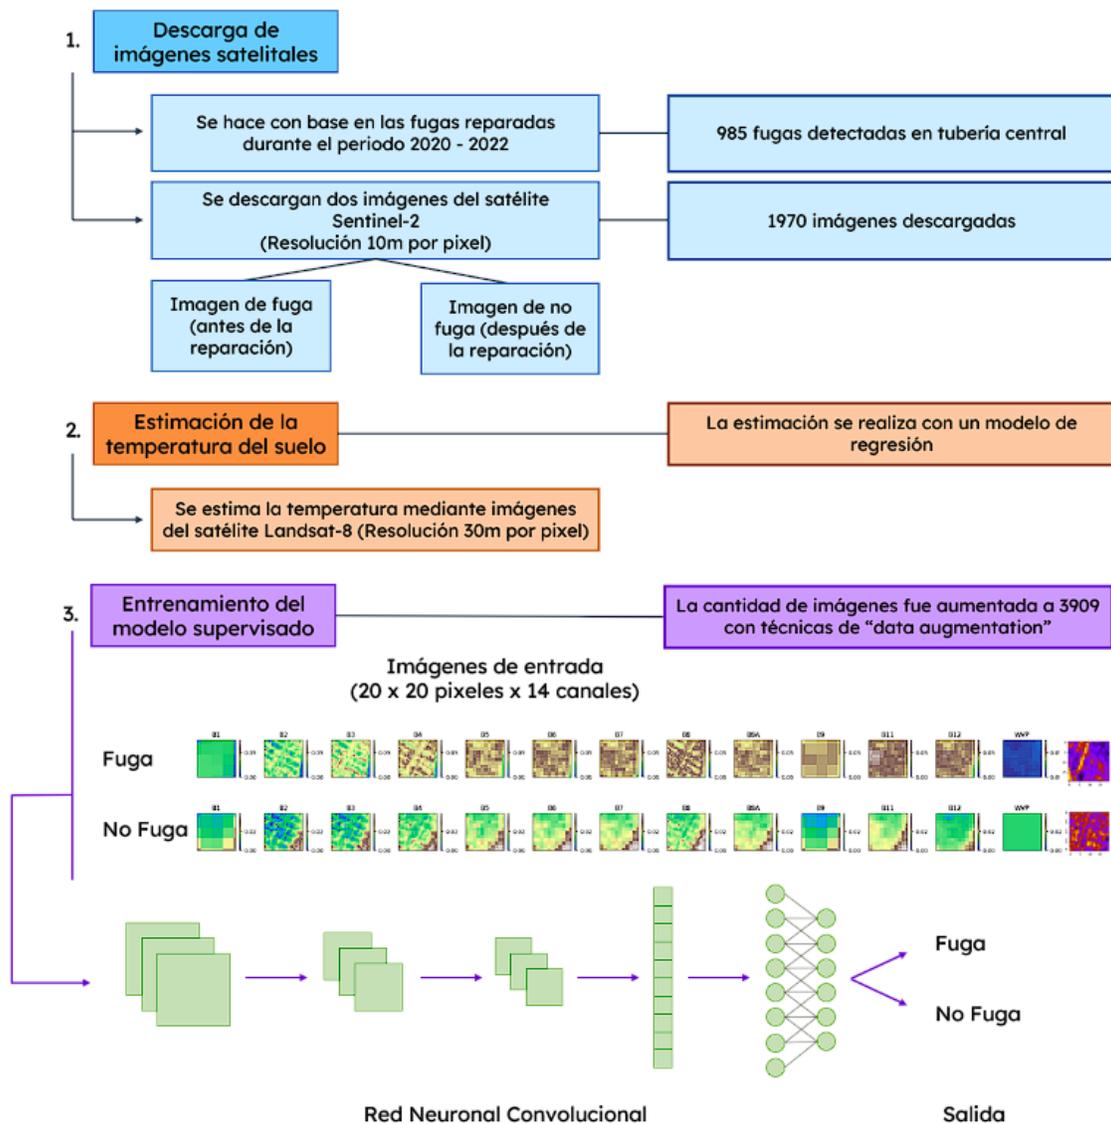
Dentro de los estudios que involucran el uso de imágenes satelitales para la detección de fugas de agua muy pocos hacen uso de técnicas de aprendizaje profundo. Por un lado, Agapiou et al. (2014) emplearon un método para detectar fugas de agua en tuberías subterráneas utilizando imágenes de los satélites SPOT-5 y QuickBird. Este método calculó el Índice de Diferencia Normalizado de Vegetación (NDVI por sus siglas en inglés) y estableció umbrales con la ayuda de Análisis de Componentes Principales para determinar si existía una fuga en alguna sección de la tubería, sin embargo, no reportan algún tipo de resultados de precisión sobre la detección. Por otro lado, Chen et al. (2020) proponen un método que combina imágenes del satélite Landsat 8, información sobre las fugas de agua localizadas mediante inspecciones de campo, y aprendizaje profundo para detectar fugas en canales de irrigación. Además, incluyen al análisis características del ambiente como la temperatura del suelo, cobertura de vegetación y humedad del suelo, las cuales son derivadas a partir de la información captada por los sensores del satélite. El conjunto de datos que utilizaron para entrenar su modelo contaba con 10,000 imágenes (después de técnicas de aumento de datos). Los resultados mostraron una exactitud (*accuracy*) general del modelo de 86 % para áreas rurales y urbanas.

Cabe destacar que ninguno de los estudios encontrados realizó la detección para fugas de agua que se encuentran en tuberías subterráneas combinando el uso de imágenes satelitales y aprendizaje profundo, lo cual es el objetivo y aportación de este trabajo.

### 3. Datos y Método

La metodología propuesta está conformada por tres partes. La primera es la descarga y pre-procesamiento de las imágenes satelitales con base en las coordenadas geográficas de las fugas detectadas en la ciudad de Aguascalientes. En la segunda parte se realiza la estimación de la temperatura del suelo para cada imagen descargada. Por último, la tercera parte corresponde al entrenamiento de la CNN. La figura 1 muestra, de manera general, cada paso de la metodología.

Figura 1: Metodología para la detección de fugas de agua



Elaboración propia.

### 3.1. Descarga de imágenes

Las imágenes satelitales fueron obtenidas del satélite Sentinel-2 (S2 de ahora en adelante). Este satélite fue elegido debido a dos factores: 1) alta resolución de las imágenes y 2) alta periodicidad. Ambas características permiten contar con una fuente de información constante, ya que una imagen es capturada cada 5 días, y la alta resolución permite analizar información multispectral en áreas más pequeñas; además, sus imágenes están disponibles desde el año 2015.

El satélite S2 cuenta con 13 bandas espectrales,<sup>2</sup> donde las bandas 1 y 2 corresponden al espectro visible y se utilizan principalmente para obtener información sobre la vegetación, el agua y nieve; las bandas 3 a 5 abarcan el espectro del rojo al infrarojo cercano y son utilizadas para detectar la salud de la vegetación; las bandas 6 a 9 cubren el espectro del infrarojo cercano y se utilizan para obtener información sobre la vegetación, el agua y el suelo; por último, las bandas 10 a 13 cubren el espectro del infrarojo de onda corta y se utilizan para medir la presencia de contaminantes en la atmósfera. Todas las bandas se incluyeron en el entrenamiento de la CNN, puesto que, se obtienen resultados muy similares comparado con la utilización de índices multispectrales (Chen et al., 2020).

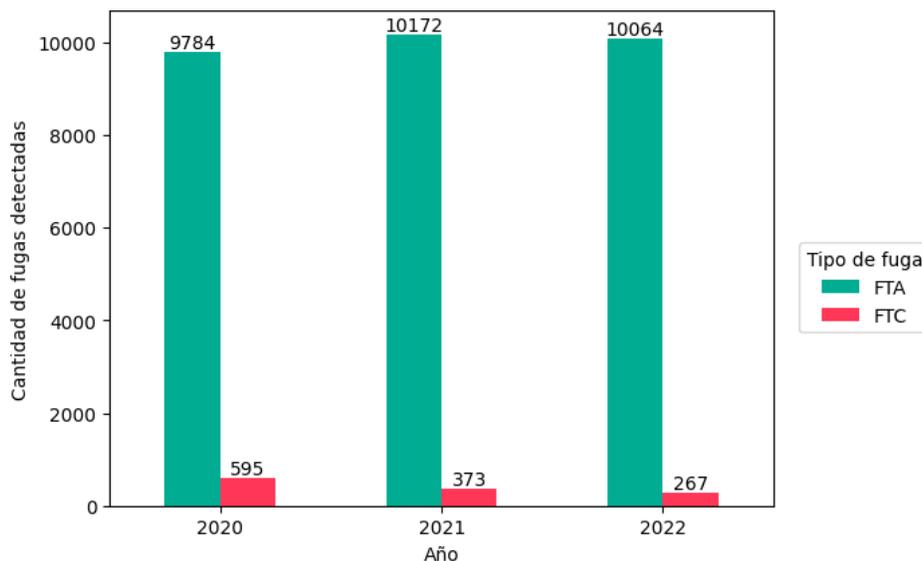
Para realizar la descarga, primero se obtuvieron las coordenadas geográficas de las fugas reparadas en la ciudad de Aguascalientes.<sup>3</sup> Es importante aclarar que existen dos tipos de fugas: fugas en tubería central (FTC) y fugas en toma de agua (FTA). Las FTA son el tipo de fuga que son más fáciles de detectar debido a que se presentan en tuberías superficiales y que conectan a cada hogar a la tubería central. Las FTC son el objeto de interés de esta investigación, ya que son las más difíciles de detectar porque son fugas invisibles que se encuentran bajo tierra en las tuberías centrales. La figura 2 muestra la distribución de fugas de agua detectadas en la ciudad de Aguascalientes durante los años 2020, 2021 y 2022. Es posible apreciar que la mayoría de las fugas detectadas corresponden a FTA, en total, en los tres años se detectaron 30,020 FTA y 1,235 FTC, de las cuales, solo 21,765 (72.37 %) FTA y 985 (79.76 %) FTC fueron reparadas (ver tabla 1).

---

<sup>2</sup> La tabla 5 en la sección de anexos, detalla las resoluciones espectrales y espaciales de cada banda espectral.

<sup>3</sup> Esta información fue proporcionada por la concesionaria de agua del municipio de Aguascalientes. Es un conjunto de datos privado.

Figura 2: Fugas de agua detectadas en la ciudad de Aguascalientes dentro del periodo 2020 - 2022



Elaboración propia con base en los datos proporcionados por la concesionaria de agua del municipio de Aguascalientes.

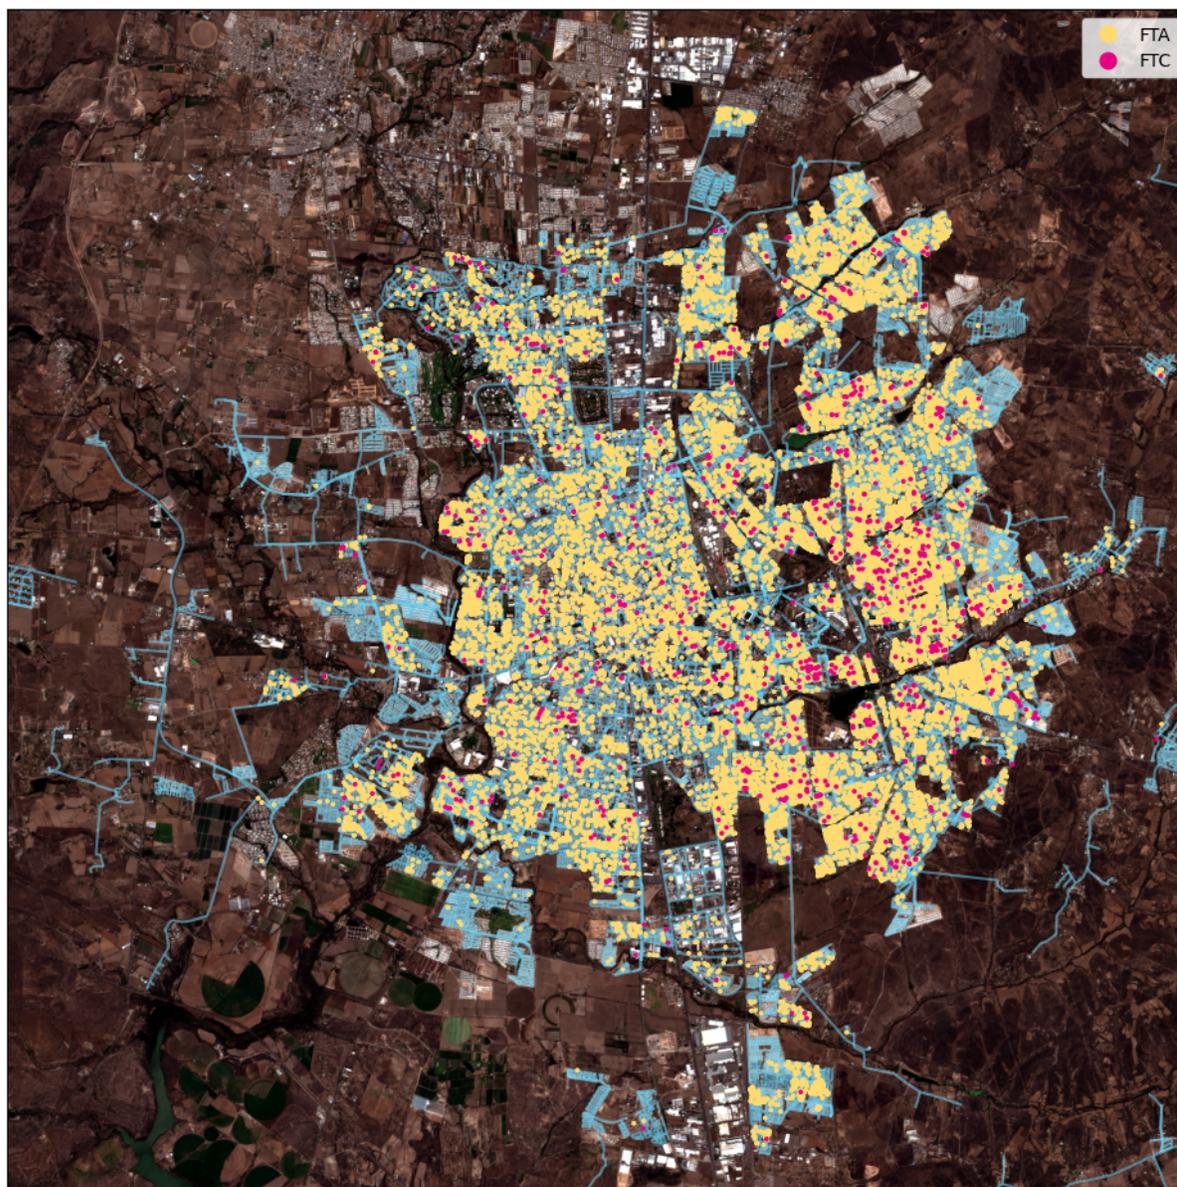
Tabla 1: Cantidad de fugas detectadas y reparadas en la ciudad de Aguascalientes durante el periodo 2020 - 2022

Año	Tipo	Detectadas	Reparadas
2020	FTA	9,784	6,181
	FTC	595	472
2021	FTA	10,172	7,861
	FTC	373	306
2022	FTA	10,064	7,863
	FTC	267	207
Total	FTA	30,020	21,765
	FTC	1,235	985

Elaboración propia con base en los datos proporcionados por la concesionaria de agua del municipio de Aguascalientes.

En la figura 3 se muestra una imagen de la ciudad de Aguascalientes tomada por el satélite S2. Las líneas azules representan la red de tuberías de distribución de agua y los puntos magenta son la ubicación geográfica de cada FTC reparada.

Figura 3: FTA y FTC reparadas en la ciudad de Aguascalientes dentro del periodo 2020 - 2022



Elaboración propia con base en los datos proporcionados por la concesionaria de agua del municipio de Aguascalientes e imágenes del satélite S2.

El conjunto de datos sobre las fugas de agua en la ciudad de Aguascalientes dentro del periodo 2020-2022, además de sus coordenadas geográficas, contenía información sobre la fecha de reparación de cada FTA y FTC detectada. Para delimitar el tamaño y ubicación de cada imagen, se utilizaron dichas coordenadas como centroides para trazar un "buffer"(área de influencia) rectangular de 100 m.

El siguiente paso fue lograr contar con dos categorías de imágenes: imágenes de fugas e imágenes de no fugas. Para ello se optó por utilizar la fecha de reparación como umbral para determinar estas dos categorías, donde una imagen de fuga es aquella que fue tomada antes de la reparación y una imagen de no fuga aquella que fue tomada después de la reparación. La elección de la fecha de reparación como umbral para determinar la categoría de la imagen tiene como propósito: 1) asegurar que las imágenes de no fuga estén situadas sobre un segmento de la red de tuberías y 2) que pertenezcan a una sección donde no existe una fuga, puesto que esta ya fue reparada.

Para el caso de las imágenes de fuga se estableció recolectar imágenes que fueran tomadas entre 5 y 30 días antes de la reparación de la fuga, mientras que para el caso de imágenes de no fuga este criterio fue de 10 a 35 días después de la reparación.

El objetivo de este procedimiento es que la CNN aprenda a partir de ejemplos positivos, es decir, imágenes con presencia de fuga, y ejemplos negativos, el caso contrario.

En total, 1970 imágenes fueron obtenidas (985 imágenes de fuga y 985 imágenes de no fuga), donde cada una cuenta con una dimensión de  $20 \times 20$  píxeles  $\times$  13 bandas espectrales. Es importante destacar que la resolución espacial de las bandas espectrales va desde 10 m hasta los 60 m por píxel. Esto significa, por ejemplo, que para las bandas con una resolución espacial de 10 m, cada píxel representa 10 m superficiales.

### **3.2. Estimación de la temperatura del suelo**

De acuerdo con Chen et al. (2020), una de las características más importantes para la correcta clasificación de fugas de agua por medio de imágenes satelitales es la temperatura del suelo (LST por sus siglas en inglés). La idea detrás de esto es que la presencia de agua debería de alterar la temperatura del suelo alrededor de la zona donde existe una fuga (Huang et al., 2010).

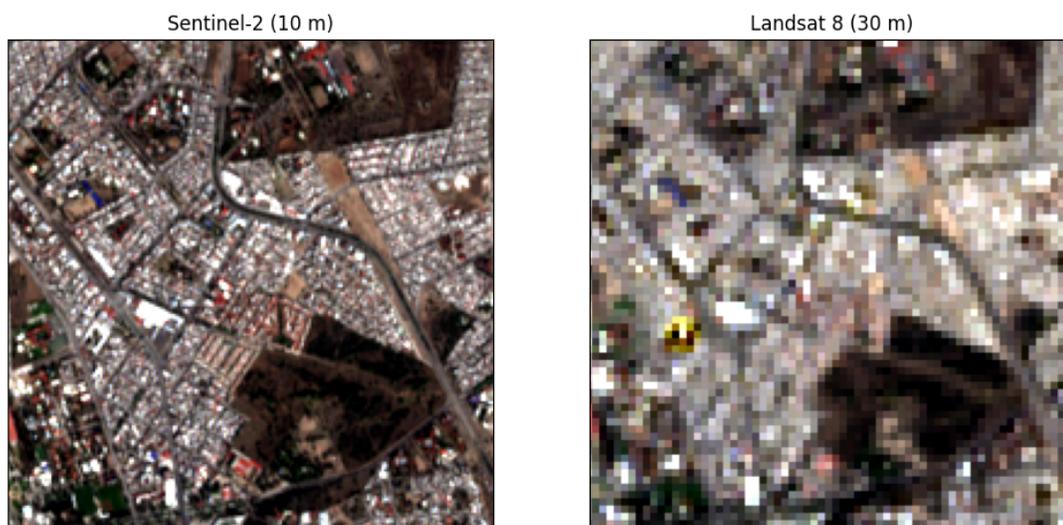
Por lo anterior, se considera importante incorporar LST al análisis, sin embargo, el satélite S2 no cuenta con la capacidad de capturar la información espectral necesaria para derivar LST, debido a que no posee un sensor infrarrojo térmico. Por esta razón, se procedió a realizar una estimación de LST con información del satélite Landsat 8 (L8 de ahora en adelante), el cual sí cuenta con un sensor infrarrojo térmico.

El satélite L8 tiene la capacidad de capturar información de 11 bandas espectrales (9 son captadas por el sensor generador de imágenes terrestres operativo y 2 por el sensor infrarrojo térmico) de las cuales la banda 1 se utiliza para rastrear partículas finas como humo y polvo, y para obtener imágenes de agua superficial; las bandas 2, 3 y 4 también pertenecen al espectro visible y captan los colores azul, verde y rojo; la banda 5 pertenece al infrarrojo cercano y se utiliza para

medir la salud de la vegetación; las bandas 6 y 7 pertenecen al infrarrojo de onda corta y son utilizadas principalmente para medir la humedad de la superficie; la banda 8 es la banda pancromática, la cual presenta sus imágenes en blanco y negro debido a que combina todos los colores visibles y se utiliza para obtener imágenes con mejor resolución; la banda 9 es la encargada de detectar las formaciones de nubes en la atmósfera; por último, las bandas 10 y 11 pertenecen al infrarrojo térmico y miden la temperatura del suelo.

El propósito de estimar LST con información de las imágenes de S2 es obtener una mejor resolución, ya que la resolución más pequeña que logran captar la mayoría de las bandas de L8 es de 30 m por píxel, la cual no es tan buena comparada con la resolución de 10 m de S2. La figura 3.2 muestra una comparación entre las imágenes de los satélites S2 y L8. Ambas imágenes capturan la misma área geográfica de la ciudad de Aguascalientes, y es posible apreciar la diferencia en resolución, siendo la imagen de S2 la que capta más información.

Figura 4: Comparación de resolución entre imágenes de los satélites S2 y L8. Ambas imágenes capturan la misma área de influencia dentro de un radio de 1000 m.



Elaboración propia con imágenes de los satélites S2 y L8.

La estimación de LST es posible gracias al estudio de Onáčillová et al. (2022), donde lograron estimar LST en una resolución de 10 m a partir de un modelo de regresión que toma como predictores a los índices NDVI,<sup>4</sup> NDBI<sup>5</sup> y NDWI<sup>6</sup> calculados con información de L8 (resolución 30 m) (1). Este modelo después es utilizado para estimar LST a 10 m, con los mismos índices

<sup>4</sup> Índice de Vegetación de Diferencia Normalizada

<sup>5</sup> Índice de Diferencia Normalizada de Áreas Construidas

<sup>6</sup> Índice de Diferencia Normalizada de Agua

construidos ahora con la información de las imágenes de S2 (2).

$$LST_{30m} = \beta_1 + \beta_2 NDVI_{30m} + \beta_3 NDBI_{30m} + \beta_4 NDWI_{30m} \quad (1)$$

$$\widehat{LST}_{10m} = \hat{\beta}_1 + \hat{\beta}_2 NDVI_{10m} + \hat{\beta}_3 NDBI_{10m} + \hat{\beta}_4 NDWI_{10m} \quad (2)$$

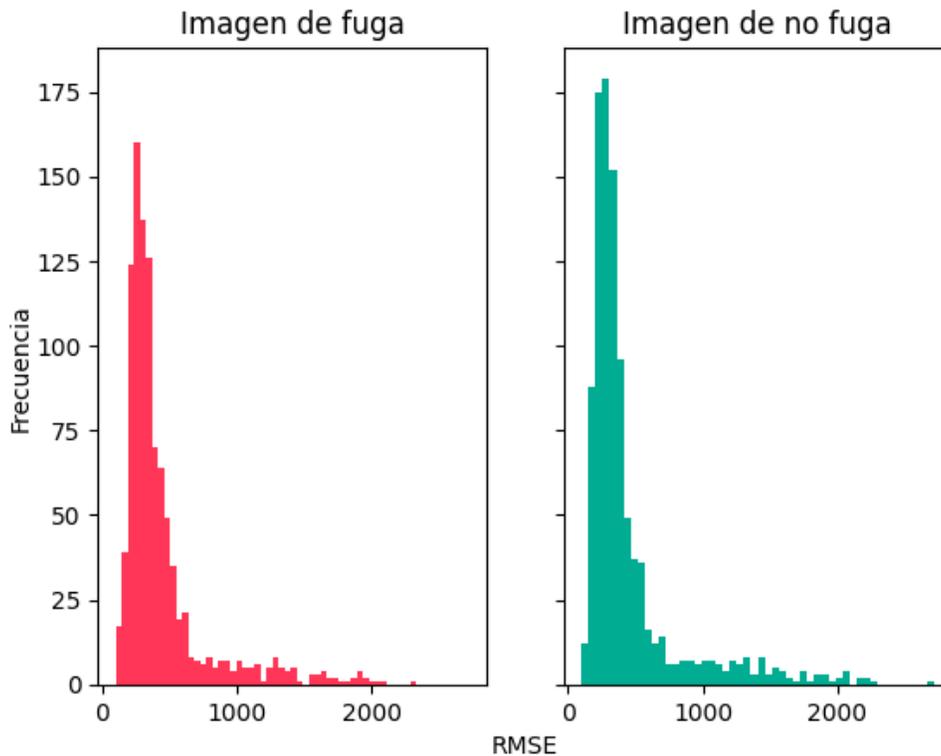
Por lo tanto, el procedimiento para la estimación fue el siguiente:

Para cada imagen de S2:

1. Obtener la imagen más cercana, en términos de fecha, del satélite L8.
2. Calcular los índices NDVI, NDBI y NDWI para las imágenes de ambos satélites.
3. Ajustar el modelo de regresión de la ecuación (1) con los índices de L8.
4. Estimar  $LST_{10m}$  con el respectivo modelo del paso 3.
5. Añadir  $\widehat{LST}_{10m}$  como banda espectral a la imagen de S2.

Al final, 1970 modelos de regresión fueron estimados (uno por cada imagen descargada). Para determinar la fiabilidad de la estimación se calculó, por cada modelo, el error cuadrático medio (RMSE por sus siglas en inglés). Las imágenes de fuga son las que presentan un error promedio menor ( $\overline{RMSE}_{fuga} = 443.19$ ) comparado con las imágenes de no fuga ( $\overline{RMSE}_{no\ fuga} = 453.29$ ), no obstante esta diferencia no es muy grande. La figura 5 muestra la distribución de RMSE para ambos tipos de imagen, es importante tener en cuenta que la magnitud de los valores de esta banda espectral van, en promedio, desde las 43,000 unidades hasta las 50,200 unidades para ambos tipos de imagen. Por lo tanto, la magnitud de los errores reportados es relativamente baja, por lo que el ajuste de los modelos puede considerarse confiable.

Figura 5: Distribución de RMSE de todos los modelos de  $\widehat{LST}_{10m}$  estimados



Elaboración propia.

Una vez agregada  $\widehat{LST}_{10m}$  a cada imagen, las dimensiones de las imágenes pasan a ser  $20 \times 20$  píxeles  $\times$  14 bandas espectrales.

### 3.3. Entrenamiento del modelo supervisado

El entrenamiento del modelo supervisado fue a través de una CNN compuesta por 3 capas de convolución y 2 capas completamente conectadas, la figura 6 muestra la arquitectura completa.

El número de filtros para las capas de convolución fueron 32, 64 y 128, respectivamente, y el tamaño de los filtros fue de  $2 \times 2$ ,  $4 \times 4$  y  $2 \times 2$ , respectivamente. Estos tamaños de filtros fueron elegidos porque el tamaño de "stride" fue de  $1 \times 1$ , lo cual permite que el filtro tenga más oportunidad de desplazarse por la imagen; esto no sería posible para el caso de un filtro y stride más grandes, dado que las dimensiones de las imágenes son muy pequeñas.

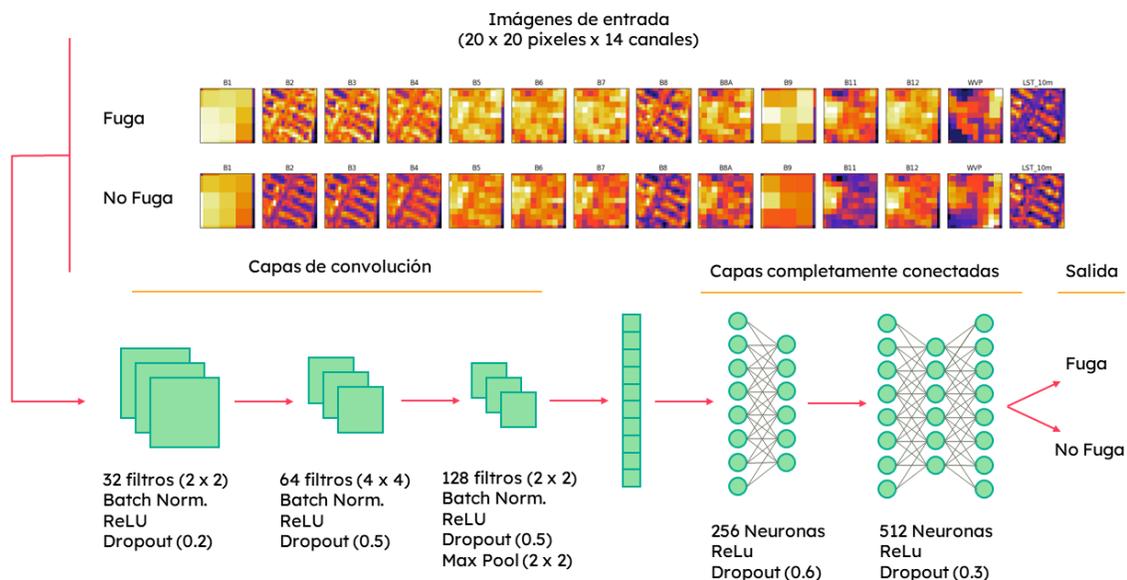
La primera capa completamente conectada estuvo conformada por 256 neuronas, mientras que la segunda capa contuvo 512 neuronas.

Se utilizó la función de activación ReLU<sup>7</sup> en todas las capas de convolución y en las capas densas. Solo la capa de salida utilizó la función sigmoide debido a que se trata de un problema de clasificación binaria. "Batch normalization" fue aplicado en todas las capas de convolución con el objetivo de reducir los tiempos de entrenamiento.

Cabe destacar que esta arquitectura fue elegida de manera experimental, es decir, entrenando varios modelos y modificando aspectos como el número de capas, tamaño y número de filtros, etc. Aunado a esto, se probó la arquitectura empleada en el artículo de Chen et al. (2020), la cual no obtuvo muy buenos resultados. Al final la elección de la arquitectura final fue con base en la que presentara un desempeño balanceado y estable en el entrenamiento.

Para evitar el sobreajuste (overfitting) del modelo, se empleó la técnica de regularización "Dropout", la cual remueve, de manera aleatoria en cada iteración, las conexiones entre nodos (Y. H. Liu & Mehta, 2019). Se aplicó en todas las capas, y la proporción de conexiones removidas fue establecida dependiendo de la cantidad de parámetros entrenables; entre mayor cantidad de parámetros entrenables mayor la proporción de dropout. La lógica detrás de esto es que las capas más grandes, es decir, con una mayor cantidad de entrenables son las más propensas a "memorizar" los patrones del conjunto de entrenamiento, por lo tanto, un mayor dropout ayuda a mitigar este problema.

Figura 6: Arquitectura de la CNN empleada



Elaboración propia.

<sup>7</sup> Rectified Linear Unit.

Dado que el conjunto de imágenes descargadas es relativamente pequeño, se emplearon técnicas de “data augmentation” las cuales consisten en aplicar transformaciones a las imágenes para aumentar la cantidad de imágenes disponibles en el conjunto de datos. Data augmentation se utiliza principalmente cuando el conjunto de datos es pequeño, las clases están desbalanceadas, existen problemas de sobreajuste o para mejorar la capacidad de generalización del modelo (Goodfellow et al., 2016; Zafar et al., 2018). Las transformaciones aplicadas consistieron en rotaciones y transposiciones; gracias a esto, la cantidad de imágenes pasó de 1970 a 3909.

Por último, el conjunto de imágenes fue dividido en 64 % para entrenamiento (2501 imágenes), 20 % para validación (782 imágenes) y 16 % para prueba (626 imágenes).

El entrenamiento del modelo se hizo en dos partes. La primera parte consistió en entrenar un modelo base que presentara un desempeño balanceado, esto en términos de accuracy y en la pérdida del modelo. La segunda parte consistió en utilizar la misma arquitectura y pesos del modelo base para entrenar el modelo final, modificando algunos de los hiperparámetros.

### 3.3.1. Modelo base

Se buscó entrenar un modelo base que no presentara sobreajuste y que la pérdida fuera disminuyendo conforme avanzaba el número de iteraciones. El modelo base fue entrenado con 1000 iteraciones (epochs), utilizando el método Adam de optimización, una tasa de aprendizaje dinámica (la tabla 2 muestra los valores la tasa de aprendizaje de acuerdo con el progreso de iteraciones) y un tamaño de lote (batch size) de 512. Todo el procedimiento fue realizado en Python 3.11.2, específicamente, con la ayuda de las APIs Google Earth Engine para la descarga de las imágenes y Keras para el entrenamiento del modelo.

Tabla 2: Valores de la tasa de aprendizaje para el modelo base

Epochs	Tasa de aprendizaje
0 - 200	0.0001
201 - 400	0.00001
401 - 600	0.000015
601 - 700	0.000001
701 - 850	0.000025
851 - 1000	0.00004

Elaboración propia.

### 3.3.2. Modelo final

El modelo final puede considerarse como la continuación del modelo base, ya que se mantuvo la misma arquitectura, método de optimización y pesos resultantes del modelo base. El entrenamiento del modelo final se hizo con 300 epochs y un batch size de 256 imágenes. La tabla 3 muestra la variación de la tasa de aprendizaje utilizada para el modelo final.

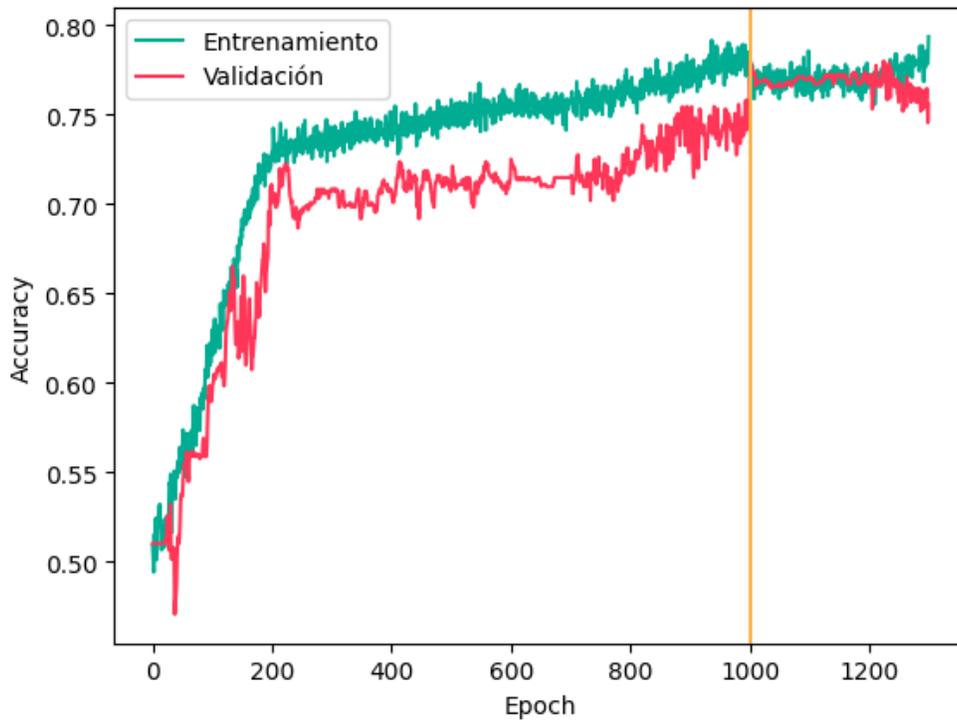
Tabla 3: Valores de la tasa de aprendizaje para el modelo final

Epochs	Tasa de aprendizaje
0 - 200	0.000001
201 - 300	0.00005

Elaboración propia.

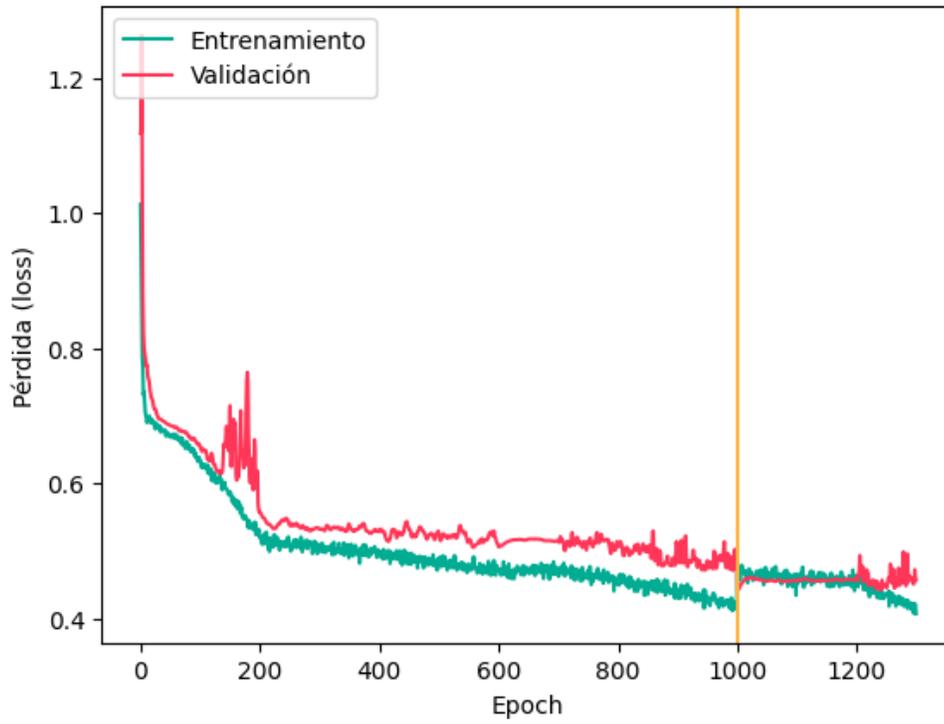
Las figuras 7 y 8 muestran el desempeño del modelo base (epochs 1 a 1000) y del modelo final (epochs 1001 a 1300) en el conjunto de entrenamiento y validación. Las curvas muestran un desempeño balanceado, sin señales de sobreajuste y una reducción constante de la pérdida.

Figura 7: Desempeño del modelo en términos de accuracy



Elaboración propia.

Figura 8: Desempeño del modelo en términos de pérdida



Elaboración propia.

## 4. Resultados

El desempeño del modelo final fue medido a través del conjunto de prueba, el cual consta de 626 imágenes (323 imágenes de fuga y 303 de no fuga). Para evaluar la efectividad de  $\widehat{\text{LST}}_{10m}$  en la predicción, también se entrenó un modelo únicamente con las bandas espectrales de S2, es decir, dejando fuera  $\widehat{\text{LST}}_{10m}$ , pero manteniendo la misma arquitectura y procedimiento de entrenamiento. Las métricas de evaluación para ambos modelos fueron las siguientes:

$$\textit{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$\textit{Recall} = \frac{TP}{TP + FN} \quad (4)$$

$$\textit{Precision} = \frac{TP}{TP + FP} \quad (5)$$

$$F_1\text{-score} = 2 \times \frac{\textit{Precision} \cdot \textit{Recall}}{\textit{Precision} + \textit{Recall}} \quad (6)$$

Donde, *Accuracy* mide la proporción de clasificaciones correctas para ambas categorías de imagen (fuga o no fuga), *Recall* mide la proporción de imágenes de fuga (clasificación verdadera) que fueron clasificadas como fugas, *Precision* mide la proporción de imágenes clasificadas como fugas que realmente son fugas (clasificación verdadera) y *F<sub>1</sub>-score* es la media armónica entre *Recall* y *Precision*.

La tabla 4 muestra los resultados de las métricas de evaluación para ambos modelos. En este caso, es seguro utilizar la métrica *Accuracy* para evaluar, de manera general, el desempeño de los modelos, dado que el conjunto de imágenes muestra clases balanceadas (Irizarry, 2019).

Es posible observar que ambos modelos presentan desempeños similares, sin embargo, el modelo que incluye  $\widehat{\text{LST}}_{10m}$  obtuvo un *Accuracy* de 81 % lo cual es ligeramente mejor que su contraparte, ya que este último modelo que no incluye  $\widehat{\text{LST}}_{10m}$  obtuvo un *Accuracy* de 74 %, habiendo una diferencia de 7 puntos porcentuales. Por lo tanto, esto concuerda con lo encontrado por (Chen et al., 2020) dado que LST sí mejora la predicción del modelo.

Otro aspecto a destacar es que, tanto en *Recall* como en *Precision*, ambos modelos muestran valores muy balanceados para la clasificación de fugas y no fugas. Esto es importante porque significa que los modelos no están especializados en detectar solo una categoría. Sin embargo, es notable que en la categoría de las fugas ambos modelos son capaces de identificar una gran proporción de fugas debido a un *Recall* alto, por otro lado, para la categoría de no fugas ambos

modelos son capaces de detectar más verdaderos positivos, es decir, es muy seguro que las no fugas clasificadas sean en realidad no fugas debido a la alto nivel de *Precision*.

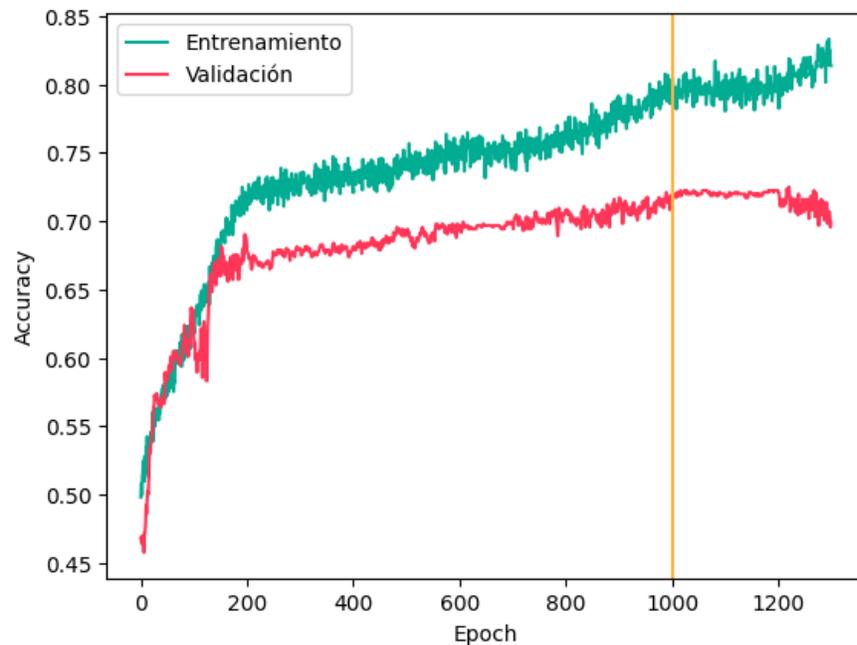
Tabla 4: Evaluación de los modelos entrenados.

Modelo	Clase	Recall	Precision	F1-score
Con $\widehat{LST}_{10m}$	Fuga	0.89	0.75	0.82
	No fuga	0.72	0.88	0.79
Sin $\widehat{LST}_{10m}$	Fuga	0.77	0.72	0.74
	No fuga	0.72	0.77	0.75

Elaboración propia.

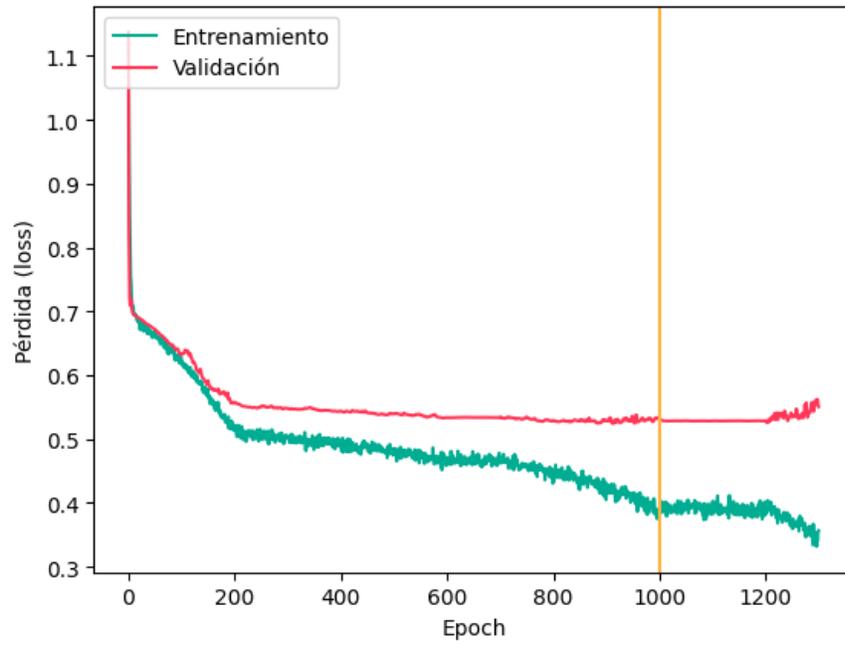
Por último, las figuras 9 y 10 muestran el desempeño en el entrenamiento del modelo que no incluye  $\widehat{LST}_{10m}$ . En ambas figuras se puede notar que el desempeño del modelo se estanca a lo largo del entrenamiento, sobretudo en la pérdida, la cual se mantiene constante a partir del epoch 200. Esto puede deberse a 2 razones: 1) A pesar de que la metodología es la misma, el modelo no está optimizado para obtener los mejores resultados utilizando únicamente las bandas espectrales de S2 o 2)  $\widehat{LST}_{10m}$  sí funciona como un buen predictor y mejora el desempeño del modelo.

Figura 9: Desempeño del modelo sin  $\widehat{LST}_{10m}$  en términos de accuracy



Elaboración propia.

Figura 10: Desempeño del modelo sin  $\widehat{LST}_{10m}$  en términos de pérdida



Elaboración propia.

## **5. Discusión**

La detección de fugas de agua es una acción que requiere de métodos más eficaces, puesto que es un problema complejo que demanda mucha coordinación y atención (Morais & de Almeida, 2007). Además, su prevalencia representa una fuerte pérdida de recursos hídricos, tanto en la ciudad de Aguascalientes (SEGGOB, 2022) como en diversas partes del mundo (Rahman et al., 2018).

Los resultados de esta investigación muestran que es posible realizar la detección de fugas de agua en tuberías subterráneas y en ambientes urbanos mediante el uso de imágenes satelitales y redes neuronales convolucionales.

Las ventajas de este método son: 1) alto grado de reproducibilidad, dado que el código puede ser replicado, ya sea en la nube o en casi cualquier hardware; 2) fácil acceso a imágenes satelitales, gracias a la API de Google Earth Engine; 3) Monitoreo periódico y de gran cobertura, debido a que las imágenes de S2 son generadas cada 5 días. En conjunto, tiene el potencial de reducir esfuerzos y acotarlos a las zonas donde el modelo indique la existencia de una fuga.

### **5.1. Limitaciones**

Este método tiene sus limitaciones en tres aspectos. Primero, la resolución de las imágenes abarca áreas muy grandes ( $20 \text{ píxeles} \times 20 \text{ píxeles} = 200 \text{ m} \times 200 \text{ m}$ ), por lo que, la detección no es tan precisa en términos geográficos. Esto podría solucionarse con el uso de imágenes de mayor resolución espacial, sin embargo, hasta el momento no existen imágenes de acceso abierto, mediante la API de Google Earth Engine, con una resolución mayor a la de S2. Segundo, la cantidad de imágenes para entrenar el modelo está sujeta a la cantidad de fugas detectadas, reparadas y registradas, por lo tanto, es necesario contar a priori con dicho registro, el cual debe incluir las coordenadas geográficas de cada fuga. Puesto que las FTC son fugas difíciles de detectar, es de esperarse que los registros de esta categoría no sean prevalentes. Por último, es posible que la temperatura del suelo no mejore tanto el desempeño de la predicción como debería debido a que en esta metodología es una variable estimada.

### **5.2. Recomendaciones para futuras investigaciones**

El experimento llevado a cabo abre la puerta a futuras investigaciones que intenten mejorar los resultados de la detección con imágenes de mayor resolución o que utilicen un satélite que sea capaz de captar la temperatura del suelo, como por ejemplo L8. También sería importante replicar los resultados para otras ciudades, con el objetivo de comprobar la fiabilidad y consistencia

del método, puesto que pueden existir variables del entorno que alteren el desempeño. En este sentido, también es importante explorar la capacidad de detectar fugas de agua utilizando únicamente las bandas espectrales de S2, es decir, intentar obtener las mejores métricas de desempeño dejando fuera la temperatura estimada del suelo.

El desarrollo de una plataforma interactiva permitiría implementar el modelo de manera continua para la detección de fugas de agua. La idea de dicha plataforma es que tome como insumo la red de tuberías de distribución de agua, para segmentarla en pequeñas imágenes y que dichas imágenes sean clasificadas por el modelo, con el objetivo de lograr un monitoreo constante.

## 6. Conclusión

Este trabajo explora la detección de fugas de agua mediante el uso de imágenes satelitales y redes neuronales convolucionales. La metodología propuesta consiste en la descarga de las imágenes del satélite Sentinel-2, estimación de la temperatura del suelo a partir de un modelo de regresión e imágenes del satélite Landsat 8, y el entrenamiento de una red neuronal convolucional que sea capaz de clasificar las imágenes en fugas y no fugas. La descarga de las imágenes está delimitada a la ubicación geográfica de las fugas, la cual es información privada que fue compartida por la concesionaria de agua del municipio de Aguascalientes.

Los resultados del experimento muestran que es posible realizar la detección de fugas de agua en tuberías subterráneas con una precisión general de 81 %, la cual podría ser mejorada aumentando la cantidad de imágenes disponibles para el análisis y/o con imágenes de mayor resolución espacial, lo cual indica un costo económico mayor.

El aporte de este trabajo radica en proveer una metodología eficaz que ayude a focalizar esfuerzos y recursos para prevenir la pérdida de un recurso tan importante.

Todo el código de este trabajo se encuentra en el siguiente repositorio de Github [https://github.com/erickfama/rs\\_leaks](https://github.com/erickfama/rs_leaks).

## 7. Referencias

- Agapiou, A., Themistocleous, K., Alexakis, D. D., Kourtis, N., Sarris, A., Perdikou, S., Clayton, C. R. I., Phinikaridou, H., Manoli, A., & Hadjimitsis, D. G. (2013). Variations of spectral signature profiles of wet and dry targets for supporting the detection of water-leakages using satellite data. *Remote Sensing for Agriculture, Ecosystems, and Hydrology*. <https://doi.org/10.1117/12.2029289>
- Agapiou, A., Alexakis, D. D., Themistocleous, K., & Hadjimitsis, D. G. (2014). Water leakage detection using remote sensing, field spectroscopy and GIS in semiarid areas of Cyprus. *Urban Water Journal*, 13(3), 221-231. <https://doi.org/10.1080/1573062X.2014.975726>
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*. <https://doi.org/10.1109/icengtechnol.2017.8308186>
- BI Noticias. (2022, 19 de septiembre). *Cada día se detectan 60 fugas de agua potable, visibles e invisibles*. <https://www.binoticias.com/aguascalientes/cada-dia-se-detectan-60-fugas-de-agua-potable-visibles-e-invisibles>
- Campbell, J. B., Wynne, R. H., & Thomas, V. A. (2022). *Introduction to Remote Sensing* (6ta ed.). Guildford Press.
- Chatelard, C., Krapez, J.-C., Barillot, P., Deliot, P., Frédéric, Y.-M., Pierro, J., Nouvel, J.-F., Hélias, F., Louvet, Y., Goff, I. L., & Serra, G. (2018). Multispectral Approach Assessment for Detection of Losses in Water Transmission Systems by Airborne Remote Sensing. En G. L. Loggia, G. Freni, V. Puleo & M. D. Marchis (Eds.), *HIC 2018. 13th International Conference on Hydroinformatics* (pp. 408-418). EasyChair. <https://doi.org/10.29007/4xs9>
- Chen, J., Tang, P., Rakstad, T., Patrick, M., & Zhou, X. (2020). Augmenting a deep-learning algorithm with canal inspection knowledge for reliable water leak detection from multispectral satellite images. *Advanced Engineering Informatics*, 46, 101161. <https://doi.org/10.1016/j.aei.2020.101161>
- Esparza, A. (2021, 6 de agosto). *Se desperdicia 40 % del agua por fugas en Aguascalientes*. <https://www.elsoldelcentro.com.mx/local/se-desperdicia-40-del-agua-por-fugas-en-aguascalientes-7052490.html>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Hu, W., Patel, J. H., Robert, Z., Novosad, P., Asher, S., Tang, Z., Burke, M., Lobell, D., & Ermon, S. (2019). *Mapping missing population in rural india: a deep learning approach with satellite imagery*. <https://doi.org/10.1145/3306618.3314263>

- Huang, Y., Flippo, G., Maas, S. J., & Fletcher, R. S. (2010). Airborne remote sensing for detection of irrigation canal leakage. *Irrigation and Drainage*, 59(5), 524-534. <https://doi.org/10.1002/ird.511>
- Irizarry, R. A. (2019). *Introduction to Data Science: Data analysis and prediction algorithms with R*. CRC Press.
- Irvin, J., Sheng, H., Ramachandran, N., Johnson-Yu, S., Zhou, S., Story, K., Rustowicz, R., Elsworth, C., Austin, K., & Ng, A. Y. (2020). *ForestNet: Classifying drivers of deforestation in indonesia using deep learning on satellite imagery*. <https://doi.org/10.48550/arXiv.2011.05479>
- Krapez, J. C., Sanchis Muñoz, J., Mazel, C., Chaterlad, C., Déliot, P., Frédéric, Y. M., Barillot, P., Hélias, F., Barba Polo, J., Olichon, V., Serra, G., Brignolles, C., Carvalho, A., Carreira, D., Oliveira, A., Alves, E., Fortunato, A. B., Azevedo, A., Benetazzo, P., . . . Le Goff, I. (2022). Multispectral optical remote sensing FOR water-leak detection. *Sensors*, 22(3), 1057-1087. <https://doi.org/10.3390/s22031057>
- Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782. <https://doi.org/10.1109/LGRS.2017.2681128>
- Liu, Q., Zhou, F., Hang, R., & Yuan, X. (2017). Bidirectional-Convolutional LSTM Based Spectral-Spatial Feature Learning for Hyperspectral Image Classification. *Remote Sensing*, 9(12), 1330. <https://doi.org/10.3390/rs9121330>
- Liu, Y. H., & Mehta, S. (2019). *Hands-On Deep Learning Architectures with Python*. Packt Publishing.
- LJA. (2022, 26 de septiembre). *Inicia detección de fugas de agua con gas helio en Aguascalientes*. <https://www.lja.mx/2022/09/inicia-deteccion-de-fugas-de-agua-con-gas-helio/>
- Maggiori, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2017). Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 645-657. <https://doi.org/10.1109/tgrs.2016.2612821>
- Morais, D. C., & de Almeida, A. T. (2007). Group decision-making for leakage management strategy of water network. *Resource Conservation and Recycling*, 52, 441-459. <https://doi.org/10.1016/j.resconrec.2007.06.008>
- Newsweek. (2022). Veolia Aguascalientes implementa tecnología para la detección de fugas (Newsweek, Ed.). <https://newsweek.espanol.com/2022/10/veolia-aguascalientes-implementa-tecnologia-para-la-deteccion-de-fugas/>
- Nguyen, T. T., Hoang, T. D., Pham, M. T., Vu, T. T., Nguyen, T. H., Huynh, Q. T., & Jo., J. (2020). Monitoring agriculture areas with satellite images and deep learning. *Applied Soft Computing*, 95(1), 106565. <https://doi.org/10.1016/j.asoc.2020.106565>

- Onáčillová, K., Gallay, M., Paluba, D., Péliová, A., Tokarčík, O., & Laubertová, D. (2022). Combining Landsat 8 and Sentinel-2 Data in Google Earth Engine to Derive Higher Resolution Land Surface Temperature Maps in Urban Environment. *Remote Sensing*, *14*(16). <https://doi.org/10.3390/rs14164076>
- O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *ArXiv, abs/1511.08458*.
- Rahman, N. A., Muhammad, N. S., & Mohtar, W. H. M. W. (2018). Evolution of research on water leakage control strategies: where are we now? *Urban Water Journal*, 1-15. <https://doi.org/10.1080/1573062X.2018.1547773>
- Salas, J., Zea-Ortiz, M., Villaseñor, E., Pulido, D., & Figueroa, A. (2021). Fine-Grained large-scale vulnerable communities mapping via satellite imagery and population census using deep learning. *Remote Sensing*, *13*(18), 3603. <https://doi.org/10.3390/rs13183603>
- SEGGOB. (2022). Plan Hídrico Estatal 2021-2050 del Estado de Aguascalientes. [https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwi5hNGkkKD\\_AhV7PEQIHezRBg4QFnoECAUQAQ&url=https%5C%3A%5C%2F%5C%2Feservicios2.aguascalientes.gob.mx%5C%2FNormatecaAdministrador%5C%2Farchivos%5C%2FEDO-23-180.pdf&usg=AOvVaw2RvPr3iFvGOMbFxyMkzf07](https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwi5hNGkkKD_AhV7PEQIHezRBg4QFnoECAUQAQ&url=https%5C%3A%5C%2F%5C%2Feservicios2.aguascalientes.gob.mx%5C%2FNormatecaAdministrador%5C%2Farchivos%5C%2FEDO-23-180.pdf&usg=AOvVaw2RvPr3iFvGOMbFxyMkzf07)
- Sheffield, J., Wood, E. F., Beck, H., Coccia, G., Serrat-Capdevilla, A., & Verbist, L. (2018). Satellite remote sensing for water resources management: potential for supporting sustainable development in data-poor regions. *Water Resources Research*, 9724-9758. <https://doi.org/10.1029/2017WR022437>
- Slavkovikj, V., Verstockt, S., De Neve, W., Van Hoescke, S., & Van de Walle, R. (2015). Hyperspectral image classification with convolutional neural networks. *MM '15: Proceedings of the 23rd ACM international conference on Multimedia*, 1159-1162. <https://doi.org/10.1145/2733373.2806306>
- Yeh, C., Perez, A., Driscoll, A., Azzari, G., Tang, Z., Lobell, D., Ermon, S., & Burke, M. (2020). Using publicly available satellite imagery and deep learning to understand economic well-being in Africa. *Nat Commun*, *11*(1), 2583. <https://doi.org/10.1038/s41467-020-16185-w>
- Zafar, I., Tzanidou, G., Burton, R., Patel, N., & Araujo, L. (2018). *Hands-on convolutional neural networks with TensorFlow: Solve computer vision problems with modeling in TensorFlow and Python*. Packt.

## Anexos

### A. Bandas espectrales de Sentinel-2

Tabla 5: Información general de las bandas espectrales de Sentinel-2

Banda	Resolución espacial	Espectro
B1	60 m	Visible
B2	10 m	Visible
B3	10 m	Visible
B4	10 m	Visible
B5	20 m	VNIR
B6	20 m	VNIR
B7	20 m	VNIR
B8	10 m	VNIR
B8a	20 m	VNIR - SWIR
B9	60 m	VNIR - SWIR
B10	60 m	SWIR
B11	20 m	SWIR
B12	20 m	SWIR

VNIR = Espectro visible y cercano al infrarrojo

SWIR = Infrarrojo de onda corta.