

Segmentación de fallas geológicas en imágenes sísmicas ruidosas usando redes neuronales
convolucionales

Álvaro José Ascanio Sánchez

Trabajo de Grado para optar al Título de Geólogo

Director

Yesid Paul Goyes Peñafiel

Geólogo, PhD (c)

Codirectora

Ana Gabriela Mantilla Dulcey

Geóloga

Universidad Industrial de Santander

Facultad de Ingenierías Físicoquímicas

Escuela de Geología

Bucaramanga

2025

“Nuestras virtudes y nuestros defectos son inseparables, como la fuerza y la materia.

Cuando se separan, el hombre ya no existe”

Nikola Tesla.

Dedicatoria

A mi madre Mery Sánchez por siempre confiar en mí, impulsarme a cada día ser mejor y siempre ser mi apoyo incondicional.

A mis hermanos Eylin y Jessé por ser mi motivo de superación y hacer felices mis días con sus ocurrencias. A mis tíos Jairo, Marlene y German por su apoyo y consejos. A Angie y Juan Diego por ser mis compañeros desde la infancia.

A mis abuelos por compartirme de su valiosa experiencia, e inculcar en mí, valores.

A todos ustedes este logro.

Agradecimientos

A PhD (c) Yesid Paul Goyes Peñafiel, por dirigir con dedicación este trabajo de investigación, por ser mi mentor en la universidad, por sus consejos profesionales, apoyo, confianza y paciencia en esta etapa como estudiante de pregrado y joven investigador.

A la geóloga Ana Mantilla Dulcey por codirigir este trabajo y brindarme consejos profesionales para que mis productos sean cada día mejor.

Al geólogo Nicolás Córdoba por asesora mis dudas y compartir su experiencia conmigo.

Al profesor PhD (c) Sait Khurama por su evaluación del plan de investigación y sus valiosos consejos profesionales y apoyo.

Al Semillero de Investigación en Geofísica Aplicada y Computacional (SIGAC) por darme la oportunidad de realizar mi investigación dentro de él y brindarme todos los recursos para su culminación.

A los profesores que me impartieron clases en la Escuela de Geología- UIS, por su esfuerzo y compromiso con mi aprendizaje.

A la Universidad Industrial de Santander por brindarme los espacios y herramientas de calidad necesarias para mi formación como profesional integral.

A todos mis compañeros y amigos que me acompañaron y apoyaron a lo largo de esta etapa.

Tabla de Contenido

	Pág.
Introducción.....	12
1 Planteamiento del problema	14
2 Objetivos.....	16
2.1 Objetivo general.	16
2.2 Objetivos específicos.	16
3 Marco teórico	17
3.1 Método sísmico de reflexión y su adquisición.....	17
3.1.1 Generación de imágenes sísmicas post-apilado	18
3.2 Interpretación de fallas geológicas en imágenes sísmicas	19
3.3 Ruido sísmico	20
3.4 Redes Neuronales Convolucionales (<i>CNN</i>).....	21
3.5 Segmentación binaria de imágenes	22
3.5.1 Métricas para evaluación de tareas de segmentación binaria	24
3.5.2 Bloques de atención (Attention gates)	25
4 Metodología	26
4.1 Fase 1. Construcción de una base de datos de imágenes sísmicas segmentadas con fallas geológicas que presenten variaciones en características como su densidad y ocurrencia ...	26
4.2 Fase 2. Implementación de arquitecturas de redes neuronales convolucionales para la tarea de segmentación automática de fallas geológicas en imágenes sísmicas.....	28
4.3 Fase 3. Evaluación de la influencia del ruido sísmico en la segmentación de fallas geológicas mediante algoritmos de redes neuronales convolucionales.....	29
5 Resultados	31

5.1 Base de datos de imágenes sísmicas segmentadas con fallas geológicas de distinta densidad y ocurrencia	31
5.1.1 Imágenes sísmicas recopiladas y su interpretación de fallas geológicas	31
5.1.2 Análisis estructural básico de la base de datos recopilada.	33
5.1.3 Conjunto de datos adecuados a tareas de aprendizaje automático.	39
5.2 Arquitecturas de redes neuronales convolucionales para la tarea de segmentación automática de fallas geológicas en imágenes sísmicas.	43
5.2.1 Estado del arte de CNN's aplicadas a tareas de segmentación de fallas geológicas. .	43
5.2.2 Criterios utilizados durante el entrenamiento de las CNN's	46
5.2.3 Resultado del entrenamiento y evaluación de las CNN's en la predicción de fallas geológicas.	48
5.3 Influencia del ruido sísmico en la segmentación de fallas geológicas mediante algoritmos de redes neuronales convolucionales.....	54
5.3.1 Inducción de ruido en imágenes sísmicas de evaluación.....	55
5.3.2 Desempeño de los bloques de atención en la predicción de fallas geológicas en imágenes sísmicas ruidosas.	57
6 Conclusiones	65
7 Recomendaciones y trabajo futuro.....	67
8 Repositorio y acceso a datos	67
Referencias bibliográficas	68
Apéndices	74

Lista de Figuras

	Pág.
Figura 1. <i>Esquema general para la generación de imágenes sísmicas post-apilado.</i>	18
Figura 2. <i>Arquitectura de red neuronal convolucional U-Net para la tarea de segmentación de fallas geológicas.</i>	22
Figura 3. <i>Representación de fallas geológicas en máscaras binarias.</i>	23
Figura 4. <i>Estructura del Bloque de Atención (Attention Gate).</i>	26
Figura 5. <i>Esquema de la metodología empleada durante la investigación.</i>	31
Figura 6. <i>Visualización de imágenes sísmicas para el conjunto de datos Sintético 1.</i>	34
Figura 7. <i>Visualización de imágenes sísmicas para el conjunto de datos Sintético 2.</i>	36
Figura 8. <i>Visualización de imágenes sísmicas para el conjunto de datos Real 1.</i>	37
Figura 9. <i>Visualización de imágenes sísmicas para el conjunto de datos Real 2.</i>	39
Figura 10. <i>Gráficos de función de pérdida y métrica de precisión al entrenar red con imágenes sísmicas normalizadas entre -1 y 1.</i>	41
Figura 11. <i>Gráficos de función de pérdida y métrica de precisión al entrenar red con imágenes sísmicas normalizadas entre 0 y 1.</i>	41
Figura 12. <i>Visualización de parches preprocesados de imágenes sísmicas y máscaras de fallas geológicas.</i>	42
Figura 13. <i>Distribución de los conjuntos de datos empleados.</i>	48
Figura 14. <i>Resultados de las predicciones hechas por el modelo Attention U-Net.</i>	49
Figura 15. <i>Resultados de las predicciones hechas por el modelo UNet++.</i>	50
Figura 16. <i>Resultados de las predicciones hechas por el modelo Inception UNet.</i>	51

Figura 17. <i>Predicciones de fallas geológicas realizadas por los modelos Inception UNet, Attention U-Net y UNet++.</i>	54
Figura 18. <i>Visualización de los parches sísmicos con distintos tipos de ruido simulado e intensidad.</i>	56
Figura 19. <i>Predicciones realizadas por los modelos U-Net con ruido simulado al 50%.</i>	57
Figura 20. <i>Máscara binaria real y predichas de fallas geológicas, realizadas por los modelos U-Net complementado con bloques de atención (Attention U-Net) y no complementado con bloques de atención (U-Net) en Real 1 con ruido impulsivo al 10 %.</i>	63

Lista de Tablas.

	Pág.
Tabla 1. <i>Número de parches y tamaño digital de los datasets adquiridos.</i>	43
Tabla 2. <i>Configuraciones de CNN's utilizadas en la segmentación de fallas geológicas.</i>	47
Tabla 3. <i>Desempeño de modelos de CNN's entrenados en las imágenes sísmicas de evaluación.</i>	52
Tabla 4. <i>Influencia del nivel de ruido en métrica de intersección sobre unión (IoU) en U-Net con y sin bloques de atención.</i>	58
Tabla 5. <i>Influencia de nivel de ruido en métrica de precisión en U-Net con y sin bloques de atención.</i>	59
Tabla 6. <i>Influencia de nivel de ruido en métrica de Recall en U-Net con y sin bloques de atención.</i>	60
Tabla 7. <i>Influencia de nivel de ruido en métrica de coeficiente de Dice en U-Net con y sin bloques de atención.</i>	61

Tabla 8. *Evaluación de los modelos U-Net y Attention U-Net en parche del conjunto real 1 a 0 y 10% de ruido impulsivo.* 64

Lista de Apéndices

	Pág.
Apéndices A. <i>Atributos sísmicos en la interpretación de fallas geológicas.</i>	74
Apéndices B. <i>Ejemplos de tipos de ruidos que pueden presentarse en imágenes sísmicas.</i>	74
Apéndices C. <i>Red U-Net complementada con bloques de atención.</i>	76
Apéndices D. <i>Ecuación de normalizado de las imágenes sísmicas en el rango de 0 a 1.</i>	76
Apéndices E. <i>Imágenes sísmicas y máscaras binarias del conjunto de datos Sintético 1.</i>	77
Apéndices F. <i>Imágenes sísmicas y máscaras binarias del conjunto de datos Sintético 2.</i>	78
Apéndices G. <i>Imágenes sísmicas y máscaras binarias del conjunto de datos Real 1.</i>	79
Apéndices H. <i>Inline 201 del conjunto Real 2 y su máscara binaria.</i>	80
Apéndices I. <i>Gráficos de función de pérdida y métricas de precisión e Intersection over Union (IoU) durante el entrenamiento de la red Attention UNet.</i>	81
Apéndices J. <i>Gráficos de función de pérdida y métricas de precisión e intersección sobre unión (IoU) durante el entrenamiento de la red Inception U-Net.</i>	82
Apéndices K. <i>Gráficos de función de pérdida y métricas de precisión e Intersection over Union (IoU) durante el entrenamiento de la red U-Net++.</i>	83

Resumen

Título: Segmentación de fallas geológicas en imágenes sísmicas ruidosas usando redes neuronales convolucionales*

Autor: Álvaro José Ascanio Sánchez**

Palabras Clave: Bloques de Atención, Fallas Geológicas, Inteligencia Artificial, Interpretación sísmica, Redes Neuronales Convolucionales, Ruido Sísmico, Segmentación.

Descripción: La interpretación de fallas geológicas en imágenes sísmicas es fundamental para la realización de modelos geológicos útiles en la caracterización de yacimientos. Tradicionalmente, este proceso ha sido llevado a cabo por profesionales que, mediante el uso de atributos sísmicos, han identificado las fallas geológicas. Sin embargo, estos algoritmos matemáticos han mostrado ser propensos a cometer errores al interpretar fallas en condiciones de ruido sísmico. Otro de los métodos utilizados ha incluido la interpretación de fallas geológicas desde la perspectiva de la segmentación binaria de imágenes, empleando redes neuronales convolucionales complementadas con bloques de atención, las cuales han demostrado ser eficientes en tareas de segmentación de fallas geológicas. Esta investigación tiene como objetivo analizar el desempeño de las redes neuronales en la segmentación de fallas geológicas, incluso en condiciones de ruido sísmico. Para ello, se creó una base de datos de imágenes sísmicas y sus máscaras binarias representativas de las fallas geológicas, con dimensiones de 128x128 píxeles, para ser utilizadas en tareas de aprendizaje automático. Estas imágenes fueron implementadas y evaluadas en las arquitecturas de redes neuronales *Attention U-Net*, *Inception U-Net* y *U-Net++*. Obteniendo un desempeño similar entre los modelos *U-Net++* y *Attention U-Net*, de lo cual debido las bajas diferencias y menor número de parámetros entrenables, se concluyó que la red *Attention U-Net* realiza eficientemente la tarea de segmentación de las fallas geológicas. Posteriormente, esta arquitectura fue evaluada tanto con bloques de atención (*Attention U-Net*) como sin ellos (*U-Net*), utilizando imágenes sísmicas afectadas por cuatro tipos de ruido simulados computacionalmente a distintas intensidades, identificando al ruido impulsivo como el de mayor afectación. Ambos modelos mostraron un desempeño similar, con una leve superioridad cuantitativa de *U-Net*. No obstante, en datos reales con ruido impulsivo del 10 %, *Attention U-Net* presentó segmentaciones más continuas y definidas, superando al modelo *U-Net* por menos del 1 % cuantitativamente.

* Trabajo de Grado

** Facultad de Ingenierías Físicoquímicas. Escuela de Geología. Geología. Director: Yesid Paul Goyes Peñafiel. PhD (c) en Ciencias de la Computación. Codirectora: Ana Gabriela Mantilla Dulcey. Geóloga.

Abstract

Title: Geological fault segmentation in noisy seismic images using convolutional neural networks*

Author: Álvaro José Ascanio Sánchez**

Key Words: Artificial Intelligence, Attention Gates, Convolutional Neural Networks, Geological Faults, Segmentation, Seismic Interpretation, Seismic Noise.

Description: The interpretation of geological faults in seismic images has been fundamental for the realization of geological models useful in reservoir characterization. Traditionally, this process has been carried out by professionals who, by seismic attributes, have identified the geological faults. However, these mathematical algorithms have been shown to be prone to error when interpreting faults in seismic noise conditions. Another method used has included the interpretation of geological faults from the perspective of binary image segmentation, using convolutional neural networks complemented with attention gates, which have proven to be efficient in geological fault segmentation tasks. This research aims to analyze the performance of neural networks in the segmentation of geological faults, even under seismic noise conditions. For this purpose, a database of seismic images and their binary masks representing geological faults, with dimensions of 128x128 pixels, was created to be used in machine learning tasks. These images were implemented and evaluated in the neural network architectures Attention U-Net, Inception U-Net and U-Net++. Obtaining similar performance between the U-Net++ and Attention U-Net models, from which due to the low differences and lower number of trainable parameters, it was concluded that the Attention U-Net network efficiently performs the task of geological fault segmentation. Subsequently, this architecture was evaluated both with attention gates (Attention U-Net) and without them (U-Net), using seismic images affected by four types of computationally simulated noise at different intensities, identifying impulsive noise as the most affected. Both models showed similar performance, with a level of quantitative superiority of U-Net. However, in real data with 10% impulsive noise, Attention U-Net presented more continuous and defined segmentations, quantitatively outperforming the U-Net model by less than 1%.

* Bachelor Thesis

** Faculty of Physicochemical Engineering. Department of Geology. Advisor: Yesid Paul Goyes Peñafiel. PhD Candidate in Computer Science. Co-advisor: Ana Gabriela Mantilla Dulcey. Geologist.

Introducción

Durante la prospección y monitoreo de recursos como los hidrocarburos es necesario comprender los distintos aspectos geológicos que conforman las zonas de interés, para lo cual se estudian diferentes ramas de la geología dentro de las que se encuentran la geología estructural, la geología superficial, la estratigrafía y la petrología, usando herramientas como la geología de campo y la geofísica que hacen parte del proceso de caracterización integrada de un yacimiento.

En la fase de exploración de hidrocarburos se utiliza el método geofísico de sismica de reflexión en el que mediante un arreglo de sensores se registra el comportamiento en superficie de las ondas mecánicas generadas artificialmente. Estas ondas se reflejan y refractan según las características estratigráficas y estructurales del subsuelo, donde posteriormente mediante el procesamiento de la información sísmica permiten generar imágenes del subsuelo denominadas imágenes sísmicas. Una parte fundamental de la caracterización integrada de un yacimiento de hidrocarburos implica la interpretación de las imágenes sísmicas, en estas se identifican y segmentan diferentes características estructurales y estratigráficas presentes como las superficies de estratificación, cuerpos geológicos intrusivos, pliegues, trampas estructurales, entre otros, que definen aspectos como el volumen de un yacimiento, tipo de trampa, condiciones geomecánicas, condiciones petrofísicas y demás, que permiten acotar las áreas de interés para una posterior etapa de explotación.

La interpretación sísmica es una tarea que, aunque depende de la calidad de los datos y la experiencia de quien la realiza, requiere mucho tiempo, implicando retrasos en el proceso de caracterización y el aumento de los costos operacionales para una empresa. Parte fundamental de este proceso de interpretación sísmica incluye la segmentación de fallas geológicas, realizada en software comercial como lo son OpendTect y Petrel por un intérprete que cuenta con experiencia especialmente en situaciones desafiantes como zonas con fallas relativamente pequeñas, zonas de

alta densidad de fallas o con presencia de fallas aproximadamente paralelas a superficies de estratificación entre otras.

Sin embargo, uno de los problemas a los que se enfrentan los intérpretes es el ruido presente en las imágenes sísmicas, el cual es generado por la interferencia de señales que no son representativas de las características del subsuelo y que producen un enmascaramiento de la información como la ubicación de las fallas geológicas dificultando el proceso de interpretación sísmica.

Por consiguiente, para mejorar la interpretación de fallas geológicas en imágenes sísmicas ruidosas normalmente se busca mejorar la relación de la señal y el ruido mediante procesos como filtros de ruido durante la adquisición en campo, edición de trazas ruidosas, apilamiento de ondas con punto medio común (CMP) y filtrado de frecuencias que posiblemente estén asociadas al ruido (Anderson & McMechan, 1988). No obstante, estos procesos en algunas situaciones no consiguen suprimir la totalidad del ruido sísmico.

Una manera de abordar el problema se enfoca en el mejoramiento del proceso de interpretación en imágenes sísmicas ruidosas, es en este caso donde la inclusión de tecnologías como la inteligencia artificial pueden ser ventajosas ya que son capaces de reconocer características que definen una falla geológica en las imágenes sísmicas, y generar predicciones que puedan ser evaluadas. En el campo de la geología se ha utilizado la inteligencia artificial para intentar resolver diversos problemas, como la predicción de sistemas de pórfidos (Mantilla Dulcey, 2023) y la predicción de propiedades físicas de las rocas (García-Arias et al., 2024). Las Redes Neuronales Convolucionales (*CNN*) son un tipo de algoritmo de inteligencia artificial aplicado en datos matriciales como las imágenes, con diversas aplicaciones en distintas áreas del conocimiento como la medicina, donde se ha empleado en la segmentación de órganos como el páncreas (Oktay

et al., 2018) y vasos sanguíneos en imágenes de retina (Li et al., 2021), así como en geología en tareas como la segmentación de fallas geológicas en datos sísmicos (Álvarez Castillo et al., 2022; Wu et al., 2019; Dou & Li, 2024), relacionada con el presente trabajo.

1 Planteamiento del problema

Durante la fase de exploración y reevaluación de reservas de hidrocarburos, se realiza un proceso denominado caracterización integrada de yacimientos por parte de las empresas petroleras en el que se busca entender el subsuelo y sus características en un área determinada, lo que genera información clave para la viabilidad de un proyecto. La caracterización integrada de yacimientos involucra varias fases que incluyen, interpretación sísmica, modelamiento estático y simulación numérica. A lo largo del proceso de interpretación de imágenes sísmicas, se realizan actividades como la identificación y segmentación de los horizontes de formaciones geológicas, extracción de cuerpos geológicos como domos salinos, intrusivos ígneos y la interpretación espacial de las fallas geológicas, las cuales están involucradas en el proceso de migración de hidrocarburos y la generación de trampas estructurales para el almacenamiento de este. El proceso de segmentación es realizado por un profesional, quien cuidadosamente identifica manualmente las distintas fallas, comúnmente en secciones 2D con direcciones Este-Oeste, Norte-Sur o aleatorias según lo considere el profesional en el seguimiento de las fallas geológicas interpretadas, lo que incrementa el tiempo y costo operacional para una empresa en fases como la exploración. Adicionalmente, condiciones estructurales como la densidad y ocurrencia de fallas geológicas y el ruido presente en las imágenes sísmicas plantean desafíos en la interpretación, debido a la capacidad que tienen las fallas de cambiar la orientación y forma de las capas geológicas, haciendo difícil el seguimiento de horizontes estratigráficos.

El ruido en imágenes sísmicas es uno de los problemas que en geofísica se han tratado de resolver a lo largo de los años definido como una señal de interferencia no deseada, este puede ser producido por factores externos, generalmente ambientales y factores propios de la adquisición. Este ruido oculta en las imágenes sísmicas la información adquirida del subsuelo, lo que dificulta el proceso de interpretación. Algunos esfuerzos se enfocan en la mitigación del ruido mediante técnicas como los filtros de frecuencias asociados a algún tipo de ruido relacionado espacial y/o temporalmente con la señal sísmica y la reducción del ruido durante el procesamiento sísmico donde se realiza un apilado de las señales que se promedian para un punto común en profundidad haciendo que el ruido disminuya. Sin embargo, en algunos casos el ruido sísmico persiste haciéndolo difícil de eliminar. Otra de las técnicas novedosas consiste en el uso de algoritmos de inteligencia artificial como las redes neuronales convolucionales las cuales según el estado del arte han demostrado ser eficientes en tareas como la reconstrucción de imágenes sísmicas ruidosas y la segmentación automática de fallas geológicas.

Por consiguiente, en el siguiente trabajo surge la necesidad de investigar acerca de la afectación del ruido de las imágenes sísmicas en la calidad y precisión de la segmentación (extracción automática) de fallas geológicas, considerando variables estructurales como la densidad y ocurrencia de fallas en las imágenes sísmicas, al aplicar modelos de inteligencia artificial basados en redes neuronales convolucionales.

2 Objetivos

2.1 Objetivo general.

Segmentar las fallas geológicas presentes en imágenes sísmicas ruidosas usando redes neuronales convolucionales.

2.2 Objetivos específicos.

Construir una base de datos de imágenes sísmicas segmentadas con fallas geológicas que presenten variaciones en características como su densidad y ocurrencia (sección 5.1).

Implementar arquitecturas de redes neuronales convolucionales para la tarea de segmentación automática de fallas geológicas en imágenes sísmicas (sección 5.2).

Evaluar la influencia del ruido sísmico en la segmentación de fallas geológicas mediante algoritmos de redes neuronales convolucionales. (sección 5.3).

3 Marco teórico

3.1 Método sísmico de reflexión y su adquisición

Uno de los métodos utilizados para la exploración del subsuelo es el método sísmico de reflexión, en este se realiza la adquisición y procesamiento de señales generadas por ondas mecánicas que atraviesan el subsuelo. Este proceso permite obtener una representación de la disposición de las estructuras del subsuelo en imágenes sísmicas post-apilado, que pueden presentarse en tres dimensiones en forma de cubos sísmicos o en dos dimensiones en imágenes sísmicas. El método sísmico utilizado para la obtención de imágenes post-apilado se basa en la propiedad de impedancia acústica la cual depende directamente de la velocidad de propagación de las ondas y la densidad en el medio que atraviesan, los cambios de esta propiedad en profundidad son representados con picos en los registros de cada geófono (Milsom & Eriksen, 2013). En consecuencia, las variaciones en las propiedades físicas de las rocas permiten definir unidades litológicas dentro de un yacimiento.

Para la adquisición de los datos sísmicos se utiliza una fuente de energía impulsiva o vibratoria para generar las ondas elásticas que se propagan hacia el subsuelo pasando por capas de rocas que poseen propiedades físicas y litológicas de interés. Las ondas experimentan una partición de energía cada vez que encuentran a su paso una interfaz entre dos capas con velocidades y densidades diferentes; una parte de la energía se transmite y otra se refleja. La energía que se refleja forma el campo de ondas que contiene información de las amplitudes, longitudes de onda, fases y tiempos dobles de los reflectores del subsuelo. Cuando estos campos de onda llegan a la superficie son captados por instrumentos de medición llamados en general geófonos y esta información se almacena en forma digital en cintas o discos duros en los equipos de registro (Yajaira Herrera & Norman Cooper, 2010). El tiempo en el que las ondas regresan a los geófonos en superficie está directamente relacionado con la profundidad del horizonte reflectante y la

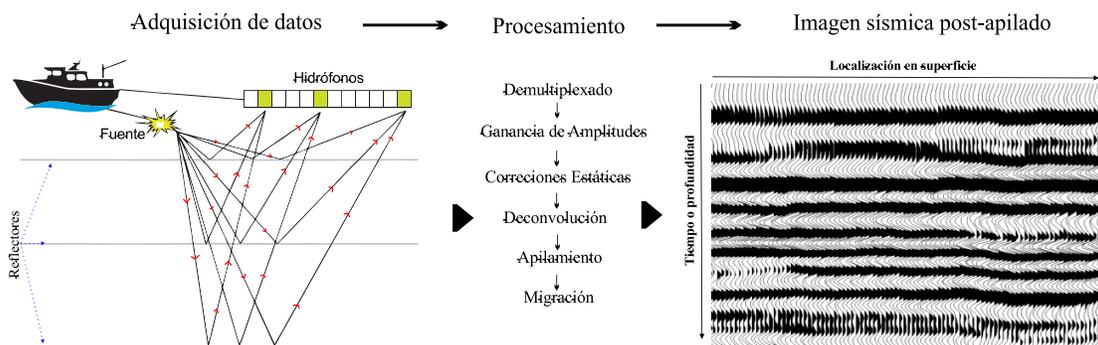
velocidad del sonido entre la superficie y el reflector. Los datos adquiridos son procesados de acuerdo con la información que se planea obtener, en el caso de la sísmica de reflexión el objetivo es obtener información de la estructura lo más acertada posible del subsuelo mediante lo que se conoce como imágenes sísmicas post-apilado.

3.1.1 Generación de imágenes sísmicas post-apilado

Para la obtención de imágenes sísmicas post-apilado los datos recopilados siguen un proceso (ver Figura 1) que incluye principalmente, recuperación de amplitudes perdidas debido a la profundidad, correcciones en los datos sísmicos de tiempo, amplitud y contenido de frecuencias, deconvolución de la onda generada por la fuente, apilamiento de trazas sísmicas con un origen común (*stacking*) que consiste en sumar todas las trazas (información recopilada por cada geófono) que corresponden a un mismo punto de reflexión, y el ajuste de la posición real de los reflectores mediante un proceso conocido como migración (Talagapu, 2005). Una vez finalizado el procesamiento, en la sísmica 2D los datos suelen representarse en forma de secciones transversales donde la escala vertical es el tiempo de viaje bidireccional *TWT* (*Two-Way Traveltime*) de las ondas o profundidad y la escala horizontal la distancia lateral alcanzada por sección sísmica (Groshong, 2006).

Figura 1.

Esquema general para la generación de imágenes sísmicas post-apilado.



Nota. Procesamiento de datos sísmicos para la creación de imágenes sísmicas post-apilado. Modificado de Simm & Bacon (2014) y Hart (2000).

3.2 Interpretación de fallas geológicas en imágenes sísmicas

Las imágenes sísmicas post-apilado son interpretadas con el objetivo de obtener un modelo estructural del subsuelo de utilidad en la caracterización de yacimientos. Parte de la interpretación sísmica implica la segmentación de fallas geológicas, su correcta interpretación influye en el conocimiento que se tiene de las propiedades mecánicas del subsuelo, las rutas de migración y trampas de fluidos y la forma de la superficie de la tierra (Alcalde, et al. 2017). El proceso de interpretación es realizado por un geocientífico quien se basa en el uso de software especializado para la realización de modelos a partir de las interpretaciones, los más utilizados principalmente son comerciales como Petrel, *Decision Space*, *Paleoscan*, etc.

En las imágenes sísmicas, las geometrías de las fallas geológicas se establecen principalmente vinculando las terminaciones de reflectores correspondientes a los estratos geológicos (Alcalde et al., 2017). Para la segmentación de fallas geológicas, el intérprete visualiza las imágenes sísmicas en secciones 2D que en el caso de adquisiciones 3D son llamadas *inline*, *crossline*, *randomline* y *time/depth-slice* según su orientación (Zou et al., 2020). Cada sección es interpretada en el software con trazos a través de las discontinuidades de los reflectores, correspondientes a fallas geológicas. El flujo de trabajo normalmente utilizado en la interpretación de fallas geológicas es facilitado mediante la integración de atributos sísmicos, estos extraen características de la información sísmica a través de una serie de funciones teóricas y empíricas (Barnes, 2016), permitiendo obtener características como las discontinuidades de los reflectores o bordes que luego son interpretados como fallas geológicas (ver Apéndices A). Sin embargo, existen otras explicaciones para la terminación de un reflector, algunas geológicas como los

cambios de facies deposicionales y disconformidades, que no siempre son fáciles de distinguir, lo que aumenta las ambigüedades en la interpretación de fallas y otros de tipo geofísico como los efectos de procesamiento, anomalías, cambios en la velocidad y el ruido sísmico, este último induce errores en los cálculos generados por los atributos sísmicos. (Alcalde et al., 2017).

3.3 Ruido sísmico

El ruido en imágenes sísmicas corresponde a señales de interferencia no deseadas, causantes del enmascaramiento de la información sísmica propia de las características del subsuelo. Estas señales pueden ser generadas por factores ambientales como vibraciones naturales, presencia de animales, adquisición cerca de cuerpos de agua en movimiento, redes eléctricas, ondas superficiales generadas por la fuente sísmica, etc. Según Kumar & Ahmed (2020) el ruido sísmico puede ser ubicado en alguna de las siguientes categorías: (1) de origen ambiental, (2) ruido relacionado con la propagación de onda, (3) ruido relacionado con la adquisición sísmica y (4) efectos del procesamiento de los datos sísmicos. Dependiendo del factor que lo origine, el ruido sísmico puede clasificarse en ruido aleatorio generalmente producido por factores externos ambientales y el ruido coherente que se produce en las señales sísmicas y que está relacionado temporal y/o espacialmente (Fogat et al., 2023). Se han desarrollado diversas técnicas para la reducción del ruido sísmico durante la etapa de procesamiento. Entre ellas se incluyen el apilamiento de ondas con puntos medios comunes (CMP), la corrección de ruido en la adquisición de campo, el tratamiento de ondículas afectadas y el filtrado de frecuencias y longitudes de onda asociadas al ruido en las imágenes sísmicas (Elboth et al., 2010). A pesar del uso de estos métodos, el ruido es difícil de suprimir completamente durante la etapa de procesamiento, haciendo que las imágenes tengan interferencias y se dificulte la interpretación de las características del subsuelo. Con el objetivo de estudiar soluciones a la presencia de ruido en imágenes sísmicas en el estado

del arte se han desarrollado algoritmos computacionales que simulan ruido mediante distribuciones estadísticas y ecuaciones personalizadas (ver Apéndices B).

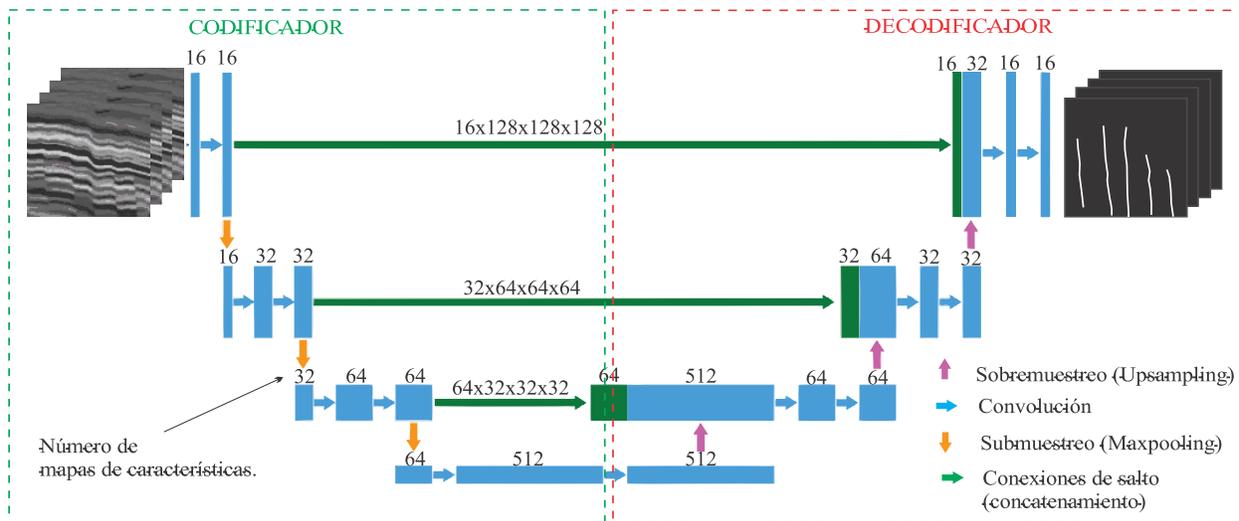
3.4 Redes Neuronales Convolucionales (CNN)

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) son un tipo de arquitectura de red neuronal artificial, utilizada principalmente en el análisis de imágenes. Las CNN toman como entrada imágenes o matrices de datos procesadas mediante convoluciones matemáticas y funciones de activación que evitan la linealidad del algoritmo, generando los llamados mapas de características. Algunas redes convolucionales como las utilizadas en tareas de segmentación necesitan generar máscaras de igual dimensión a los datos de entrada, este proceso es realizado por redes *autoencoder* mediante un proceso de codificación y decodificación (Daniel et al., 2021). En la codificación la red extrae características profundas a través de un submuestreo (*max-pooling*) que mantiene el número de mapas de características, pero reduce sus dimensiones espaciales. La transformación de los datos es realizada con *Kernels* o Filtros, los cuales son parámetros matriciales que se ajustan en una red neuronal convolucional durante el aprendizaje del algoritmo haciendo que la red aprenda y que en el proceso de submuestreo (*max-pooling*) se desplaza una cantidad determinada de píxeles en cada iteración reduciendo la dimensión espacial de los mapas de características. Sin embargo, al incrementar la cantidad de filtros también incrementa la cantidad de parámetros que pueden ser entrenados, lo que conlleva a un incremento en el costo computacional o, en cambio, escasos parámetros pueden provocar un rendimiento deficiente de la red. Posteriormente en la etapa de decodificación, se extraen los mapas de características derivados de la convolución anterior y se complementan con la información proveniente de las conexiones de salto. Con esto, se incrementa la dimensionalidad espacial de los mapas de características y se reduce su cantidad; a esto se le denomina sobremuestreo

(*upsampling*). Las conexiones de salto comparten los mapas de características de igual dimensión espacial entre el bloque codificador y decodificador, evitando el problema de las redes a olvidar relaciones espaciales debido a convoluciones profundas. La red U-Net es una arquitectura de las redes neuronales convolucionales que adoptan esta estructura autoencoder (ver Figura 2), donde al final se espera obtener la máscara binaria representativa de los objetos de interés (fallas geológicas).

Figura 2.

Arquitectura de red neuronal convolucional U-Net para la tarea de segmentación de fallas geológicas.



Nota. La imagen muestra esquemáticamente la arquitectura del algoritmo de red neuronal U-Net y la transformación de los datos. Modificado de Wu et al. (2019). La imagen sísmica hace parte del mar del norte en países bajos (TerraNubis, 2020).

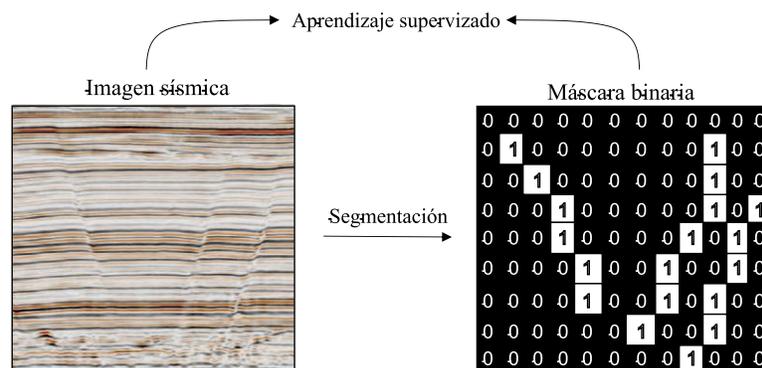
3.5 Segmentación binaria de imágenes

La segmentación binaria subdivide una imagen en sus partes constituyentes u objetos. Con el fin de separar las partes de interés del resto de la imagen, la segmentación binaria de imágenes asigna a cada píxel un valor de dos clases posibles, generalmente 1 y 0, lo que produce una nueva

imagen de la misma dimensionalidad de la original donde el valor de 1 normalmente resalta el objeto o constituyente de interés y le asigna un valor de 0 al fondo o zona de no interés, a esta nueva imagen se le denomina en el estado del arte como máscara binaria. El proceso de segmentación de fallas geológicas con *CNN's* comúnmente se ha abordado mediante el entrenamiento supervisado, que es un proceso donde las *CNN's* aprenden relaciones no lineales en las características de varios pares de datos. En la segmentación de fallas geológicas estos pares de datos son las imágenes sísmicas post-apilado y su respectiva máscara binaria, la cual es una imagen de la misma dimensión a la imagen sísmica post-apilado cuyos pixeles de valor 1 representan el trazo de la falla geológica y los de valor 0 representan el área de no interés o fondo (ver Figura 3) que sea representativa de la solución esperada. Así, una vez entrenado el algoritmo se espera que tenga la capacidad de predecir la máscara binaria correspondiente a las fallas geológicas en una imagen nueva no utilizada durante el entrenamiento. Este proceso de aprendizaje se lleva a cabo con un subgrupo de datos de entrenamiento, no obstante, se generan otros subgrupos como los datos de validación y evaluación, que no se emplean en el proceso de aprendizaje, sino que se utilizan para conocer el rendimiento de un algoritmo, durante y después de la fase de entrenamiento.

Figura 3.

Representación de fallas geológicas en máscaras binarias.



Nota. La imagen muestra como en la segmentación binaria las fallas geológicas están etiquetadas con el valor de píxel de 1 y el fondo con el valor de 0. Imagen sísmica tomada del proyecto *NW Shelf Australia - Poseidón 3D* (TerraNubis, 2017).

3.5.1 Métricas para evaluación de tareas de segmentación binaria

En la evaluación cuantitativa del proceso de segmentación binaria son usadas una serie de métricas que comparan las máscaras binarias predichas por un modelo computacional con las máscaras verdaderas mediante una serie de funciones matemáticas. Algunas de las métricas utilizadas en el estado del arte para evaluar tareas de segmentación con redes neuronales convolucionales (Laiton-Bonadiez et al., 2023; León Batallas et al., 2020), son descritas a continuación.

Coefficiente de similitud de Dice:

$$Dice = \frac{2|T \cap P|}{|T| + |P|} \quad (1)$$

Donde, T representa la máscara binaria de fallas geológicas verdadera y P la máscara binaria predichas.

Precisión:

$$Precisión = \frac{TP}{|TP| + |FP|} \quad (2)$$

Intersección sobre unión (IoU):

$$IoU = \frac{TP}{TP - FP + FN} \quad (3)$$

Recall:

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

Donde, TP corresponde al número de clases positivas predichas como positivas, referente a los píxeles que representan las fallas (1) que el algoritmo predijo como fallas (1), FP es el número de clases negativas (0) predichas incorrectamente como positivas (1), es decir el número de píxeles que no corresponden a fallas (0) que el algoritmo predijo como fallas (1) y FN el número de clases negativas clasificadas correctamente como negativas, que son los píxeles que no contienen fallas (0) que son predichos por el algoritmo con no presencia de falla (0). Un valor cercano a 1 en las anteriores métricas representa un mejor desempeño en la segmentación realizada por el algoritmo, siendo el rango de las ecuaciones de 0 hasta 1.

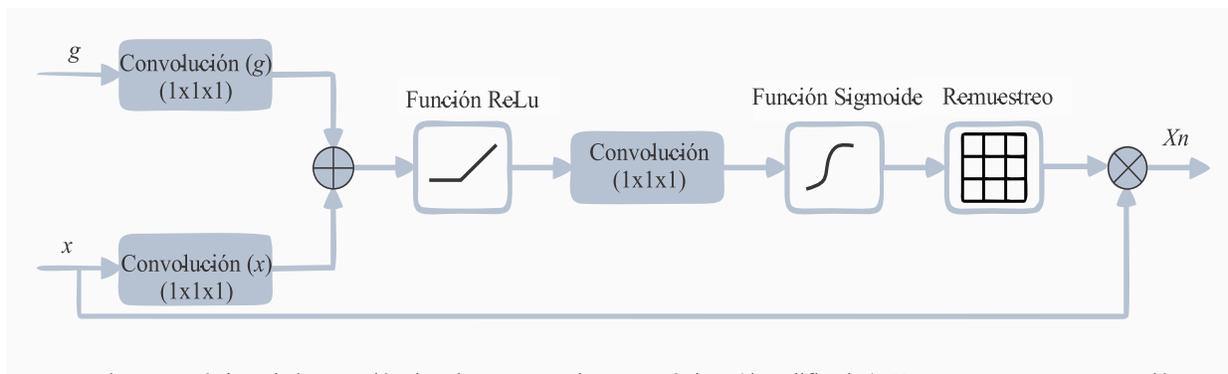
3.5.2 Bloques de atención (*Attention gates*)

Una de las desventajas con las que cuentan las redes neuronales convolucionales como las U-Net es que esta tiende en cada época de entrenamiento a volver a aprender características globales de la imagen de entrada que son redundantes, lo que implica un uso recurrente de los recursos computacionales. Los bloques de atención aprovechan las ventajas de las conexiones de salto de las redes U-Net que ayudan en el problema de la red a olvidar las relaciones espaciales de las características extraídas y suprimen las activaciones en regiones irrelevantes, reduciendo así el número de características reiterativas (Nava et al., 2022). Este tipo de mecanismo podría ayudar a enfocar los esfuerzos computacionales en la región alrededor de las fallas geológicas, lo que, en condiciones de ruido, se evitaría realizar cálculos computacionales en áreas de la imagen sísmica donde no se encuentran las fallas geológicas. Específicamente, los bloques de atención toman y suman los mapas de características provenientes de las conexiones de salto y de la fase de deconvolución, el resultado de esta operación es evaluado a través de una función de activación como la de unidad lineal rectificadora (*ReLU*) que estandariza los valores negativos a cero y los positivos los mantiene sin cambios, esto con el fin de asegurar un correcto proceso en la

optimización. La nueva información sigue una convolución y una función de activación que normaliza los datos entre 1 y 0 usando la función sigmoide, valores que al multiplicarse a la salida del mecanismo de atención filtran la información relevante en los mapas de características provenientes del proceso de deconvolución (Oktay et al., 2018), (ver Figura 4). Finalizando el proceso, el resultado es remuestreado y multiplicado con el mapa de características inmediatamente anterior en el bloque de deconvolución, haciendo que la red aprenda a enfocarse en regiones de interés cercanas a las fallas geológicas.

Figura 4.

Estructura del Bloque de Atención (Attention Gate).



g: mapa de características de la conexión de salto; *x*: mapa de características (decodificador) *Xn*: nuevo mapa *x* con atención

Nota. La figura representa los procesos matemáticos que componen los bloques de atención. Modificado de Oktay et al. (2018).

4 Metodología

4.1 Fase 1. Construcción de una base de datos de imágenes sísmicas segmentadas con fallas geológicas que presenten variaciones en características como su densidad y ocurrencia

Resumen: En esta primera fase, se construyó una base de datos de imágenes sísmicas de reflexión post-apilado que cuentan con datos de interpretación de fallas geológicas, estos son visualizados con el fin de conocer algunas de sus características geológicas. Se finaliza con el

preprocesamiento donde se acondicionaron a un tipo de dato matricial estándar, para ser usados en tareas de aprendizaje automático, así como su división en conjuntos para el entrenamiento, validación y prueba de la red neuronal.

Actividad 1.1. Recopilación de datasets de imágenes sísmicas segmentadas con fallas geológicas. Se consultaron distintos datasets disponibles para uso académico en fuentes web como *SEG Wiki*, *Blake Ridge Hydrates 3D*, *USGS Central Alaska*, *USGS Beaufort Sea - Artic Alaska*, *TerraNubis*, *GitHub*, entre otras. Los datasets se componen de imágenes sísmicas y su respectivo conjunto de fallas geológicas interpretadas, requeridas para la tarea de segmentación en el algoritmo de Red Neuronal Convolutiva.

Actividad 1.2. Análisis de los datos recopilados con variabilidad en características de las fallas geológicas presentes en las imágenes sísmicas. Se realizó un análisis de los datos adquiridos en la actividad 1.1. con el objetivo de conocer la variabilidad de características sísmicas relacionadas con las fallas geológicas presentes, como sus densidades de ocurrencia y continuidad mediante el análisis de imágenes sísmicas 2D, se utilizaron librerías de funciones del lenguaje de programación Python, como Matplotlib para la visualización de los datos y Numpy para el tratamiento matemático de matrices multidimensionales.

Actividad 1.3. Preprocesamiento de los datos obtenidos para su utilización en redes neuronales convolutivas. Se acondicionaron las imágenes sísmicas y su interpretación de fallas geológicas generalmente encontradas en formato SEG-Y y ASCII respectivamente, a matrices de datos que se redimensionaron a un mismo tamaño de 128x128 píxeles para su estandarización y se aplicó un proceso de aumento de datos mediante rotaciones verticales y horizontales para disminuir la tendencia de algunas redes a crear modelos sobreajustados de los datos. Estos fueron separados en conjuntos de validación, evaluación y entrenamiento para ser

utilizados en el entrenamiento y evaluación de modelos de redes neuronales convolucionales. Este proceso fue realizado con librerías del lenguaje de programación Python como *Numpy*, *Scikit-image*, *Tensorflow* y *Scikit-learn*.

4.2 Fase 2. Implementación de arquitecturas de redes neuronales convolucionales para la tarea de segmentación automática de fallas geológicas en imágenes sísmicas

Resumen: En esta segunda fase se realizó la revisión en el estado del arte de las diferentes arquitecturas de redes neuronales convolucionales y posibles técnicas de atención complementarias utilizadas para la segmentación de fallas geológicas de las cuales se seleccionaron 3 basándose en aspectos como la disponibilidad de las arquitecturas en internet, la viabilidad computacional (parámetros entrenables) y con mejor documentación en el estado del arte, dichas arquitecturas se pusieron a prueba con un subconjunto de datos de la primera fase para evaluar su desempeño mediante métricas como *Intersection over Union (IoU)* y precisión, que son utilizadas en tareas de segmentación binaria.

Actividad 2.1. Revisión y elección de las arquitecturas de redes neuronales computacionales y técnicas de atención complementarias utilizadas en tareas de segmentación de fallas geológicas. Se realizó una revisión del estado del arte en las arquitecturas de redes neuronales convolucionales utilizadas para la segmentación de fallas geológicas y sus posibles técnicas de atención complementarias para la mejora en los resultados. Seguidamente, se seleccionaron 3 arquitecturas de redes neuronales convolucionales aplicadas en la segmentación de fallas geológicas, en base a criterios como la disponibilidad en internet de las arquitecturas de red, las más documentadas en el estado del arte y la viabilidad computacional.

Actividad 2.2. Definición de criterios utilizados en el problema de optimización. Se definieron los criterios utilizados para el ajuste de los parámetros entrenables en la red neuronal

convolucional, de acuerdo con la revisión en el estado del arte de hiperparámetros utilizados en las distintas arquitecturas específicamente en la tarea de segmentación de fallas geológicas. Estos criterios comprenden la función de costo o pérdida que se busca minimizar a lo largo del entrenamiento, el método de optimización, la tasa de aprendizaje (que tanto cambian los pesos durante cada iteración del entrenamiento) y el número de épocas (cada época corresponde a una iteración completa en todo el conjunto de entrenamiento).

Actividad 2.3. Validación y evaluación de algoritmos de redes neuronales convolucionales complementados con mecanismos de atención utilizados en la segmentación de fallas geológicas. Se implementaron las arquitecturas de redes neuronales convolucionales, en entornos de ejecución alojados en servidores de la plataforma Kaggle debido a la disponibilidad de Unidades de Procesamiento Gráfico (*GPU*). En este trabajo se utilizó una GPU NVIDIA Tesla P100 de 16 GB de memoria que permitió la realización de cálculos computacionales en menor tiempo. Para la implementación de los modelos se utilizó la librería del lenguaje de programación Python, Tensorflow, que gracias a su optimización es utilizado comúnmente en proyectos que implican redes neuronales convolucionales. Se seleccionaron algunos datos de los conjuntos de entrenamiento y se validó el desempeño de las redes con un subconjunto de los datos de validación mediante las métricas definidas en la Sección 3.5.1.

4.3 Fase 3. Evaluación de la influencia del ruido sísmico en la segmentación de fallas geológicas mediante algoritmos de redes neuronales convolucionales

Resumen: En esta tercera fase, se evaluó el ruido en imágenes sísmicas post-apilado presente en imágenes sísmicas de reflexión mediante modelamiento computacional, a través de la aplicación de funciones matriciales, simulando ruidos aleatorios y coherentes en distintos rangos de intensidad que generaron un nuevo conjunto de datos, donde se evaluó la influencia del ruido

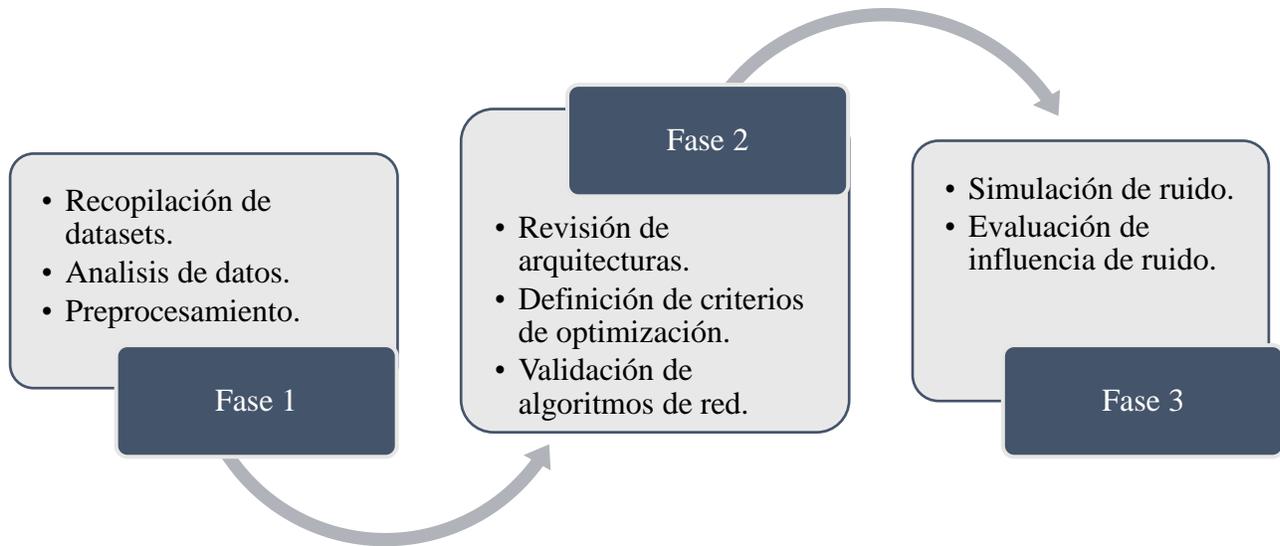
en la segmentación de las fallas geológicas, haciendo uso de la red convolucional seleccionada en la segunda fase para su evaluación con y sin bloques de atención en condiciones de ruido.

Actividad 3.1. Inducción de varios tipos y rangos de ruido en las imágenes sísmicas de prueba. Se tomaron las imágenes sísmicas asignadas como imágenes de prueba en la actividad 1.3 de la primera fase y se aplicaron algunos algoritmos de simulación de ruido en varios rangos con el objetivo de generar un nuevo conjunto de datos, para la evaluación del ruido en la segmentación de las fallas geológicas; esta fue realizada con la arquitectura de red y mecanismo de atención seleccionado en la segunda fase. Se simularon ruidos de tipo aleatorios como el blanco (gaussiano) e Impulsivo (sal y pimienta), y ruidos coherentes lineales y de ondas mediante funciones matemáticas que simularon la interferencia generada por estos. *Numpy* y *Pytorch* fueron las principales librerías de programación utilizadas.

Actividad 3.2. Evaluación de la influencia del ruido en la extracción automática de fallas geológicas en imágenes sísmicas mediante CNN's complementadas y no complementadas con mecanismos de atención. Se evaluó la capacidad que tiene el ruido sísmico en disminuir la calidad de la segmentación de fallas geológicas, mediante técnicas de redes neuronales convolucionales complementadas con técnicas de atención y sin ellas. Para ello se evaluó la red seleccionada en la fase 2 con imágenes sísmicas ruidosas establecidas en la actividad 3.1 y luego se comparó el desempeño de la segmentación con y sin mecanismos de atención asociados a la *CNN* utilizada, a través de distintos rangos de ruidos. Las métricas utilizadas incluyen Intersección sobre unión (IoU), Precisión, Coeficiente de Dice y *Recall*, las cuales fueron explicadas en la sección 3.5.1. Para esto, se utilizaron las funciones integradas en Keras y funciones personalizadas.

Figura 5.

Esquema de la metodología empleada durante la investigación.



Nota. Esquema resumido de la metodología realizada en la presente investigación.

5 Resultados

En esta sección se muestran los resultados de las distintas actividades realizadas para cumplir los objetivos de la investigación siguiendo la metodología planteada anteriormente.

5.1 Base de datos de imágenes sísmicas segmentadas con fallas geológicas de distinta densidad y ocurrencia

En esta sección mediante la consulta de información en internet se realizó una recopilación de datasets con imágenes sísmicas y sus respectivas fallas geológicas segmentadas que fueron analizadas y preprocesadas para su uso en tareas de aprendizaje automático.

5.1.1 *Imágenes sísmicas recopiladas y su interpretación de fallas geológicas*

La segmentación de fallas geológicas en imágenes sísmicas post-apilado mediante redes neuronales convolucionales es una tarea que según el estado del arte se ha abordado desde el aprendizaje supervisado, este enfoque requiere pares de datos compuestos por la imagen sísmica

y la máscara binaria que representa la ubicación de sus fallas geológicas (ver Apéndices E, Apéndices F, Apéndices G y Apéndices H). Debido a esto, se consultó la disponibilidad de estos datos en artículos y bases de datos alojadas en internet para su descarga.

5.1.1.1 Conjunto de datos “Sintético 1”. Este conjunto de datos originalmente denominado “*Synthetic Seismic Dataset 200T, 20V*” fue descargado desde la plataforma Kaggle¹, el cual fue creado basándose en la metodología introducida por Wu et al. (2019). Consiste en 200 volúmenes 3D de imágenes sísmicas post-apilado y sus respectivos 220 volúmenes 3D de fallas geológicas con valores binarios (1 fallas y 0 no fallas). Cada volumen 3D tiene dimensiones de 128×128×128 en los ejes *X, Y* y *Z* respectivamente, en archivos de tipo matricial guardados con la extensión “.npz”, lo que facilita su lectura con librerías de programación Python como Numpy y ocupa un espacio de almacenamiento de 3.43 GB.

5.1.1.2 Conjunto de datos “Sintético 2”. Este conjunto de datos fue creado por la compañía Equinor para la competencia de identificación de fallas geológicas *FORCE* versión 2020² y consiste en un volumen 3D de imágenes sísmicas post-apilado y otro volumen 3D binario (1 y 0) con las fallas geológicas interpretadas, ambos simulados con la herramienta de modelamiento *Compound Earth Simulator (CES)* y exportados en formato *SEG Y (.sgy)*. El tamaño de almacenamiento es de 368 MB y sus dimensiones son de 101×589×751 en los ejes *X, Y* y *Z* (o *inline, crossline* y *depth line*, respectivamente). La interpretación de las fallas geológicas fue realizada únicamente en las secciones *X* o *inline*.

5.1.1.3 Conjunto de datos “Real 1”. Este conjunto de datos denominado originalmente “*A Gigabyte Interpreted Seismic Dataset for Automatic Fault Recognition*” fue descargado del repositorio de datos de la Universidad de Harvard e interpretado por An et al. (2021). Consiste en 18 volúmenes de imágenes sísmicas y 18 volúmenes de datos binarios (valores 1 y 0) que

1 <https://www.kaggle.com/datasets/malik9/synth-seis-data/data?select=prediction>.

2 https://drive.google.com/drive/folders/1jJhpmoAsMmA-kB1dL1IGDW_aRSTbkprV.

representan la interpretación de fallas geológicas. La sísmica utilizada proviene de una adquisición marina en el campo de gas Thebe, ubicado en la cuenca Carnarvon, al noreste de Australia³. Cada uno de los volúmenes cuenta con dimensiones de 100x3174x1537 en los ejes X, Y y Z respectivamente, ocupando un espacio total de 20.6 GB. Fueron exportados como archivos matriciales de extensión “.npz”, compatibles con la librería Numpy del lenguaje de programación Python.

5.1.1.4 Conjunto de datos “Real 2”. Este conjunto de datos fue tomado del proyecto *F3 Demo 2023*⁴ adquirido en el Mar del Norte, Países Bajos. El proyecto incluye un volumen sísmico 3D almacenado en un archivo *SEG Y* (.sgy). Sus dimensiones son de 650x950x462 en los ejes X, Y y Z (o *inline*, *crossline* y *depth line*, respectivamente) con un tamaño de almacenamiento de 666 MB. Este conjunto no incluye fallas geológicas interpretadas, por lo tanto, se extrajo el inline 201 que presentaba una mejor visualización de las fallas geológicas para su interpretación manual en el software de código abierto *Label-Studio*, basado en Mazloun (2024), donde se obtuvo la máscara binaria representativa de la interpretación de las fallas. Finalmente, este conjunto incluye una sección 2D de imagen sísmica post-apilado y su respectiva máscara binaria 2D representativas de las fallas geológicas, ambas con dimensiones 951x462 en los ejes Y y Z respectivamente.

5.1.2 Análisis estructural básico de la base de datos recopilada.

Las redes neuronales convolucionales aprenden a partir de los datos de entrenamiento, por lo tanto, es esencial su análisis para identificar los dominios estructurales que se espera la red sea capaz de predecir. Por tal motivo, se extrajeron dos secciones *inline* de un volumen de cada conjunto de datos, para el análisis de características como la densidad (número de zonas con grupos de fallas cercanas interconectadas) y ocurrencia (cantidad de fallas geológicas en una sección) de fallas geológicas

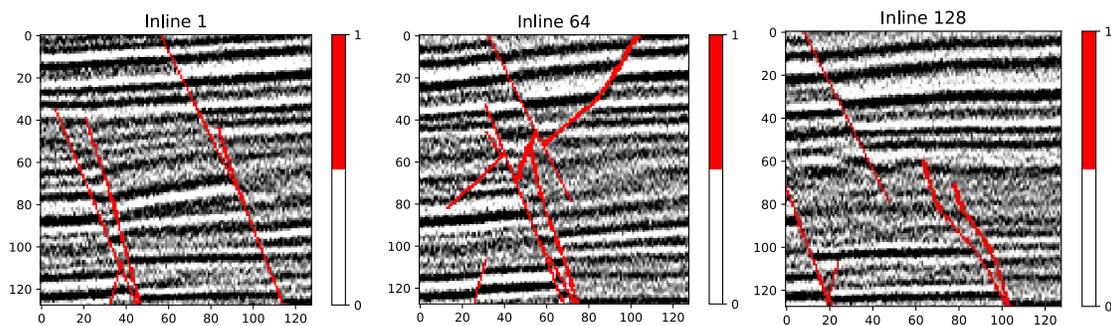
³ <https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/YBYGBK>.

⁴ <https://terranubis.com/datainfo/F3-Demo-2023>.

5.1.2.1 Sintético 1. Con el objetivo de entender las características estructurales presentes se eligieron los *inline* 1, 64 y 128 de uno de sus volúmenes (ver Figura 6) para la visualización de las imágenes sísmicas y su máscara binaria de fallas geológicas. Las imágenes sísmicas presentan variaciones aleatorias en la dirección vertical como ocurre en las adquisiciones reales. Estructuralmente los reflectores sísmicos representan capas geológicas originalmente paralelas que son afectadas por el desplazamiento propio de las fallas geológicas. En cada sección observada la ocurrencia de fallas oscila entre 9 y 5. El conjunto de datos representa los casos geológicos donde las fallas generalmente se encuentran asociadas a otras fallas secundarias conformando lo que se conoce en la literatura como sistema de fallas; esto se ve evidenciado en la densidad de fallas donde hacia el centro del volumen sísmico se hace cada vez más fuerte con zonas de 2 hasta 7 fallas interconectadas. Las imágenes sísmicas simuladas contienen superficies de fallas en su mayoría con tendencia lineal, aunque también se observan algunas curvadas como lo son las fallas lístricas. Sus cinemáticas incluyen fallas normales e inversas de alto buzamiento, no se encuentran pliegues de arrastre en las capas circundantes, sin embargo, su desplazamiento induce buzamiento en las capas. Otro aspecto importante que tienen las imágenes es el ruido, los que simula las imágenes sísmicas reales donde el ruido está en la mayoría de los casos presente.

Figura 6.

Visualización de imágenes sísmicas para el conjunto de datos Sintético 1.

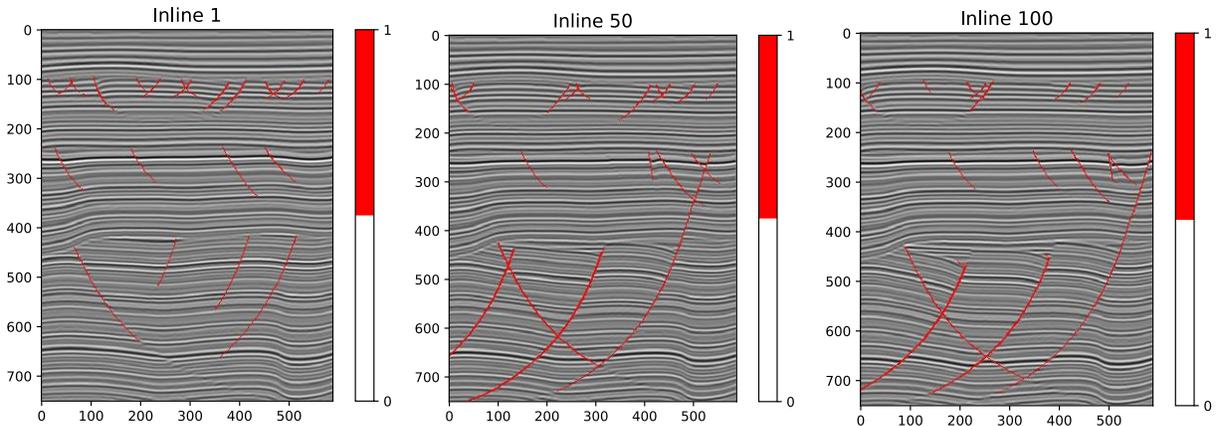


Nota. Se observan 3 secciones de imágenes sísmicas con sus máscaras binarias (valores de 1 en rojo fallas geológicas y valores de 0 en transparente, no fallas geológicas) de los datos Sintético 1 y sus dimensiones en píxeles.

5.1.2.2 Sintético 2. En este conjunto de datos se visualizaron los *inline* 1, 50 y 100 con el objetivo de tener una idea del comportamiento de las fallas geológicas en las secciones sísmicas. Las imágenes sísmicas a pesar de ser sintéticas recrean características presentes en las imágenes sísmicas reales. Es posible observar que en este conjunto de datos sintético las secciones sísmicas presentan fallas geológicas de mayor tamaño en la parte inferior comparadas con las ubicadas en la parte superior, recreando la variabilidad de tamaños de las fallas geológicas que se pueden encontrar en adquisiciones reales, debido a características como la fragilidad de las rocas y los esfuerzos que actúan en los sedimentos a distintas profundidades, así como el área afectada por la deformación lo que da formación a las fallas locales y regionales. La densidad de las fallas se hace cada vez más presente avanzando en los *inline* del volumen sísmico con secciones que cuentan con 7 hasta 12 fallas interconectadas (ver Figura 7). La imagen sísmica incluye una discontinuidad estratigráfica angular por debajo de la cual los reflectores de las capas geológicas se muestran ligeramente más plegados que los reflectores superiores. Se distingue un plegamiento en las capas producto de las fallas geológicas, lo cual es una condición generada por litologías un poco dúctiles. La ocurrencia de fallas geológicas consiste visualmente en 4 fallas principales y 14 a 16 fallas menores por sección *inline* aproximadamente. La mayoría de las fallas presentes son de estilo curvo como las conocidas fallas lístricas y de alto ángulo de buzamiento. Además, la cinemática presente en las secciones del conjunto Sintético 2, incluye fallas de tipo normal, propias de ambientes extensionales principalmente.

Figura 7.

Visualización de imágenes sísmicas para el conjunto de datos Sintético 2.



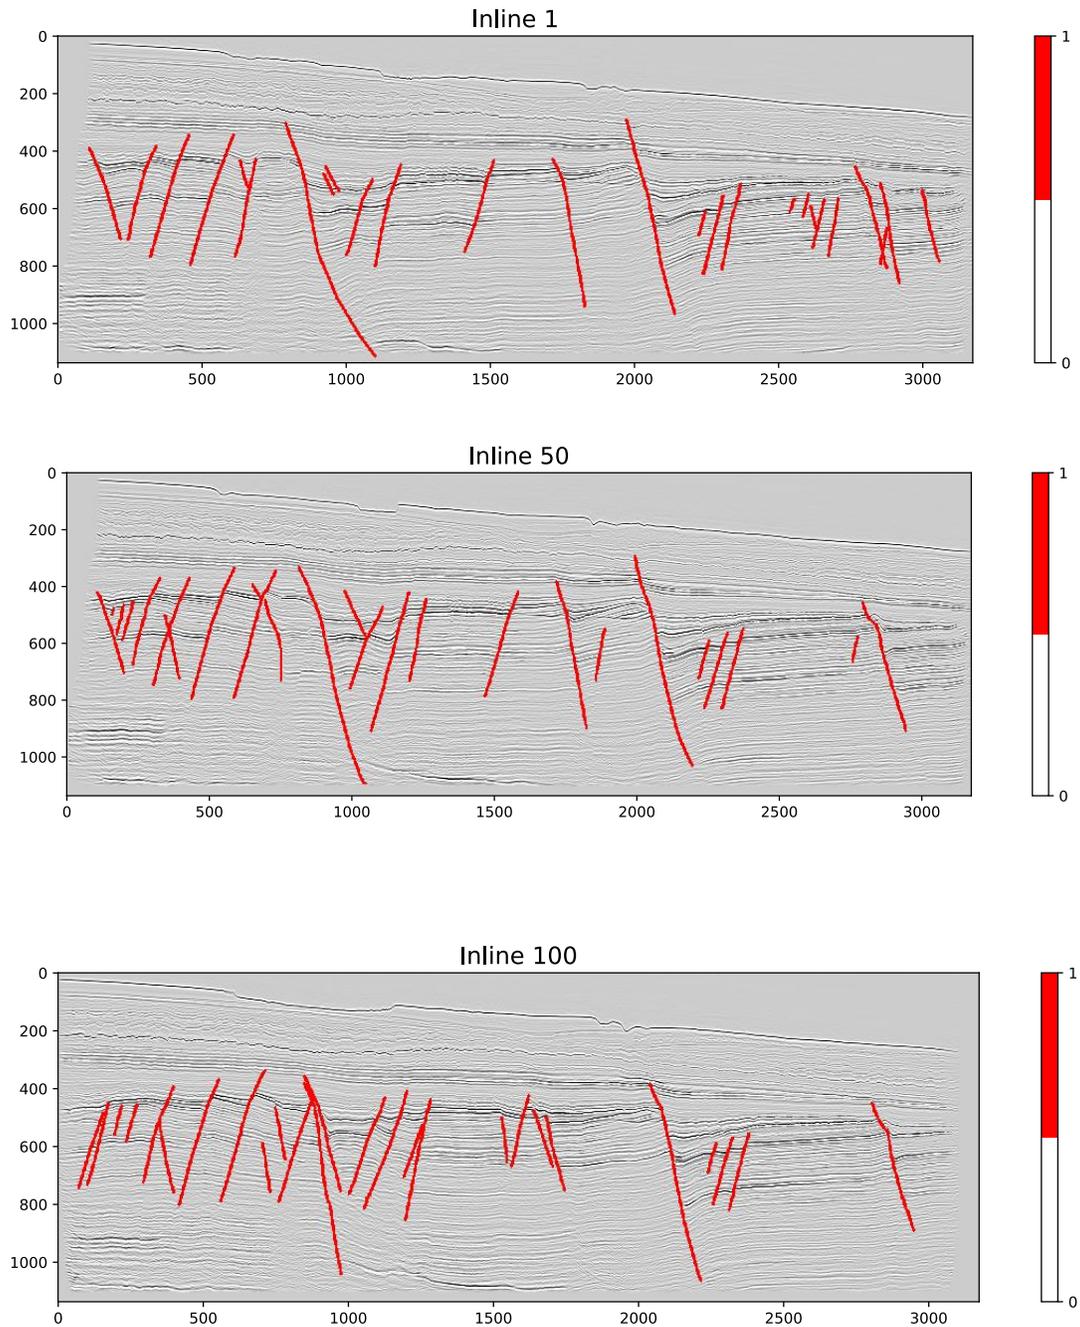
Nota. Se observan 3 secciones de imágenes sísmicas con sus máscaras binarias (valores de 1 en rojo fallas geológicas y valores de 0 en transparente, no fallas geológicas) de los datos Sintético 2 y sus dimensiones en píxeles.

5.1.2.3 Real 1. El conjunto de datos Real 1 contiene imágenes sísmicas reales con sus respectivas máscaras binarias de fallas geológicas interpretadas manualmente (ver Figura 8), estas fallas geológicas presentan un alto ángulo de buzamiento con poca variación entre ellas. La mayoría de las fallas tienen cinemática normal, esto es típico de ambientes extensionales, se observan estructuras estilo horst no tan sobresalientes. La ocurrencia de fallas geológicas mediante conteo visual en secciones comprende 2 fallas geológicas principales que afectan mayormente los estratos sedimentarios y entre 22 y 24 fallas de orden jerárquico similar por sección con tamaños similares. En algunos casos se observa una zona con densidad de fallas a la izquierda de las secciones con desde 6 a 9 fallas interconectadas. Al ser extraídas de una adquisición sísmica real, naturalmente presenta variaciones en los valores de amplitud en dirección tanto horizontal como vertical. Geológicamente la imagen sísmica muestra la ocurrencia de un evento tectónico principal que pliega y genera fallas geológicas de gran tamaño generando espacios de acomodación de

sedimentos en la cuenca que luego son llenados por los sedimentos recientes que presentan una relativa distribución horizontal con pocos cambios dúctiles o frágiles

Figura 8.

Visualización de imágenes sísmicas para el conjunto de datos Real 1.

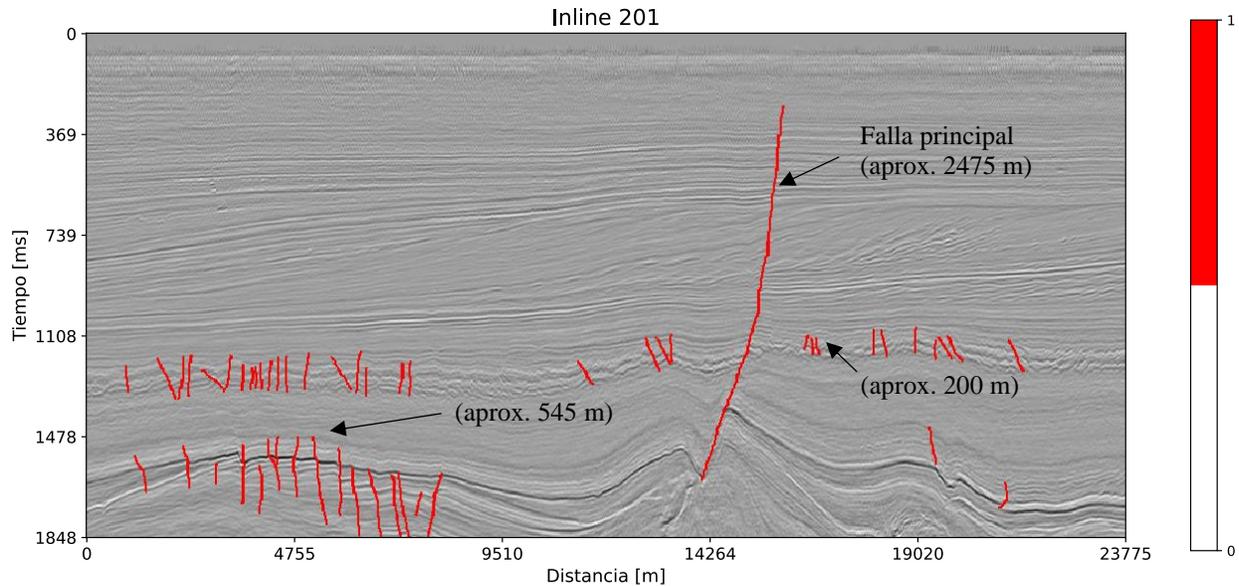


Nota. Se muestran 3 secciones de imágenes sísmicas y sus máscaras binarias con valores de 1 para la interpretación de fallas geológicas resaltadas en color rojo y valores de 0 donde no hay fallas, del conjunto de datos Real 1 y sus dimensiones en píxeles.

5.1.2.4 Real 2. Este conjunto de datos es uno de los más utilizados académicamente debido a su disponibilidad y popularidad científica. El conjunto de datos Real 2 es extraído del bloque F3 de países bajos. Se consultó la disponibilidad de máscaras binarias de la interpretación de fallas geológicas disponibles para este bloque, sin embargo, no fue posible encontrarlas. Por lo tanto, se hizo un barrido por los inline del volumen sísmico en búsqueda de una visualización más clara de las fallas geológicas eligiendo el inline 201 como imagen sísmica para este conjunto de datos (ver Figura 9). La interpretación de fallas geológicas fue realizada de manera manual con software de código abierto, obteniendo así su correspondiente máscara binaria de fallas geológicas, teniendo en cuenta la interpretación realizada por Mazloum (2024). Los tamaños de las fallas geológicas en su mayoría son pequeñas entre 254 y 545 metros comparadas con la falla principal que puede intuirse es de tipo regional debido a su extensión aproximada de 2475 metros. En cuanto a la ocurrencia, usando un conteo visual se observan 52 fallas de alto ángulo de buzamiento y zonas donde aumenta la densidad de fallas con un total de 12 fallas interconectadas. Mediante un análisis visual de las secciones se observa que todas las fallas cuentan con cinemáticas normales. Además de las deformaciones y discontinuidades generadas por las fallas, se puede observar que la mayoría de los reflectores sísmicos son continuos lateralmente, a excepción de un paquete litológico que presenta estructuras sedimentarias sigmoidales que generan truncamiento en los reflectores; según el estado del arte este tipo de estructuras estarían asociadas a depósitos de un gran paleosistema fluviodeltáico en la región del Mar Báltico.

Figura 9.

Visualización de imágenes sísmicas para el conjunto de datos Real 2.



Nota. Se observa la imagen sísmica correspondiente al inline 201 y su máscara binaria superpuesta con valores de 1 en la interpretación de fallas geológicas y valores de 0 donde no hay fallas, para el conjunto de datos Real 2 y sus dimensiones.

5.1.3 Conjunto de datos adecuados a tareas de aprendizaje automático.

Cuando se trabajan con datos uno de los pasos más importantes consiste en realizar el preprocesamiento. Esta etapa permitió verificar la calidad de los datos, estandarizarlos para hacerlos comparables entre otras opciones necesarias para el entrenamiento de redes neuronales convolucionales. Se tomaron los conjuntos de datos y se les aplicó un flujo de procesamiento que incluye:

5.1.3.1 Acondicionamiento del tipo de dato. Algunos de los archivos descargados se encontraron en formatos que no son compatibles o generan complicaciones a la hora de cargarlos, leerlos y modificarlos debido a su extensión. En este paso se estandarizaron las imágenes sísmicas

y máscaras binarias de tipo Segy (.sgy) en archivos de tipo matricial capaces de ser leídos por la librería de programación *Numpy* (.npy).

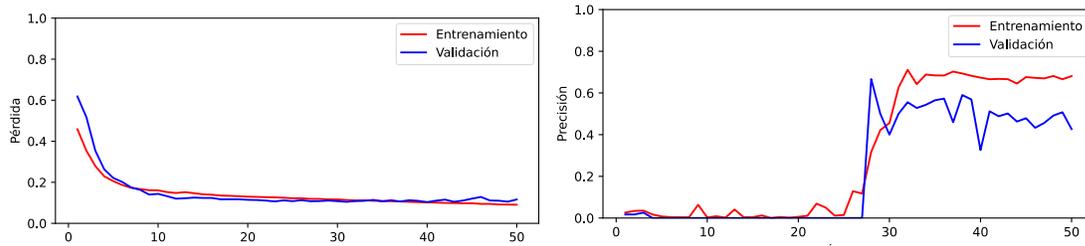
5.1.3.2 Extracción de secciones 2D a partir de volúmenes 3D. Una vez obtenidos los volúmenes 3D en archivos de tipo matricial, se utilizó la librería *Numpy* para realizar una extracción de cada una de las secciones inline que componen los distintos cubos sísmicos. Esta tarea se realizó ya que en este estudio el problema de segmentación se aborda desde el análisis de secciones sísmicas.

5.1.3.3 División en parches. Las redes neuronales convolucionales están diseñadas para entrenarse y generar predicciones en imágenes de un tamaño específico, según la bibliografía consultada se notó el uso mayoritario de matrices de datos de 128x128 píxeles. Debido a esto, se dividió cada sección sísmica en parches de 128x128 (ver Figura 12), y en algunos casos se realizó un relleno en aquellos parches donde las dimensiones no eran suficientes, evitando así la pérdida de la información original de las imágenes sísmicas y sus máscaras de fallas geológicas.

5.1.3.4 Normalización de parches. Esta actividad se aplicó únicamente a los parches de las imágenes sísmicas con el objetivo de optimizar el proceso de entrenamiento de las redes neuronales convolucionales, ya que una gran variabilidad en los datos de entrenamiento puede introducir cierto sesgo no deseado de los datos y hacer más difícil la actualización de parámetros entrenables en búsqueda de reducir la función de pérdida relacionada con las predicciones. Para esto se utilizó la fórmula de normalización mínima máxima (ver Apéndices D) entre los valores de 0 y 1, ya que mediante una prueba demostró ser más eficiente que la normalización mínima máxima entre 1 y -1 (ver Figura 10 y Figura 11), ambos rangos utilizados en el estado del arte (Adeyemo & Wimmer, 2018; Li et al., 2021; Oktay et al., 2018).

Figura 10.

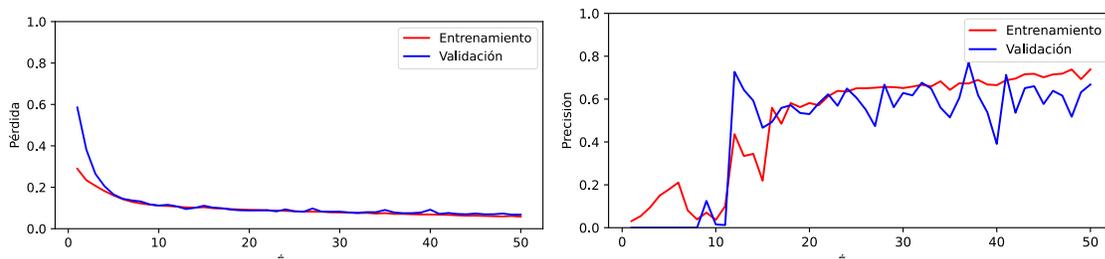
Gráficos de función de pérdida y métrica de precisión al entrenar red con imágenes sísmicas normalizadas entre -1 y 1.



Nota. Los gráficos muestran el desempeño de la red durante la tarea de segmentación usando imágenes sísmicas normalizadas entre -1 y 1.

Figura 11.

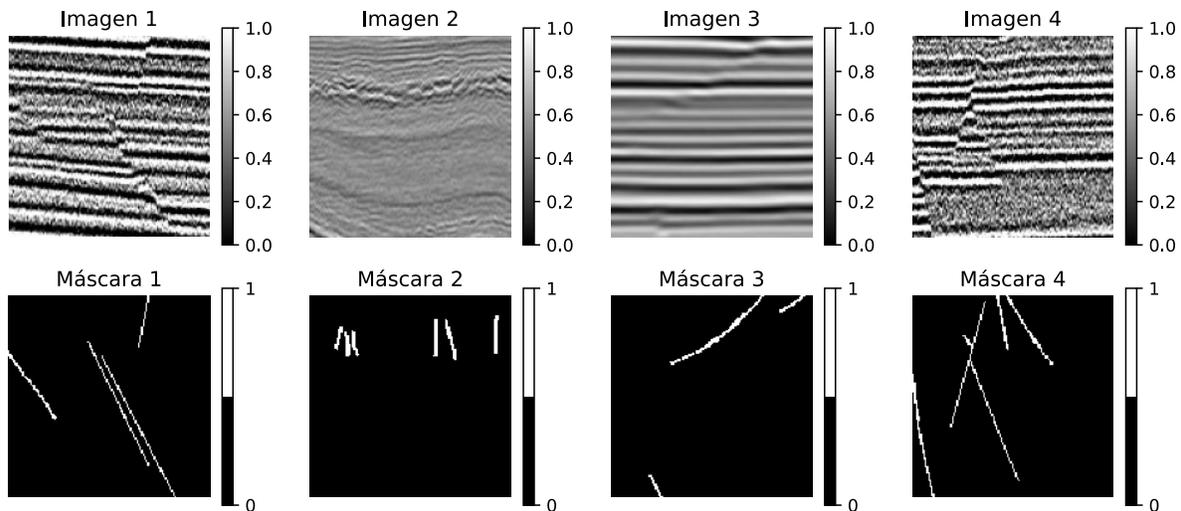
Gráficos de función de pérdida y métrica de precisión al entrenar red con imágenes sísmicas normalizadas entre 0 y 1.



Nota. Los gráficos muestran el desempeño de la red durante la tarea de segmentación usando imágenes sísmicas normalizadas entre 0 y 1.

Figura 12.

Visualización de parches preprocesados de imágenes sísmicas y máscaras de fallas geológicas.



Nota: La barra de color representa los valores continuos de las amplitudes de las imágenes sísmicas y los valores binarios en las máscaras de fallas geológicas (1 falla y 0 no falla).

5.1.3.5 Aumento de datos. Las secciones cercanas pueden parecerse y generar que la red neuronal convolucional se sobreajuste a los datos y no sea capaz de generar predicciones en otros datos diferentes a los utilizados durante el entrenamiento, una de las maneras de evaluar este sobreajuste es mediante el aumento de la función de pérdida al evaluar los datos de validación (ver Apéndices I, Apéndices J y Apéndices K). En este trabajo se realizó un aumento de datos con el objetivo de ayudar a generalizar las predicciones en datos que no haya utilizado durante el entrenamiento y diversificar la orientación del buzamiento y cinemática de las fallas geológicas. El proceso de aumento de datos consistió en aplicar una rotación vertical y otra horizontal a cada parche sísmico, sin que esto implique cambios en lo que son las fallas geológicas. La cantidad de parches obtenidos luego del proceso de aumento de datos y su tamaño digital se pueden ver en la Tabla 1.

Tabla 1.

Número de parches y tamaño digital de los datasets adquiridos.

Conjunto de datos	Número de Parches	Tamaño
<i>Sintético 1</i>	153,600	9.39 GB
<i>Sintético 2</i>	9,696	607 MB
<i>Real 1</i>	1,557,792	107 GB
<i>Real 2</i>	64	6 MB
Total	1,721,152	117.003 GB

Nota. El número de parches incluye las imágenes sísmicas y las máscaras correspondientes a las fallas geológicas.

5.2 Arquitecturas de redes neuronales convolucionales para la tarea de segmentación automática de fallas geológicas en imágenes sísmicas.

5.2.1 Estado del arte de CNN's aplicadas a tareas de segmentación de fallas geológicas.

Las redes neuronales convolucionales han evolucionado en cuanto a las arquitecturas que presentan. Cada tipo de arquitectura de *CNN* tienen ventajas y desventajas en aspectos como el tiempo de entrenamiento, el número de parámetros entrenables, los requerimientos computacionales, la manera en cómo extraen matemáticamente características, el tiempo de ejecución, etc. A continuación, se mostrarán las arquitecturas de redes neuronales convolucionales utilizadas en el estado del arte para la tarea de segmentación de fallas geológicas en imágenes sísmicas.

5.2.1.1 UNet++. Fue introducida por Zhou et al. (2018), este tipo de red está compuesta por una serie de bloques convolucionales interconectados de manera densa entre la parte codificadora y decodificadora de la red U-Net con el objetivo de tener una mejor transferencia de información semántica entre ambos. Yang et al. (2020), realizaron una aplicación de este tipo de arquitecturas de *CNN's* para la segmentación de fallas geológicas en imágenes sísmicas 3D, ellos

realizaron el entrenamiento de la red con imágenes sintéticas y utilizaron sísmica real del bloque LH al suroeste de China para la comprobación de las predicciones. Como resultados se obtuvo que el algoritmo entrenado fue capaz de delimitar fallas geológicas en las imágenes sísmicas con diferente ocurrencia de fallas y generar buenas predicciones, aunque exista cierto grado de ruido sísmico que puede inducir falsas regiones etiquetadas como fallas.

5.2.1.2 Inception-UNet. La arquitectura de red *Inception-UNet* es introducida por Delibasoglu & Cetin (2020). Esta arquitectura está basada en la red U-Net complementada con una técnica denominada bloques de inception agregando varias matrices convolucionales y concatenándolas antes de aplicar a mejorar la extracción de características en la red antes de realizar un *maxpooling*, ayudando a extraer más características a distintos niveles de la arquitectura. Un caso de aplicación en la segmentación de fallas geológicas fue realizado por Dinh & Nguyen (2022); en este estudio los autores realizaron la segmentación de fallas en imágenes sísmicas 3D, utilizando un conjunto de datos sintético. Una de las ventajas de este tipo de arquitectura es que reduce el número de parámetros entrenables en aproximadamente 12 veces los parámetros que tienen otras arquitecturas.

5.2.1.3 ResUNet. Fue propuesta por Zhang et al., 2017, para la extracción automática de carreteras de imágenes aéreas. La arquitectura de este tipo de red aprovecha las ventajas de la red *UNet* y modifica los bloques convolucionales típicos en estas redes a bloques residuales que van sumando los mapas de características entrantes a las resultantes de los bloques de residuales. Liu et al., (2020), son unos de los autores que han utilizado este tipo de arquitecturas para la segmentación de fallas geológicas en datos 3D. El entrenamiento de la red *ResUNet* se llevó a cabo con imágenes sísmicas sintéticas y la evaluación de las predicciones fue realizada utilizando sísmica real adquirida al este de China en el mar Bahaí. En este caso de estudio realizaron una

comparación con la red *UNet* y encontraron que el tiempo de entrenamiento de la red *ResUNet* era mayor al entrenamiento de la red *UNet*, pasando de 3.54 horas a 8.21 horas y obteniendo una diferencia en métricas de menos del 1%, además de aumentar su número de parámetros entrenables a casi el doble.

5.2.1.4 W-Net. La red *W-Net* está basada en la red *U-Net* y está compuesta por una combinación de dos de estas, la primera realiza el trabajo de extraer las características de una imagen como la segmentación de objetos y una segunda red *U-Net* que toma ese resultado de la primera y los refina, de ahí que su nombre sea por la forma en que se representa como una “W”, fue propuesta por Xia & Kulis (2017). Este tipo de red neuronal convolucional fue utilizada por Yan et al. (2024), para la segmentación de fallas geológicas en imágenes sísmicas 3D. Se hizo uso de imágenes sísmicas sintéticas para la etapa de entrenamiento y para la evaluación de las predicciones se eligió un volumen sísmico real perteneciente al bloque F3 de Países Bajos. Este estudio concluyó que la red *W-Net* es capaz de generar predicciones muy fiables de las fallas geológicas, sin embargo, presenta algunas dificultades al predecir en zonas donde las fallas están interconectadas y por lo tanto en zonas falladas complejas.

5.2.1.5 U-Net. La arquitectura de red *U-Net* es una de las más comunes en la tarea de segmentación de fallas geológicas. Consiste en un bloque codificador que extrae características importantes mediante convoluciones a la imagen de entrada que luego comparte la información a un bloque decodificado, este reestablece las dimensiones espaciales de la imagen y entrega la imagen con su máscara binaria predicha. La arquitectura es normalmente representada en forma de “u” de ahí su nombre. Fue propuesta inicialmente para aplicaciones en segmentación de órganos en imágenes médicas por Ronneberger et al., (2015). Como se mencionó anteriormente es una arquitectura que se ha utilizado en casos de segmentación de fallas; algunos de los estudios que la

utilizan incluyen a Qi et al. (2020); Alohalí et al. (2022) y Ghosh et al. (2023). Estos autores han utilizado para el entrenamiento de sus CNN's conjuntos de datos sintéticos como Qi et al. (2020), quienes evaluaron sus modelos entrenados en imágenes sísmicas reales de Nueva Zelanda, obteniendo mejores predicciones en fallas con alto grado de buzamiento, imposibilidad de mapear fallas lístricas de acuerdo con la naturaleza de los datos de entrenamiento y un bajo tiempo para la realización de predicciones comparado con el entrenamiento. Alohalí et al. (2022) han utilizado imágenes sísmicas reales adquiridas en Arabia, las cuales fueron separadas en porciones de entrenamiento y evaluación, interpretados manualmente y aumentados, concluyendo buenas predicciones en los conjuntos de evaluación y en datos externos como los del volumen F3 de países bajos, donde las predicciones de fallas geológicas fueron buenas.

Cada una de las arquitecturas tienen sus ventajas y desventajas principalmente computacionales o en la calidad de sus predicciones. Según esta revisión se eligieron 3 arquitecturas que se consideran viables para la ejecución y mejor documentación en el estado del arte. Las redes elegidas son la *UNet++* debido a los buenos resultados en conjuntos sintéticos ruidosos, *Inception UNet* por su bajo número de parámetros lo que implica menos parámetros y tiempo de entrenamiento, y la *U-Net* la cual será complementada con algoritmos de bloques de atención en búsqueda de mejorar la calidad de sus predicciones.

5.2.2 Criterios utilizados durante el entrenamiento de las CNN's

Las CNN's son algoritmos no lineales que buscan reducir una función de pérdida entre los datos de entrada y salida, ajustando los valores de los parámetros entrenables mediante una ecuación denominada optimizador, este proceso se realiza utilizando grupos de datos (*batch*) que actualizan los parámetros entrenables varias veces (épocas). Para elegir estos hiperparámetros se

hizo una consulta (ver Tabla 2) de los utilizados disponibles, en los casos de estudio para segmentación de fallas geológicas a lo cual se procedió con la elección de los más utilizados.

Tabla 2.

Configuraciones de CNN's utilizadas en la segmentación de fallas geológicas.

Referencia	Arquitectura	Función de Pérdida	Taza de Aprendizaje	Optimizador	Épocas	Lote (batch)
Wu et al., (2019)	<i>U-Net</i>	Entropía cruzada binaria	$1e^{-4}$	Adam	25	4
Corbetta, (2023)	<i>U-Net</i>	Dice Suavizado	$1e^{-3}$	Adam	20	No reportado
Dou et al., (2021)	<i>Attention U-Net</i>	Entropía cruzada binaria	$1e^{-3}$	Adam	35	32
Dinh & Nguyen, (2022)	<i>Inception-UNet</i>	Entropía cruzada binaria	$1e^{-4}$	Adam	138	No reportado
Liu et al., (2020)	<i>ResUNet</i>	Entropía cruzada balanceada	$1e^{-4}$	Adam	25	200
Bao et al., (2021)	<i>UNet++</i>	Entropía cruzada balanceada	$1e^{-4}$	Adam	200	No reportado

Nota. Esta tabla muestra los hiperparámetros y función de pérdida utilizados en distintas aplicaciones de arquitecturas de redes neuronales convolucionales para la segmentación de fallas geológicas.

De acuerdo con los datos recopilados anteriormente se elige la función de pérdida entropía cruzada balanceada, el optimizador Adam, una taza de aprendizaje de $1e^{-4}$ y un número de 25

épocas para el entrenamiento de las redes. La función de pérdida entropía cruzada balanceada es adecuada para tareas de clasificación de píxeles como la segmentación binaria donde los valores para cada píxel es de 1 o 0, penalizando a la red en los casos en que la predicción no se acerca al valor de la máscara binaria real. La función Adam optimiza los pesos de la red con ventajas como ser eficiente computacionalmente, con poco requerimiento de memoria y adecuado para grandes cantidades de datos y parámetros. El número de lotes utilizado fue de 32 de acuerdo con una prueba realizada, donde el tiempo de entrenamiento fue de 263 ms por iteración para la red U-Net la cual es en la que están basadas las demás redes a implementarse y el número de 25 épocas es suficiente para lograr la convergencia de las redes. Se hizo uso de una GPU P100 alojada en el entorno de ejecución gratuito de la plataforma Kaggle.

5.2.3 Resultado del entrenamiento y evaluación de las CNN's en la predicción de fallas geológicas.

5.2.3.1 Conjuntos de datos utilizados en el entrenamiento, validación y testeo de las CNN's.

Para esta actividad se tomaron 9728 parches de imágenes sísmicas y 9728 parches de sus respectivas máscaras binarias que representan las fallas geológicas de los conjuntos de datos Sintético 1, Sintético 2 y Real 2, luego estos datos fueron divididos en conjuntos de entrenamiento, evaluación y validación (ver Figura 13).

Figura 13.

Distribución de los conjuntos de datos empleados.

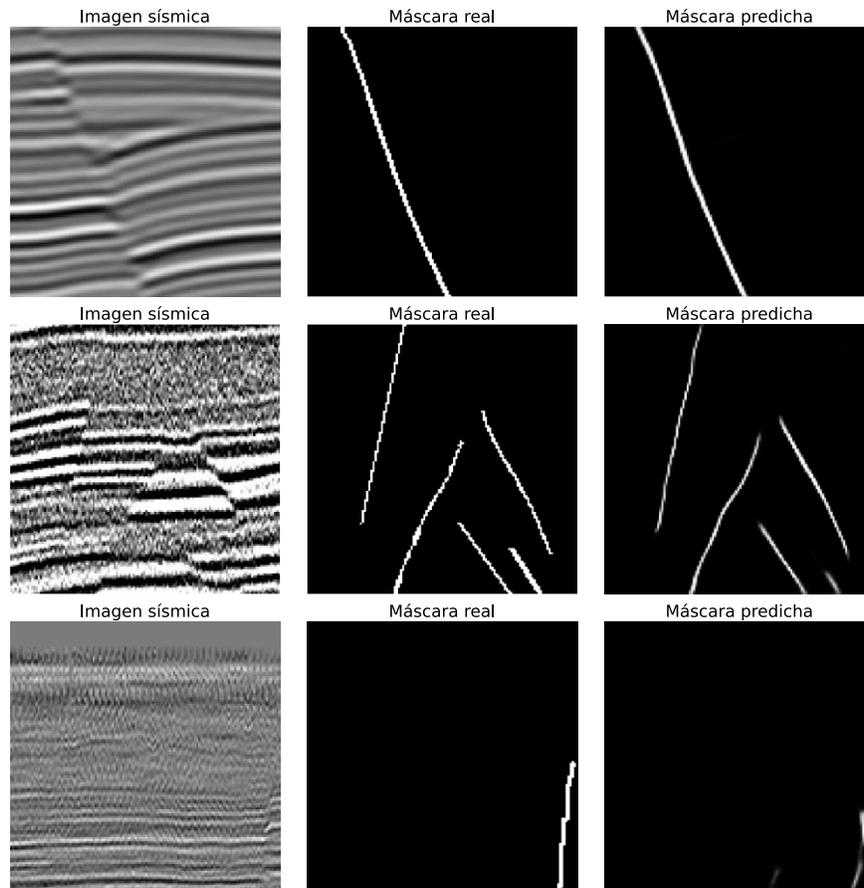


Nota. El gráfico muestra los porcentajes de los 9728 pares de parches extraídos de los conjuntos de datos Sintético 1 y 2 y Real 2 para el entrenamiento, validación y evaluación de las CNN's.

5.2.3.2 Predicciones de fallas geológicas en conjuntos de datos de evaluación.

Figura 14.

Resultados de las predicciones hechas por el modelo Attention U-Net.

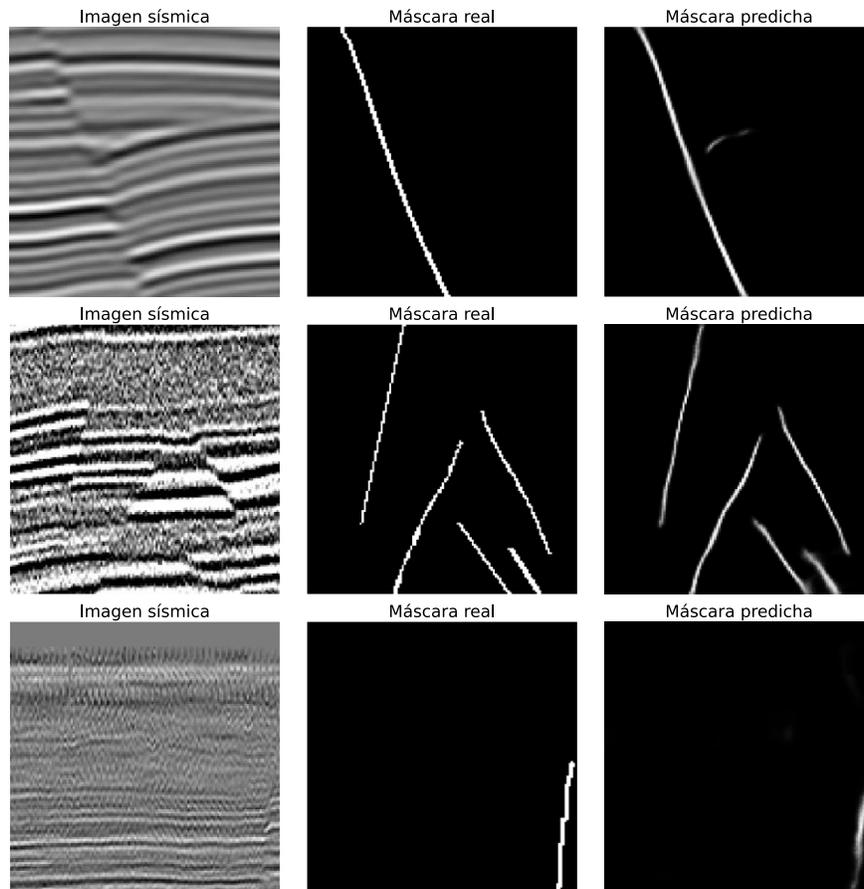


Nota. El gráfico representa ejemplos de las máscaras binaria reales y predichas por la red *Attention U-Net*.a partir de imágenes sísmicas.

Las predicciones realizadas por el modelo Attention U-Net son de buena calidad, se observa que el modelo fue capaz de reconstruir la ubicación de las fallas, aunque se le dificulta su en zonas ruidosas (ver Figura 14).

Figura 15.

Resultados de las predicciones hechas por el modelo UNet++.

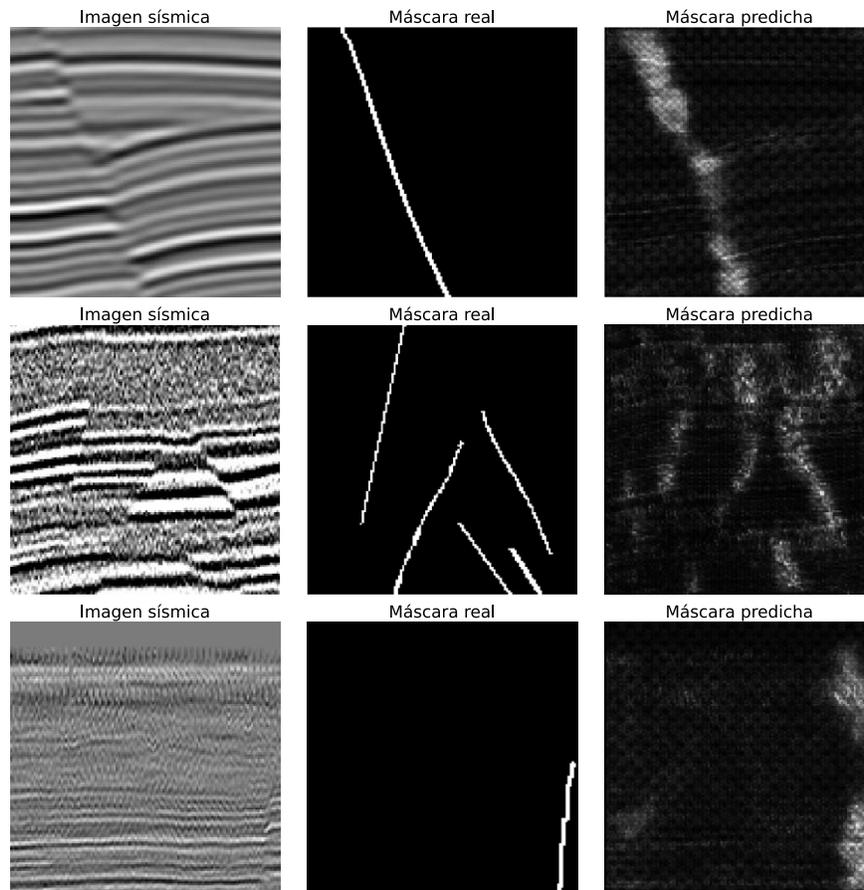


Nota. El gráfico representa ejemplos de las máscaras binaria reales y predichas por la red *UNet++* a partir de imágenes sísmicas.

Las predicciones realizadas por el modelo entrenado *UNet++* aunque delimitan en algunos casos muy bien las fallas geológicas, también se observa en comparación con la máscara binaria real que algunas predicciones no preservan muy bien la geometría original de la falla y la segmentación se ve algo borrosa notable en los extremos de las fallas y en zonas con ruido (ver Figura 15).

Figura 16.

Resultados de las predicciones hechas por el modelo Inception UNet.



Nota. El gráfico representa ejemplos de las máscaras binaria reales y predichas por la red *Inception UNet* a partir de imágenes sísmicas.

El modelo entrenado *Inception UNet* ha realizado predicciones que muestran en algunos casos las fallas resaltando, sin embargo, es evidente que la red también realiza predicciones en toda la dimensión espacial de los parches a veces asociada a los reflectores sísmicos, lo que nos demuestra que la red no aprendió correctamente a discernir entre las fallas geológicas y las superficies de estratificación (ver Figura 16).

5.2.3.3 Desempeño cuantitativo de las arquitecturas de redes neuronales convolucionales.

Una vez realizada la comprobación visual de las predicciones fallas geológicas, se realizó la evaluación del desempeño de los modelos entrenados (ver Tabla 3) mediante el uso de las métricas de Precisión e Intersección sobre Unión - *IoU* (más información sección 24) además de la función de pérdida en la que se espera minimizarla lo mayor posible, ya que esto implica un mejor ajuste de las máscaras predichas a las reales. Otros de los factores que se tuvieron en cuenta incluyen el tiempo de entrenamiento y los parámetros entrenables, los cuales son importantes computacionalmente al realizar tareas de aprendizaje automático ya que un número considerable de parámetros entrenables necesita procesadores con mejores especificaciones y el tiempo de entrenamiento lo hace más viable al ser aplicado en un flujo de trabajo.

Tabla 3.

Desempeño de modelos de CNN's entrenados en las imágenes sísmicas de evaluación.

Arquitectura	Precisión	IoU	Tiempo de Entrenamiento	Parámetros Entrenables
<i>Attention U-Net</i>	0.7511	0.5303	22.2 min	8,134,593
<i>Inception UNet</i>	0.4642	0.0072	6.5 min	73,679
<i>UNet++</i>	0.7339	0.5495	24.6 min	9,041,601

Nota. Esta tabla muestra los resultados de la evaluación de las imágenes de evaluación en cada una de las arquitecturas implementadas.

Aunque el modelo *Inception UNet*, presenta el menor de los tiempos de entrenamiento y número de parámetros entrenables, haciéndolo fácil de entrenar y con menor costo computacional, sus valores en las métricas y reducción de función de pérdida demuestran su deficiencia para realizar la tarea de segmentación de fallas comparado con los otros 2 algoritmos. El modelo de

CNN *UNet++* supera al modelo entrenado *Attention U-Net* en la mayoría de las métricas y alcanza un valor menor en la función de pérdida, sin embargo, el modelo *U-Net* tiene una mejor relación entre las métricas (*IoU* y Precisión) y el costo computacional (tiempo y número de parámetros de entrenamiento).

En resumen, el modelo de CNN entrenado con mejor rendimiento es el modelo *Attention U-Net*, debido a sus buenos resultados tanto cualitativos como cuantitativos por lo que se elige este modelo de prueba como óptimo para avanzar a la siguiente fase de evaluación de influencia de ruido en las predicciones realizadas.

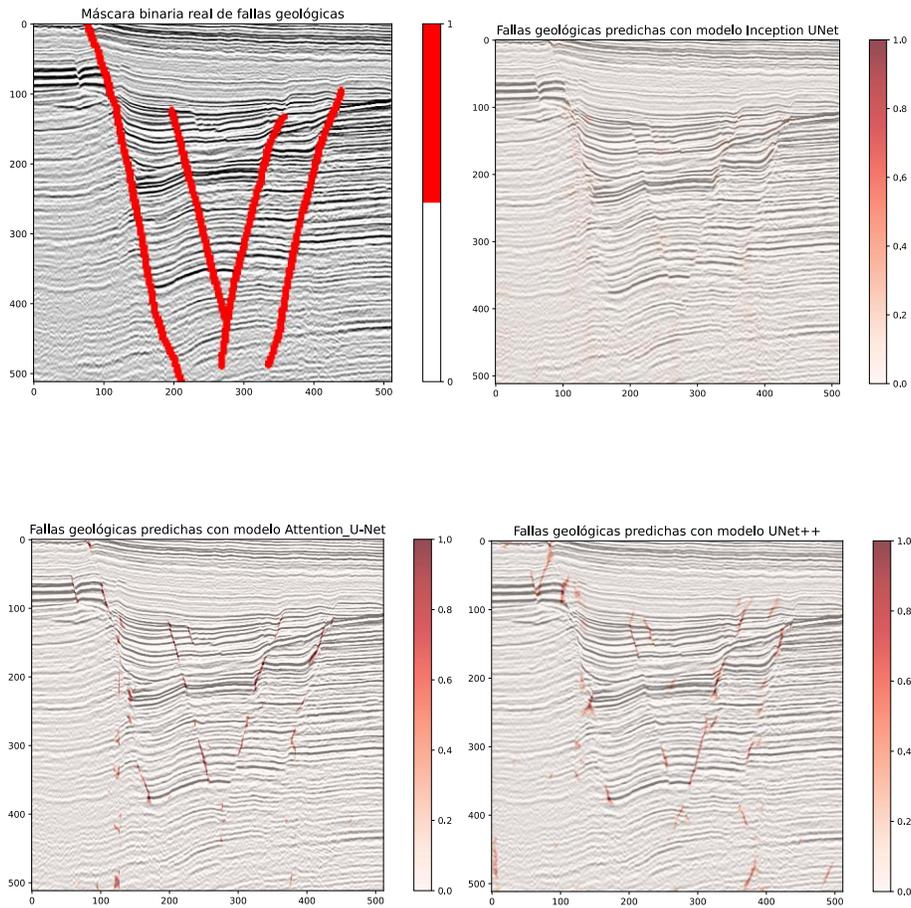
5.2.3.4 Predicciones de fallas geológicas en conjunto Real 1. Durante la predicción del conjunto de datos Real 1 (ver Figura 17), el algoritmo *Attention U-Net* es capaz de segmentar fallas geológicas con precisión a través de las discontinuidades estratigráficas. Además, realizó predicciones exitosas en zonas originalmente no etiquetadas como fallas, pero que, si pertenecen a ellas, lo que nos da un indicio de que el modelo es útil a realizar predicciones generales sobre las imágenes. Asimismo, evita realizar interpretaciones falsas en zonas con presencia de ruido sísmico.

La predicción realizada en el conjunto Real 1 por el modelo *UNet++*, muestra que las zonas donde el modelo predijo efectivamente fallas geológicas coinciden con la ocurrencia de fallas. Aunque en general sus predicciones son muy buenas, en algunas situaciones como plegamientos donde no necesariamente existen fallas son erróneamente interpretadas como tales.

Finalmente, en este mismo conjunto de datos se observó que algunas de las predicciones realizadas por el modelo *Inception UNet* se ajustan a las fallas geológicas, pero también generan predicciones en zonas donde estas no existen. Estas predicciones realizadas por este modelo son difusas y muy poco definidas, generando predicciones de muy baja calidad.

Figura 17.

Predicciones de fallas geológicas realizadas por los modelos Inception UNet, Attention U-Net y UNet++.



Nota. En las imágenes se observan las máscaras binarias predicciones de fallas realizada por los modelos *Attention U-Net*, *UNet++* e *Inception UNet*, en un parche del inline 50 de un volumen del conjunto de datos Real 1. Los valores cercanos a 1 (rojo) representan una mayor probabilidad de falla y los valores cercanos a 0 (transparente) zonas sin fallas geológicas.

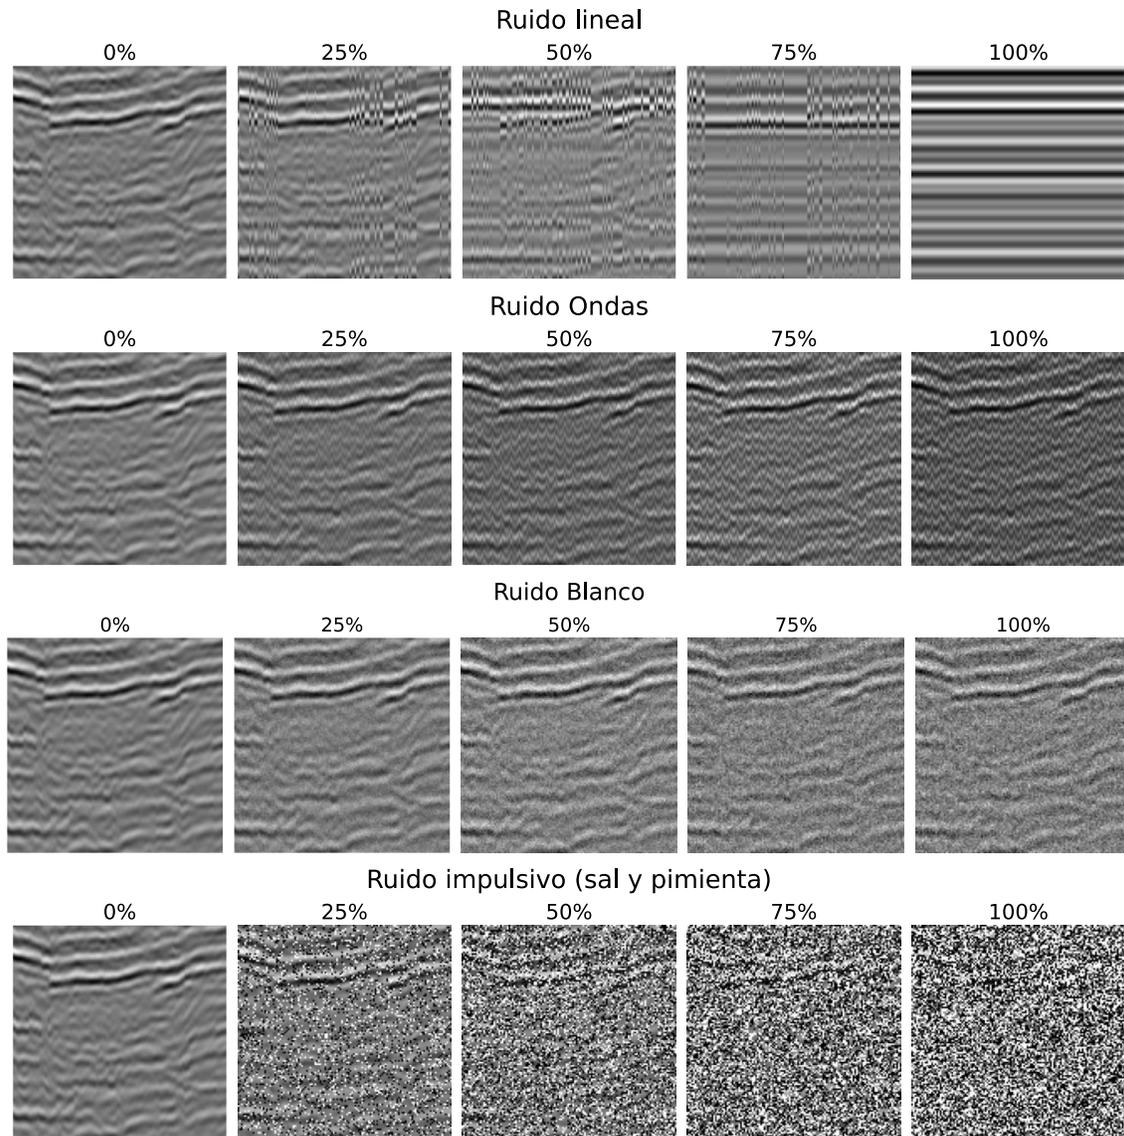
5.3 Influencia del ruido sísmico en la segmentación de fallas geológicas mediante algoritmos de redes neuronales convolucionales.

5.3.1 *Inducción de ruido en imágenes sísmicas de evaluación.*

Se simularon varios patrones de ruido en las imágenes sísmicas de testeo o evaluación, las cuales fueron utilizadas en la siguiente actividad de la presente fase (ver Figura 18). Los tipos de ruido a simular en los parches sísmicos buscan recrear algunos de los ruidos sísmicos comunes en las adquisiciones sísmicas y así obtener el control de esta variable experimental para su evaluación. Los algoritmos de ruido fueron modificados de Torres Quintero et al. (2024). Se eligieron 4 funciones que simulan el ruido (2 de tipo coherente y 2 de tipo aleatorio), inducidos con intensidades de ruido de 0, 25, 75 y 100 por ciento en cada parche sísmico, como se muestra en la Figura 18. Según Hlebnikov et al. (2021) y Yilmaz (2001), uno de los ruidos coherente comunes en la adquisición sísmica marina está relacionado con el movimiento de las olas. Este tipo de ruido genera una serie de líneas verticales de alta amplitud y baja frecuencia, las cuales difieren de las características de la mayoría de las trazas; este tipo de ruido computacionalmente se simuló mediante el algoritmo de ruido lineal. En las adquisiciones sísmicas tierra adentro este ruido coherente se encuentra relacionado principalmente a las ondas de superficie generando el efecto “*Ground-roll*” (Yilmaz, 2001). Este tipo de ruido genera una serie de ondas de interferencia que pueden enmascarar la información sísmica real; para su simulación se utilizó el algoritmo de generación de ondas/difracciones descrito en el Apéndice B, el cual genera una serie de ondas sinusoidales en distinto rangos de intensidad. Seguidamente se inició la simulación de los 2 tipos de ruidos aleatorio; normalmente se cree que el ruido aleatorio sigue una distribución gaussiana (Zhong et al., 2015), mientras que otros autores como Yue et al. (2013), hablan de la existencia de ruido aleatorio impulsivo o como comúnmente se le conoce, de sal y pimienta. Los tipos de ruido anteriormente mencionados fueron simulados para un total de 49,453 imágenes.

Figura 18.

Visualización de los parches sísmicos con distintos tipos de ruido simulado e intensidad.



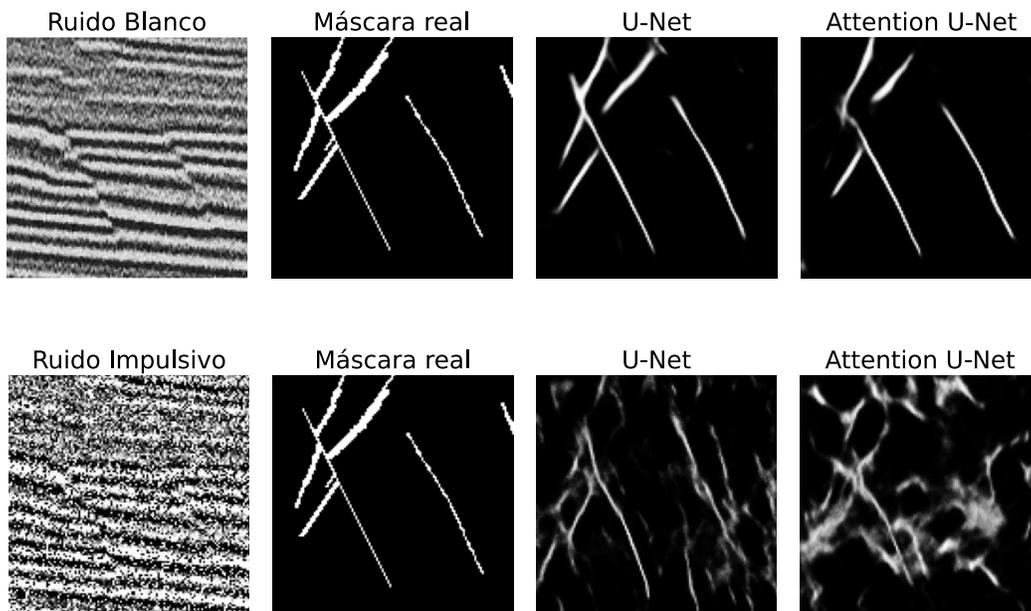
Nota. El gráfico presenta los 4 tipos de ruidos de ruido simulados en la misma imagen sísmica, cada uno en valores de 0, 25, 50, 75 y 100 % de ruido.

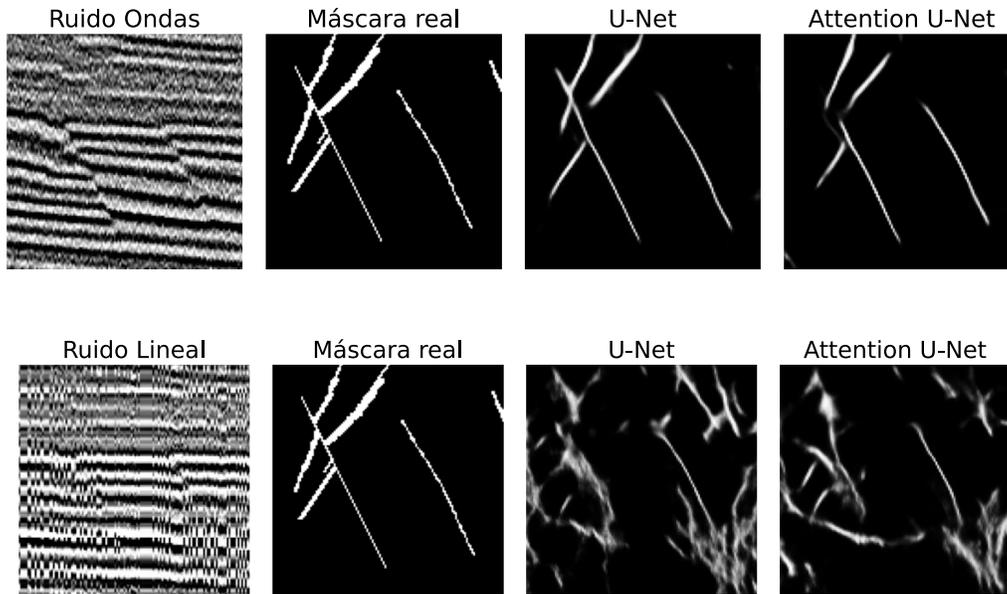
5.3.2 Desempeño de los bloques de atención en la predicción de fallas geológicas en imágenes sísmicas ruidosas.

La arquitectura de CNN's *Attention U-Net*, está compuesta por el modelo *U-Net* convencional complementado con bloques de atención que se ubican en las conexiones de salto de la red (ver Apéndices C). En este paso se compararon las predicciones de fallas geológicas en las imágenes sísmicas con ruido disponibles de la anterior actividad y se evaluaron en los modelos *U-Net* y *U-Net* complementado con bloques de atención (*Attention U-Net*). En la Figura 19 se compara visualmente las predicciones realizadas a imágenes con 50% de ruido por los modelos anteriormente mencionados, considerando los cuatro tipos de ruido descritos en la sección anterior.

Figura 19.

Predicciones realizadas por los modelos U-Net con ruido simulado al 50%.





Nota. El gráfico presenta las predicciones realizadas por los algoritmos de red neuronal U-Net con y sin bloques de atención para cada uno de los 4 tipos de ruido en una simulación del 50 %.

5.3.2.1 Evaluación cuantitativa de la influencia de ruido en la segmentación de fallas geológicas. Para obtener varios puntos de comparación se tomaron las métricas relacionadas en el marco teórico para evaluar el desempeño de los modelos a los 4 tipos de ruido y varios porcentajes de ruido (ver Tabla 4, Tabla 5, Tabla 6 y Tabla 7).

Tabla 4.

Influencia del nivel de ruido en métrica de intersección sobre unión (IoU) en U-Net con y sin bloques de atención.

CNN	<i>Attention U-Net</i>					<i>U-Net</i>				
	0%	25%	50%	75%	100%	0%	25%	50%	75%	100%
Ruido	0%	25%	50%	75%	100%	0%	25%	50%	75%	100%
Lineal	0.4275	0.1474	0.0571	0.0189	0.0000	0.5667	0.1864	0.0639	0.0206	0.0002
Ondas	0.4275	0.3581	0.2509	0.1769	0.1294	0.5667	0.4666	0.3100	0.2419	0.2019
Blanco	0.4275	0.3878	0.3007	0.2261	0.1716	0.5667	0.5178	0.3682	0.2419	0.1690

Ruido	0%	25%	50%	75%	100%	0%	25%	50%	75%	100%
Impulsivo	0.4275	0.1253	0.0595	0.0390	0.0300	0.5667	0.1216	0.0549	0.0319	0.0225

Nota: El valor en negrita es el mayor valor obtenido en cada porcentaje de ruido para la red U-Net complementada y no complementada con bloques de atención.

El análisis de la Tabla 4 muestra un mejor desempeño en la métrica de *Intersection over Union (IoU)* de la red *U-Net* sin bloques de atención independientemente de la intensidad de ruido aplicado a las imágenes. Esta métrica nos muestra que tanto se superponen las máscaras binarias predicha y real sobre el área que ocupan ambas, de lo que se puede intuir que la red *U-Net* complementada con mecanismos de atención (*Attention U-Net*) está también generando falsas predicciones en zonas donde no existen fallas geológicas como consecuencia del ruido sísmico, específicamente el ruido impulsivo dificultó la tarea de segmentación en ambas arquitecturas de *CNN's*. Desde el análisis individual de cada modelo la red *U-Net* complementada con bloques de atención tuvo mejores resultados frente al ruido de Ondas, mientras en la red *U-Net* sin bloques de atención la red realizó mejores predicciones en imágenes con ruido blanco.

Tabla 5.

Influencia de nivel de ruido en métrica de precisión en U-Net con y sin bloques de atención.

CNN	<i>Attention U-Net</i>					<i>U-Net</i>				
Ruido	0%	25%	50%	75%	100%	0%	25%	50%	75%	100%
Lineal	0.7431	0.2636	0.1046	0.0495	0.1020	0.7815	0.3042	0.1166	0.0557	0.0917
Ondas	0.7431	0.7365	0.7012	0.6763	0.6631	0.7815	0.7635	0.7080	0.6673	0.6349
Blanco	0.7431	0.7003	0.6239	0.5596	0.5171	0.7815	0.7613	0.7037	0.6330	0.5893
Impulsivo	0.7431	0.1582	0.1047	0.0578	0.0391	0.7815	0.2909	0.1028	0.0555	0.0363

Nota. El valor en negrita es el mayor valor obtenido en cada porcentaje de ruido para la red U-Net complementada y no complementada con bloques de atención.

La Tabla 5 muestra los valores obtenidos para la métrica de precisión en las predicciones realizadas por la red *U-Net* evaluada con y sin bloques de atención. La métrica de precisión evalúa el porcentaje de píxeles predichos como positivos que son realmente positivos. Los datos obtenidos muestran que la red *U-Net* sin bloques de atención obtuvo mejores resultados en la precisión de sus predicciones, esto demuestra que los mecanismos de atención se ven afectados por condiciones de ruido realizando predicciones de fallas donde no existen fallas geológicas. Específicamente la red *U-Net* complementada con bloques de atención obtiene una mejor precisión en condiciones de ruido blanco (gaussiano) si este se encuentra entre 0 y 25 % de intensidad y en ruido de ondas si la intensidad de ruido es mayor al 25% además se ve afectada en mayor proporción por el ruido lineal e impulsivo. Mientras tanto, la red *U-Net* no complementada con los bloques de atención obtiene siempre un mejor desempeño frente al ruido de tipo ondas y genera predicciones menos precisas cuando las imágenes están contaminadas con ruido impulsivo.

Tabla 6.

Influencia de nivel de ruido en métrica de Recall en U-Net con y sin bloques de atención.

CNN	<i>Attention U-Net</i>					<i>U-Net</i>				
	0%	25%	50%	75%	100%	0%	25%	50%	75%	100%
Ruido										
Lineal	0.4575	0.2406	0.1137	0.0361	0.0000	0.4645	0.2554	0.1132	0.0322	0.0000
Ondas	0.4575	0.3705	0.2476	0.1667	0.1181	0.4645	0.3947	0.2873	0.2205	0.1811
Blanco	0.4575	0.4283	0.3433	0.2525	0.1793	0.4645	0.4329	0.3396	0.2334	0.1568
Impulsivo	0.4575	0.1315	0.0942	0.0933	0.1083	0.4645	0.1522	0.0957	0.0773	0.0756

Nota. El valor en negrita es el mayor valor obtenido en cada porcentaje de ruido para la red *U-Net* complementada y son complementada con bloques de atención.

La Tabla 6 muestra los valores obtenidos para la métrica Recall de la evaluación de bloques de atención en la red *U-Net*. La métrica Recall permite saber que tantos de los píxeles que son

fallas geológicas fueron predichos como fallas. En esta métrica se observa que la red *U-Net* complementada con bloques de atención ligeramente tiene mejor desempeño en segmentar la mayor cantidad de fallas reales en las imágenes sísmicas, los mejores resultados se encuentran en imágenes con ruido blanco (gaussiano) al igual que en la red *U-Net* sin bloques de atención. En ambos casos con y sin bloques de atención la métrica de Recall se ve afectada en mayor medida por imágenes sísmicas con ruido impulsivo.

Tabla 7.

Influencia de nivel de ruido en métrica de coeficiente de Dice en U-Net con y sin bloques de atención.

CNN	<i>Attention U-Net</i>					<i>U-Net</i>				
	Ruido	0%	25%	50%	75%	100%	0%	25%	50%	75%
Lineal	0.4385	0.1797	0.0812	0.0323	0.0000	0.4742	0.2121	0.0882	0.0298	0.0000
Ondas	0.4385	0.3705	0.2726	0.1994	0.1499	0.4742	0.4234	0.3238	0.2538	0.2111
Blanco	0.4385	0.4065	0.3335	0.2572	0.1931	0.4742	0.4492	0.3709	0.2684	0.1893
Impulsivo	0.4385	0.1080	0.0523	0.0387	0.0350	0.4742	0.1167	0.0591	0.0409	0.0345

Nota. El valor en negrita es el mayor valor obtenido en cada porcentaje de ruido para la red *U-Net* complementada y no complementada con bloques de atención.

La Tabla 7 muestra los valores obtenidos para la métrica de Dice en la evaluación de las predicciones realizadas por la arquitectura de red *U-Net* con y sin bloques de atención. La métrica de Dice es muy parecida a la de *Intersection over Union (IoU)* pero teniendo en cuenta también la cantidad de píxeles de fallas que la red no predijo como fallas. La red *U-Net* sin bloques de atención obtiene mejores resultados en esta métrica en todas las intensidades de ruido propuestas, esto demuestra que la red *U-Net* sin bloques de atención es más precisa en sus predicciones y deja menos fallas sin predecir como fallas geológicas. En intensidades de ruido menor al 50 % las

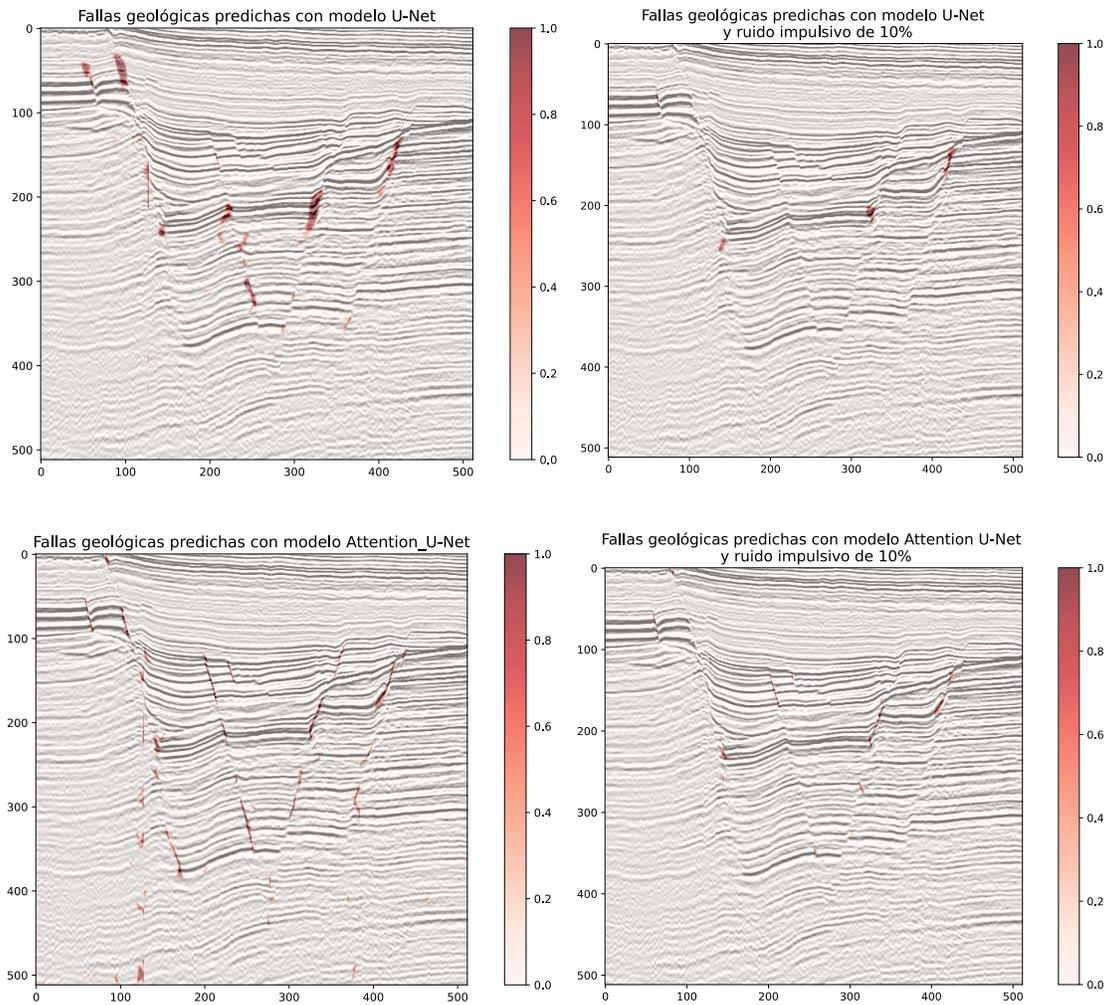
predicciones de ambas redes se ven afectadas por ruido de tipo impulsivo mientras de 50% en adelante el ruido lineal afecta en mayor medida los resultados de la segmentación. Ambas arquitecturas de red demostraron tener un mejor desempeño en imágenes sísmicas con ruido blanco (gaussiano). Según las métricas calculadas, el ruido blanco es el que menos afectó los resultados de la red U-Net el cual está normalmente asociado por naturaleza a las imágenes sísmicas. Mientras, el ruido impulsivo es el que más afectó la tarea de segmentación hecha por la red U-Net, posiblemente su naturaleza de valores extremos oculta en mayor medida la información sísmica. Por lo tanto, para la predicción de fallas geológicas con arquitecturas de redes neuronales *U-Net* se espera un mejor desempeño cuando el ruido presente sigue una distribución gaussiana, sin embargo, al ser afectado principalmente por el ruido impulsivo se deben buscar métodos para la reducción de este tipo de ruido en las imágenes sísmicas antes de utilizar el modelo de red neuronal *U-Net*.

En cuanto al desempeño de los bloques de atención como resultado de estas pruebas, se ve un mejor desempeño de la red no complementada con los bloques de atención. Si bien los bloques de atención pueden generar mayores predicciones de fallas geológicas, estas no necesariamente coinciden con fallas reales.

5.3.2.2 Aplicación y evaluación en datos del conjunto Real 1 con ruido. Con el objetivo de complementar la evaluación de los bloques de atención en la capacidad de segmentar fallas geológicas a pesar de cierto grado de ruido sísmico se eligió la sección estudiada durante todo el trabajo del conjunto de datos Real 1 para su evaluación con el tipo de ruido impulsivo (ver Figura 20) ya que demostró afectar mayormente los modelos de CNN's entrenados y un valor intermedio de ruido (50%).

Figura 20.

Máscara binaria real y predichas de fallas geológicas, realizadas por los modelos U-Net complementado con bloques de atención (Attention U-Net) y no complementado con bloques de atención (U-Net) en Real 1 con ruido impulsivo al 10 %.



Nota. Se observa las máscaras binarias predichas por los modelos *U-Net* complementado con bloques de atención (*Attention U-Net*) y no complementado con bloques de atención (*U-Net*) en un parche del inline 50 de un volumen del conjunto de datos Real 1 con ruido impulsivo al 10 %.

Los valores cercanos a 1 (rojo) representan una mayor probabilidad de falla y los valores cercanos a 0 (transparente) zonas sin fallas geológicas.

Tabla 8.

Evaluación de los modelos U-Net y Attention U-Net en parche del conjunto real 1 a 0 y 10% de ruido impulsivo.

0% Ruido Impulsivo	Precisión	IoU	Recall	Dice
<i>Attention U-Net</i>	0.6824	0.0644	0.0589	0.0931
<i>U-Net</i>	0.7870	0.0819	0.0678	0.1078
10% Ruido Impulsivo	Precisión	IoU	Recall	Dice
<i>Attention U-Net</i>	0.8049	0.0172	0.0154	0.0277
<i>U-Net</i>	0.8011	0.0172	0.0135	0.0245

Nota. La tabla muestra los valores obtenidos de las métricas al evaluar los modelos *Attention U-Net* y *U-Net*, utilizando un parche del conjunto de datos Real 1 con ruido impulsivo al 0 y 10 %.

El análisis visual de las predicciones realizadas por la red *U-Net* complementada y sin complementar con bloques de atención en datos reales muestra como el ruido impulsivo genera que ambas arquitecturas de red no sean capaces de determinar la ocurrencia de fallas geológicas en los lugares correctos. En este aspecto se puede observar como la red *U-Net* sin bloques de atención realiza predicciones de fallas principalmente en la capa de agua y pocas predicciones en los sedimentos que es donde suceden las fallas geológicas, mientras la red complementada con los bloques de atención si realiza predicciones de fallas geológicas en los sedimentos lo que demuestra que los bloques de atención ayudaron a entender la relación geológica de las fallas con el subsuelo.

6 Conclusiones

Se realizó la recopilación de aproximadamente 25 GB de información correspondientes a imágenes sísmicas reales y sintéticas con sus respectivas máscaras binarias de fallas geológicas desde repositorios de acceso libre alojados en internet. Las imágenes sísmicas recopiladas incluyen secciones con 2 a 12 fallas interconectadas, importantes para el desempeño de la red en condiciones de litologías muy fracturadas, y una ocurrencia de 9 a 52 fallas lo que permitió a las redes reconocer fallas geológicas a distintos rangos de separación entre ellas y conectar fallas asociadas espacialmente. Las fallas geológicas recopiladas presentaron cinemáticas normales e inversas, observables en las secciones sísmicas. Como resultado del procesamiento luego de un proceso de aumento de datos se obtuvo un total de 1,721,152 parches sísmicos con sus respectivas máscaras binarias de dimensiones 128x128 a las cuales se aplicó una normalización entre los valores de 0 y 1 de acuerdo con pruebas realizadas que evidencian un mejor desempeño en el entrenamiento de la red a los estandarizados entre 1 y -1. Con esto, se logró construir una base de datos lista para su uso en tareas de segmentación de fallas geológicas mediante redes neuronales convolucionales.

Se determinó con base en la revisión bibliográfica que las mejores redes para la tarea de segmentación de fallas geológicas en imágenes sísmicas son la *UNet++* debido a los buenos resultados en conjuntos sintéticos ruidosos, *Inception UNet* por su bajo número de parámetros lo que implica menos costo computacional y tiempo de entrenamiento, y la *Attention U-Net* por su variedad de aplicaciones y documentación disponible. Como resultado de la implementación de estas arquitecturas se observó que el peor desempeño lo obtuvo el modelo *Inception UNet*, el cual generó máscaras binarias que no representaron trazos continuos propios de fallas geológicas. Por el contrario, los modelos *Attention U-Net* y *UNet++* demostraron ser capaces de segmentar fallas geológicas en imágenes sintéticas y reales. Cuantitativamente, aunque el modelo *UNet++* consigue un mejor desempeño en las métricas evaluadas de precisión e *Intersection over Union*

(*IoU*), la diferencia es baja, por lo tanto, de acuerdo con el resultado cualitativo y la relación entre el desempeño y costo computacional (número de parámetros entrenables y tiempo de entrenamiento) de los modelos, la red neuronal convolucional *Attention U-Net* demostró tener un mejor desempeño para tareas de segmentación de fallas geológicas.

Como resultado de la evaluación cualitativa y cuantitativa del desempeño de los modelos entrenados *U-Net* con y sin bloques de atención se dedujo que de los ruidos evaluados el ruido blanco (gaussiano) normalmente asociado a las imágenes sísmicas en adquisiciones reales, fue el tipo de ruido que menos afectó la tarea de segmentación de las fallas geológicas, por lo que en aplicaciones reales este tipo de ruido generalmente no presentaría un mayor problema para la red en la segmentación geológica de las fallas. Por otra parte, se observó que dentro de los ruidos evaluados el impulsivo (sal y pimienta) es el que más afecta a los modelos *U-Net* con y sin bloques de atención, lo que hace necesario buscar alternativas para la disminución de este ruido en imágenes sísmicas antes de utilizar los modelos basados en las arquitecturas *U-Net* con y sin bloques de atención. En cuanto a la función de los bloques de atención, se evidenció que el modelo *Attention U-Net* fue capaz de generar predicciones precisas de fallas geológicas, delimitando exactamente los planos de fallas, al someterlo a imágenes con ruido de intensidad baja (10%) es capaz de seguir realizando predicciones buenas, sin que el ruido induzca falsas predicciones por la red. A su vez, el modelo no complementado con mecanismos de atención (*U-Net*) realiza predicciones acertadas de las fallas geológicas, sin embargo, estas predicciones no son continuas a lo largo de las fallas y disminuye su capacidad de predicción con un ruido de intensidad baja (10%).

7 Recomendaciones y trabajo futuro

Se sugiere complementar el entrenamiento de los modelos de redes neuronales convolucionales con nuevos datasets con el objetivo de aumentar el dominio estructural de los datos como variabilidad en ambientes estructurales y por lo tanto tipos de fallas, además se recomienda ampliar la investigación mediante la implementación de algoritmos que simulen otros tipos de ruido para entender el desempeño de los mecanismos de atención en estas nuevas condiciones, así como validar los modelos entrenados en nuevos datos sísmicos reales.

Este trabajo sienta las bases para seguir desarrollando a futuro los modelos de CNN's para la mejora de los procesos de segmentación de las fallas geológicas mediante la evaluación de los hiperparámetros utilizados o el reentrenamiento de los modelos con imágenes sísmicas interpretadas por profesionales para su adaptación a características geológicas específicas.

La base de datos procesada constituye un material importante para futuras investigaciones de CNN's aplicadas a la segmentación de fallas geológicas en imágenes sísmicas.

Se propone como trabajo futuro complementar esta metodología dentro de otros flujos de trabajo como una herramienta de asistencia al intérprete o como parte de programas que permitan la extracción de planos de fallas tridimensionales, como los utilizados actualmente en la industria para el modelamiento geológico.

8 Repositorio y acceso a datos

Los datos utilizados en la realización de este trabajo son de acceso abierto y pueden ser encontrados en internet en los vínculos proporcionados en la sección 5.1.1 y procesados según la metodología en el siguiente repositorio de datos: <https://github.com/AlvaroAscanio/Segmentacion-de-Fallas-Geologicas-en-Imagenes-Sismicas-ruidosas>.

Referencias bibliográficas

- Adeyemo, A., & Wimmer, H. (2018). *Effects of Normalization Techniques on Logistic Regression in Data Science*. <http://iscap.info>
- Alcalde, J., Bond, C. E., Johnson, G., Butler, R. W. H., Cooper, M. A., & Ellis, J. F. (2017). The importance of structural model availability on seismic interpretation. *Journal of Structural Geology*, 97, 161–171. <https://doi.org/10.1016/j.jsg.2017.03.003>
- Alcalde, J., Bond, C. E., Johnson, G., Ellis, J. F., & Butler, R. W. H. (2017). Impact of seismic image quality on fault interpretation uncertainty. *GSA Today*, 27(2), 4–10. <https://doi.org/10.1130/GSATG282A.1>
- Álvarez Castillo, B. D., Goyes Peñafiel, Y. P., & Argüello Fuentes, H. (2022). *Detección automática de fracturas y fallas geológicas a partir de la segmentación de imágenes con redes convolucionales profundas aplicadas a cubos sísmicos*. Universidad Industrial de Santander.
- An, Y., Guo, J., Ye, Q., Childs, C., Walsh, J., & Dong, R. (2021). A gigabyte interpreted seismic dataset for automatic fault recognition. *Data in Brief*, 37, 107219. <https://doi.org/10.1016/J.DIB.2021.107219>
- Anderson, R. G., & McMechan, G. A. (1988). Noise-adaptive filtering of seismic shot records. *Geophysics*, 53(5), 638–649. <https://doi.org/10.1190/1.1442498>
- Bao, Y., Liu, W., Gao, O., Lin, Z., & Hu, Q. (2021). E-Unet++: A Semantic Segmentation Method for Remote Sensing Images. *IMCEC 2021 - IEEE 4th Advanced Information Management, Communicates, Electronic and Automation Control Conference*, 1858–1862. <https://doi.org/10.1109/IMCEC51613.2021.9482266>
- Barnes, A. E. (2016). *Handbook of poststack seismic attributes*. Society of Exploration Geophysicists.

- Corbetta, F. (2023). *Detección automática de fallas geológicas en datos sísmicos utilizando aprendizaje profundo* [Doctoral dissertation]. Universidad Nacional de la Plata.
- Dinh, V. H. T., & Nguyen, T. A. (2022). 3D-Inception-UNet: A Light-weight U-Net Variant with Inception Blocks for 3D Fault Segmentation in Seismic Data. *Proceedings - 2022 RIVF International Conference on Computing and Communication Technologies, RIVF 2022*, 191–196. <https://doi.org/10.1109/RIVF55975.2022.10013875>
- Dou, Y., & Li, K. (2024). 3D seismic Fault Detection via Contrastive-Reconstruction Representation Learning. *Expert Systems with Applications*, 249. <https://doi.org/10.1016/j.eswa.2024.123617>
- Dou, Y., Li, K., Zhu, J., Li, X., & Xi, Y. (2021). Attention-Based 3D Seismic Fault Segmentation Training by a Few 2D Slice Labels. <https://doi.org/10.1109/TGRS.2021.3113676>
- Elboth, T., Vik Presterud, I., & Hermansen, D. (2010). Time-frequency seismic data denoising. *Geophysical Prospecting*, 58(3), 441–453. <https://doi.org/10.1111/j.1365-2478.2009.00846.x>
- Fogat, M., Roy, S., Ferreira, V., & Singh, S. (2023). A Comparative Analysis of Convolutional Neural Networks for Seismic Noise Attenuation. *Society of Petroleum Engineers - SPE EuropEC - Europe Energy Conference Featured at the 84th EAGE Annual Conference and Exhibition, EURO 2023*. <https://doi.org/10.2118/214392-MS>
- García-Arias, S., Patiño, F. A. V., Gómez, J. D. S., & Ardila, M. T. U. (2024). Mapas predictivos con redes neuronales a partir de propiedades físicas de las rocas: caso de estudio en la Mesa de Los Santos (Santander). *Revista EIA*, 21(41), 4112-pp.
- Groshong, R. H. (2006). *3-D structural geology*. Springer.

- Hart, B. S. (2000). *3-D seismic interpretation: a primer for geologists* (Vol. 48). SEPM (Society for Sedimentary Geology).
- Hlebnikov, V., Elboth, T., Vinje, V., & Gelius, L. J. (2021). Noise types and their attenuation in towed marine seismic: A tutorial. *Https://Doi.Org/10.1190/Geo2019-0808.1*, 86(2), W1–W19. <https://doi.org/10.1190/GEO2019-0808.1>
- Kim, M., Yu, J., Kang, N. K., & Kim, B. Y. (2021). Improved workflow for fault detection and extraction using seismic attributes and orientation clustering. *Applied Sciences (Switzerland)*, 11(18). <https://doi.org/10.3390/app11188734>
- Kumar, D., & Ahmed, I. (2020). Seismic Noise. *Encyclopedia of Earth Sciences Series, PartF4*. https://doi.org/10.1007/978-3-030-10475-7_146-1
- Laiton-Bonadiez, C., Sanchez-Torres, G., Leal, N., & Polo-Llanos, A. (2023). Segmentation of Brain Structures in Magnetic Resonance Imaging Using a Spatial Approach Based on Self-Attention Modules. *CISCI 2023 - Vigésima Segunda Conferencia Iberoamericana En Sistemas, Cibernética e Informática, Vigésimo Simposium Iberoamericano En Educacion, Cibernética e Informática, SIECI 2023 - Memorias*, 16–20. <https://doi.org/10.54808/CISCI2023.01.16>
- León Batallas, A., Bermeo-Paucar, J., Paredes-Quevedo, J., & Torres-Ordoñez, H. (2020). Una revisión de las métricas aplicadas en el procesamiento de imágenes. *RECIMUNDO*, 4(3), 267–273. [https://doi.org/10.26820/recimundo/4.\(3\).julio.2020.267-273](https://doi.org/10.26820/recimundo/4.(3).julio.2020.267-273)
- Li, Z., Jia, M., Yang, X., & Xu, M. (2021). Blood vessel segmentation of retinal image based on dense-U-net network. *Micromachines*, 12(12). <https://doi.org/10.3390/mi12121478>

- Liu, N., He, T., Tian, Y., Wu, B., Gao, J., & Xu, Z. (2020). Common-azimuth seismic data fault analysis using residual UNet. *Interpretation*, 8(3), SM25–SM37. <https://doi.org/10.1190/INT-2019-0173.1>
- Mantilla Dulcey, A. G. (2023). Predicción de la ocurrencia de depósitos minerales tipo pórfido usando técnicas de. *Journal of Environment Research and Public Health*, 1, 12.
- Mazloum, T. (2024). *Seismic interpretation with OpendTect: Study of shallow gas expressions in the F3 block (Dutch North Sea)*.
- Milsom, J., & Eriksen, A. (2013). *Field geophysics*. EEGS 1720 South Bellaire, Suite 110, Denver, CO 80222-4303, USA.
- Nava, L., Bhuyan, K., Meena, S. R., Monserrat, O., & Catani, F. (2022). Rapid Mapping of Landslides on SAR Data by Attention U-Net. *Remote Sensing*, 14(6). <https://doi.org/10.3390/rs14061449>
- Oktay, O., Schlemper, J., Le Folgoc, L., Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B., & Rueckert, D. (2018). *Attention U-Net: Learning Where to Look for the Pancreas*.
- Rangel, E. O., Mejía-Lavalle, M., & Sossa, H. (2017). Filtrado de ruido Gaussiano mediante redes neuronales pulso-acopladas. *Computacion y Sistemas*, 21(2), 381–395. <https://doi.org/10.13053/CyS-21-2-2742>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-Net: Convolutional Networks for Biomedical Image Segmentation*. <http://arxiv.org/abs/1505.04597>
- Simm, R., & Bacon, M. (2014). *Seismic amplitude: An interpreter's handbook*. Cambridge university press.

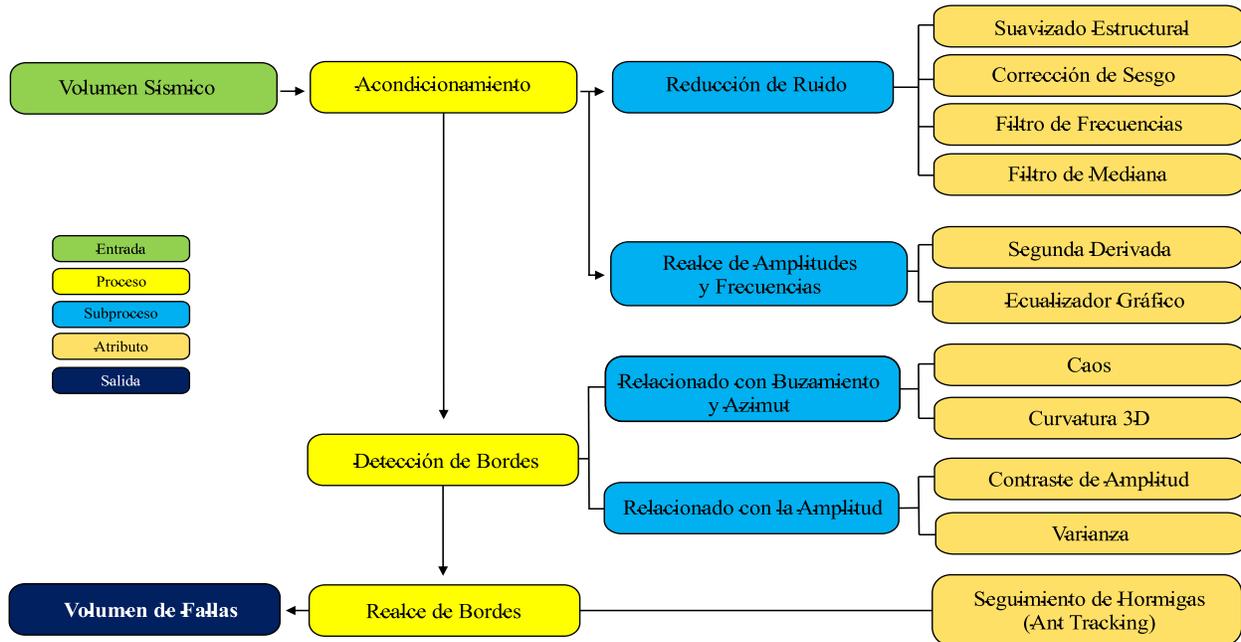
- Talagapu, K. K. (2005). 2D and 3D land seismic data acquisition and seismic data processing. *Department of Geophysics, College of Science and Technology Andhra University. Andhra Pradesh.*
- TerraNubis. (2017). *NW Shelf Australia - Poseidon 3D*. <https://terranubis.com/datainfo/NW-Shelf-Australia-Poseidon-3D>
- TerraNubis. (2020). *Project F3 Demo 2020 dataset*. <https://terranubis.com/datainfo/F3-Demo-2020>
- Torres Quintero, J. A., Arguello Fuentes, H., & Goyes Peñafiel, Y. P. (2024). *Aprendizaje supervisado y guiado por modelos generativos para la atenuación de ruido y corrección de daños estructurales en imágenes sísmicas post-apilado*. Universidad Industrial de Santander.
- Wu, X., Liang, L., Shi, Y., & Fomel, S. (2019). FaultSeg3D: Using synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *Geophysics*, 84(3), IM35–IM45. <https://doi.org/10.1190/geo2018-0646.1>
- Yajaira Herrera, & Norman Cooper. (2010). *Manual para la adquisición y procesamiento de sísmica terrestre y su aplicación en Colombia* .
- Yilmaz, Ö. (2001). *Seismic Data Analysis. Seismic Data Analysis*. <https://doi.org/10.1190/1.9781560801580>
- Yue, B., Peng, Z., He, Y., & Zhang, Q. (2013). Impulsive noise suppression using fast myriad filter in seismic signal processing. *Proceedings - 2013 International Conference on Computational and Information Sciences, ICCIS 2013*, 1001–1004. <https://doi.org/10.1109/ICCIS.2013.268>

- Zhang, Z., Liu, Q., & Wang, Y. (2017). *Road Extraction by Deep Residual U-Net*.
<https://doi.org/10.1109/LGRS.2018.2802944>
- Zhong, T., Li, Y., Wu, N., Nie, P., & Yang, B. (2015). A study on the stationarity and Gaussianity of the background noise in land-seismic prospecting. *GEOPHYSICS*, 80(4), V67–V82. <https://doi.org/10.1190/GEO2014-0153.1>
- Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., & Liang, J. (2018). *UNet++: A Nested U-Net Architecture for Medical Image Segmentation*. <http://arxiv.org/abs/1807.10165>
- Zou, Z., Rad, P. B., Macelloni, L., & Zhang, L. (2020). *Temporal and spatial variations in three-dimensional seismic oceanography*. <https://doi.org/10.5194/os-2020-112>

Apéndices

Apéndices A.

Atributos sísmicos en la interpretación de fallas geológicas.

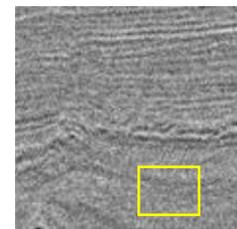


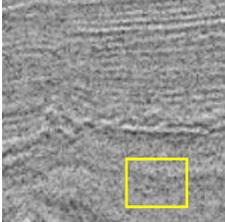
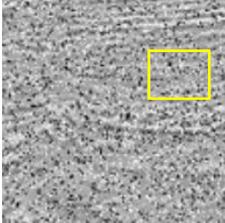
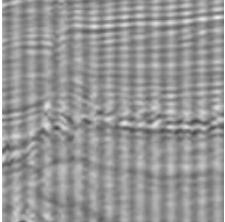
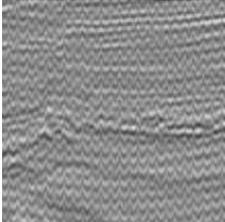
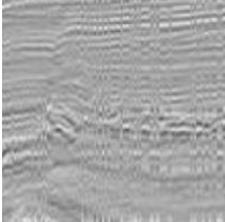
Nota. Flujo de trabajo convencional para la interpretación de fallas geológicas con atributos sísmicos. Modificado de Kim et al. (2021).

Apéndices B.

Ejemplos de tipos de ruidos que pueden presentarse en imágenes sísmicas.

Ruidos Aleatorios	
<p>Ruido Gaussiano (Blanco)</p>	<p>El ruido gaussiano afecta de manera aleatoria los píxeles de una imagen con valores uniformemente distribuidos. Su función de densidad de probabilidad $pq(x)$ viene dada en términos de la media (μ) y la varianza (σ^2) de una variable aleatoria “x”. Se expresa en la siguiente ecuación: $pq(x) = (2\pi\sigma^2)^{-1/2}e^{-(x-\mu)^2/2\sigma^2}$ (Rangel et al. 2017). La mayoría de los valores de píxel se generan de forma simétrica a la media, razón por la cual los valores muy claros u oscuros no son comunes.</p>

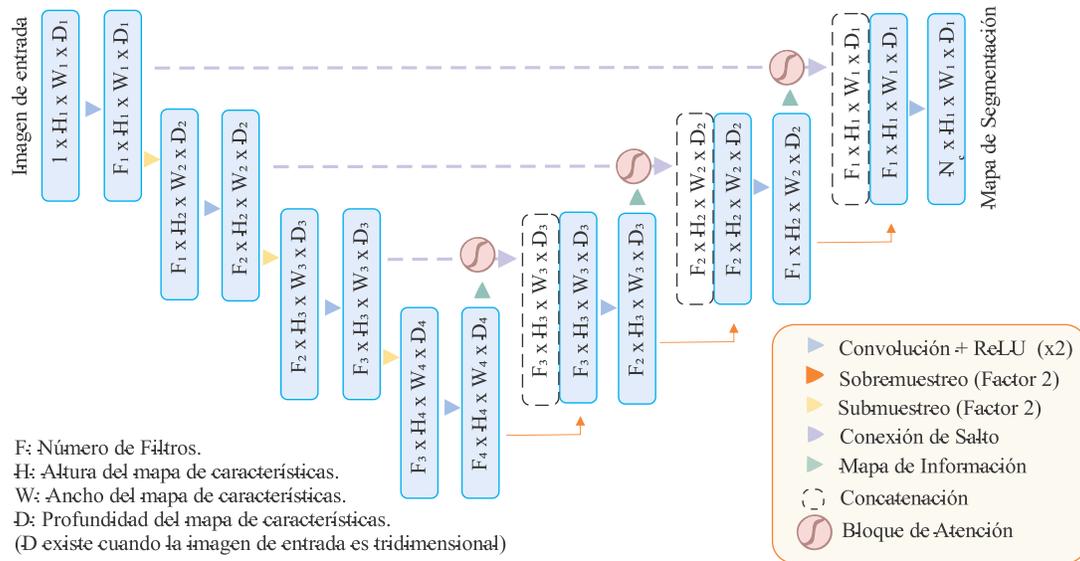


Ruido Poisson	<p>Este ruido puede ser generado mediante la ecuación de distribución de Poisson. Este ruido depende en las imágenes del valor de intensidad en cada píxel y es descrito con la siguiente ecuación: $P(x; \lambda) = \frac{\lambda^x e^{-\lambda}}{x!}$, donde “$\lambda$” representa el valor original de cada píxel, “e” es la función exponencial y “x” el número de ocurrencia del valor de ruido (Torres Quintero et al. 2024). De acuerdo con la distribución de Poisson este tiende a ser mayor cuando λ es pequeño razón por la cual se observan pixeles más oscuros en este tipo de ruido.</p>	
Sal y Pimienta	<p>El ruido sal y pimienta distribuye valores extremos de puntos brillantes y oscuros de manera aleatoria. El ruido en la imagen tiene solo dos valores, es decir, -255 (brillante) para el ruido de sal y 0 (oscuro) para el ruido de pimienta. Como resultado, la imagen parece estar salpicada de puntos oscuros y brillantes (Fogat et al. 2023). Este ruido se modela tomando un número de píxeles de manera aleatoria a los que se les reemplaza el valor por el mayor y menor valor de píxel según la escala de valores de la imagen.</p>	
Ruidos Coherentes		
Rayas (Stripes)	<p>Este ruido es aplicable a la imagen sísmica mediante una función definida en Python. Consiste en crear una matriz “Y” con datos variables en la dirección horizontal solamente, que luego es multiplicada por una función sinusoidal “s” dependiente de “Y” y la frecuencia de ocurrencia de las líneas “$frec$”, definida como $s = \text{sen}(frec * 2 * \pi * Y)$. Donde luego es multiplicada por un factor de intensidad y sumada a la imagen a afectar con el ruido (Torres Quintero et al., 2024).</p>	
Ondas/difracciones	<p>Este ruido en la realidad está relacionado a interferencias en forma de parábolas generadas por las refracciones de las ondas. De manera parecida a lo descrito en el ruido de rayas, se crea una malla bidimensional que es afectada por la ecuación $f(x) = \text{sen}(x + ay^2)$, donde “$a$” es el valor de amplitud (valor del píxel) con “x” y “y” como coordenadas en la malla. (Torres Quintero et al, 2024).</p>	
lineal	<p>Este ruido es inducido computacionalmente eligiendo el vector correspondiente a una columna aleatoria de la imagen. Este vector se repite varias veces de manera en posiciones aleatorias mediante un bucle, creando líneas verticales (Torres Quintero et al. 2024). El número de líneas es ajustable.</p>	

Nota. Esta tabla explica algunos de los tipos de ruido que pueden ser simulados computacionalmente. Modificado de Torres Quintero et al. (2024).

Apéndices C.

Red U-Net complementada con bloques de atención.

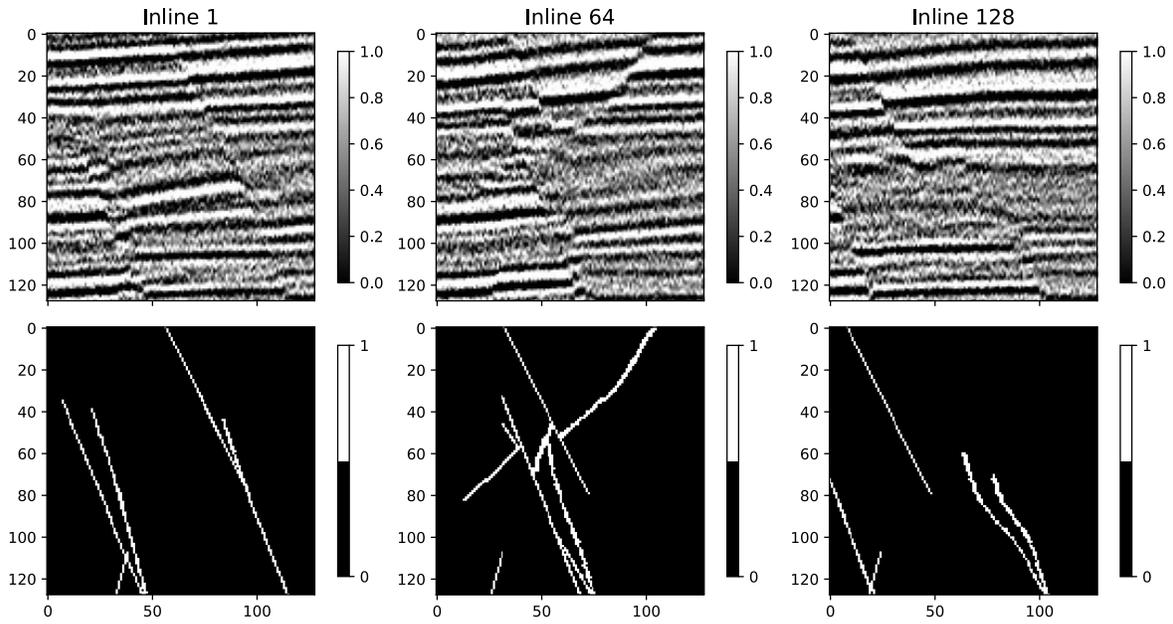


Nota. Arquitectura de red neuronal convolucional U-Net complementada con mecanismos de atención. Modificado de Oktay et al. (2018).

Apéndices D.

Ecuación de normalizado de las imágenes sísmicas en el rango de 0 a 1.

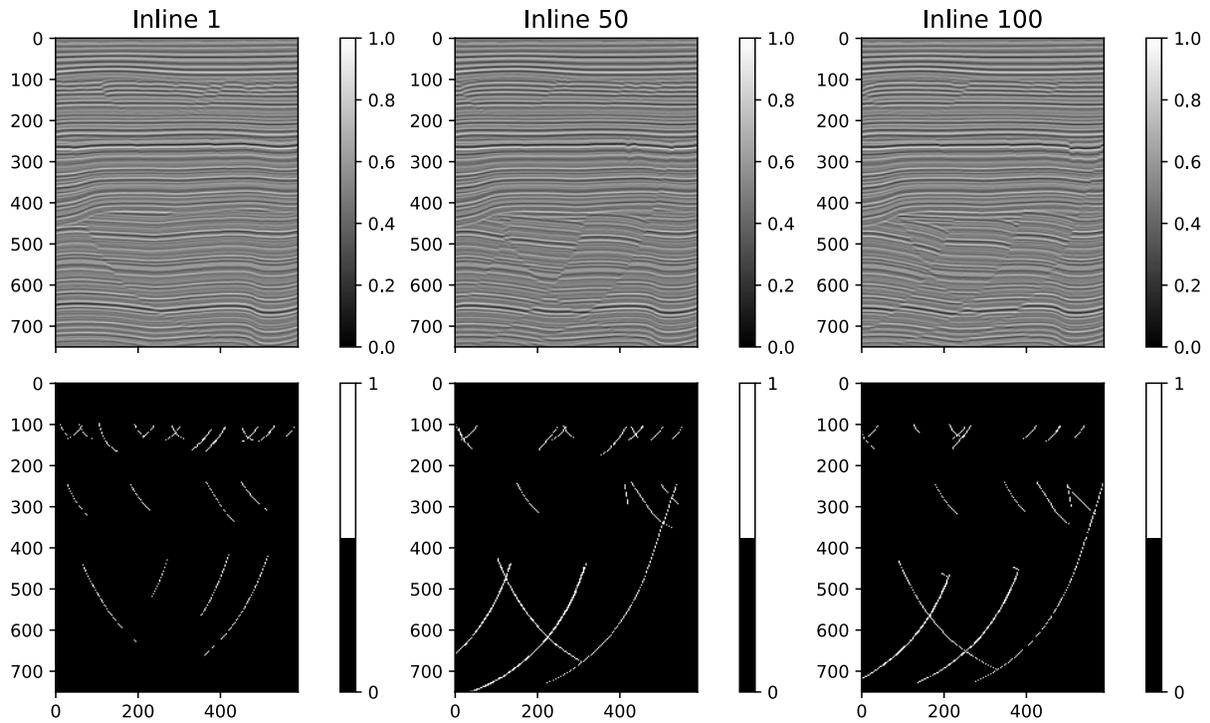
$$X_{Normalizado} = \frac{X - X_{Min}}{X_{Máx} - X_{Min}} \tag{5}$$

Apéndices E.*Imágenes sísmicas y máscaras binarias del conjunto de datos Sintético 1.*

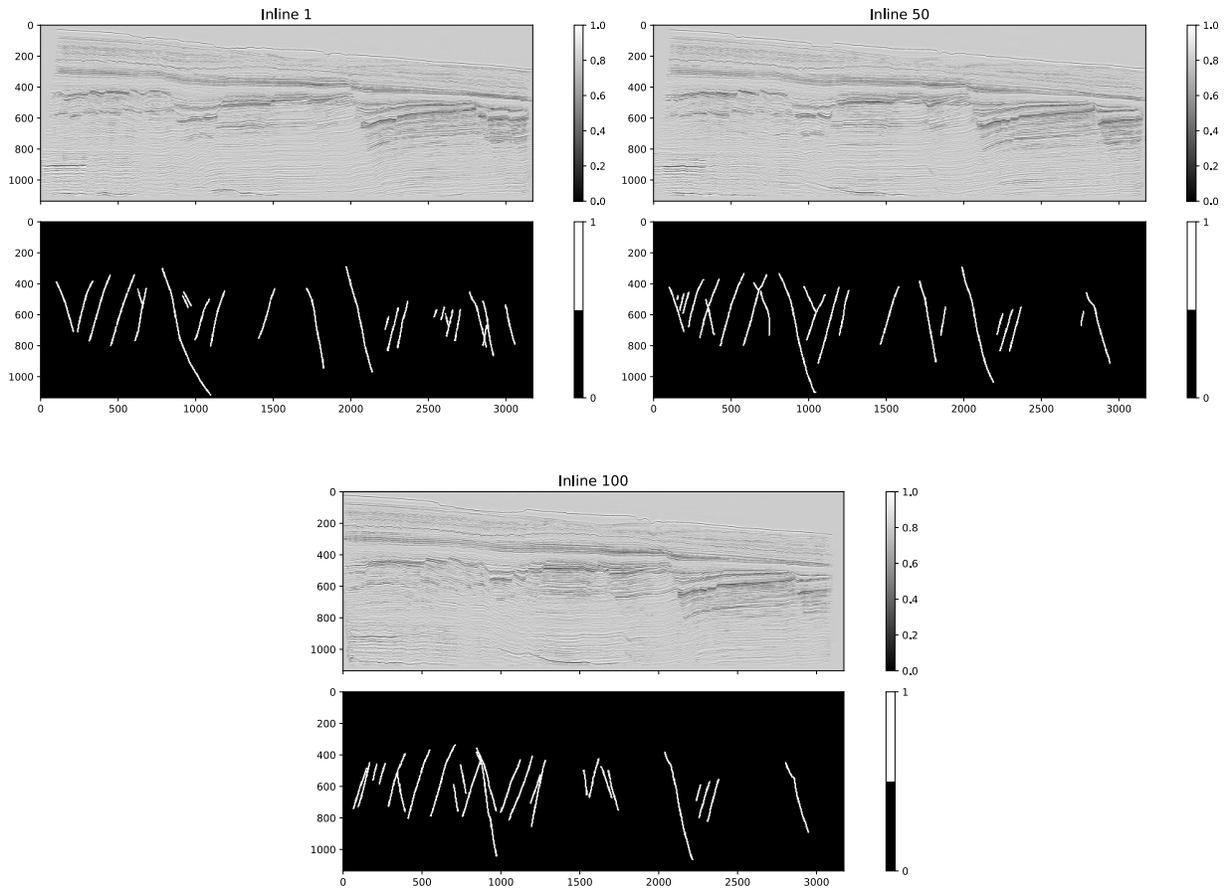
Nota. Se muestran 3 secciones de imágenes sísmicas y sus máscaras binarias con valores de 1 para la interpretación de fallas geológicas resaltadas en color blanco y valores de 0 donde no hay fallas, del conjunto de datos Sintético 1 y sus dimensiones en píxeles.

Apéndices F.

Imágenes sísmicas y máscaras binarias del conjunto de datos Sintético 2.



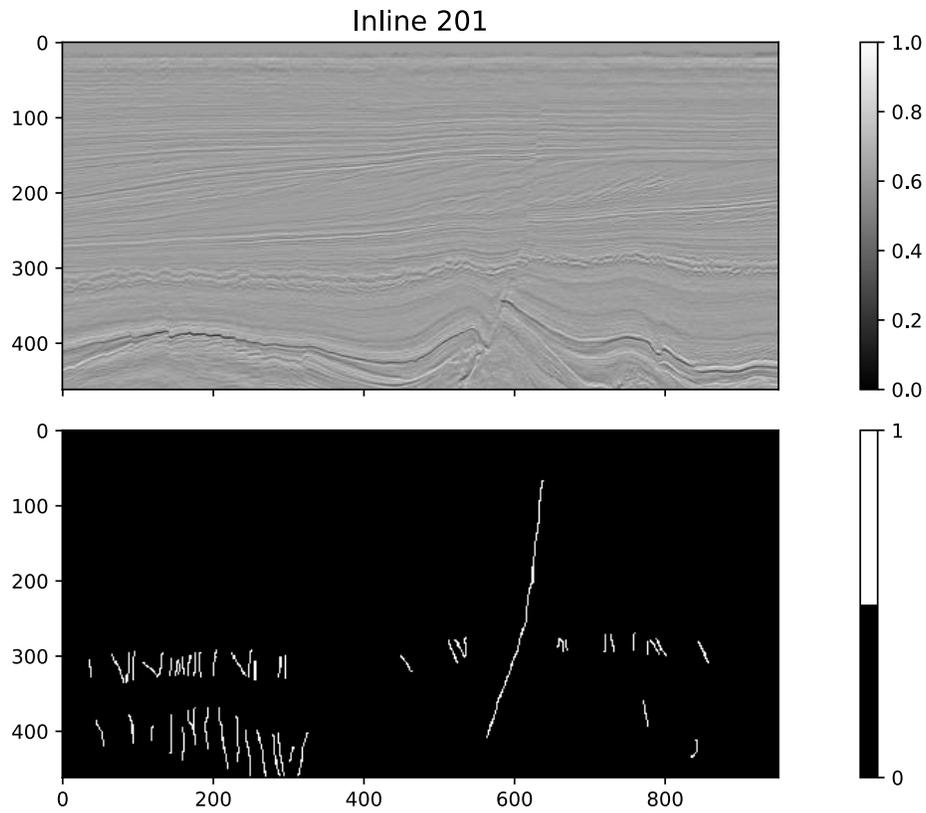
Nota. Se muestran 3 secciones de imágenes sísmicas y sus máscaras binarias con valores de 1 para la interpretación de fallas geológicas resaltadas en color blanco y valores de 0 donde no hay fallas, del conjunto de datos Sintético 2 y sus dimensiones en píxeles.

Apéndices G.*Imágenes sísmicas y máscaras binarias del conjunto de datos Real 1.*

Nota. Se muestran 3 secciones de imágenes sísmicas y sus máscaras binarias con valores de 1 para la interpretación de fallas geológicas resaltadas en color blanco y valores de 0 donde no hay fallas, del conjunto de datos Real 1 y sus dimensiones en píxeles.

Apéndices H.

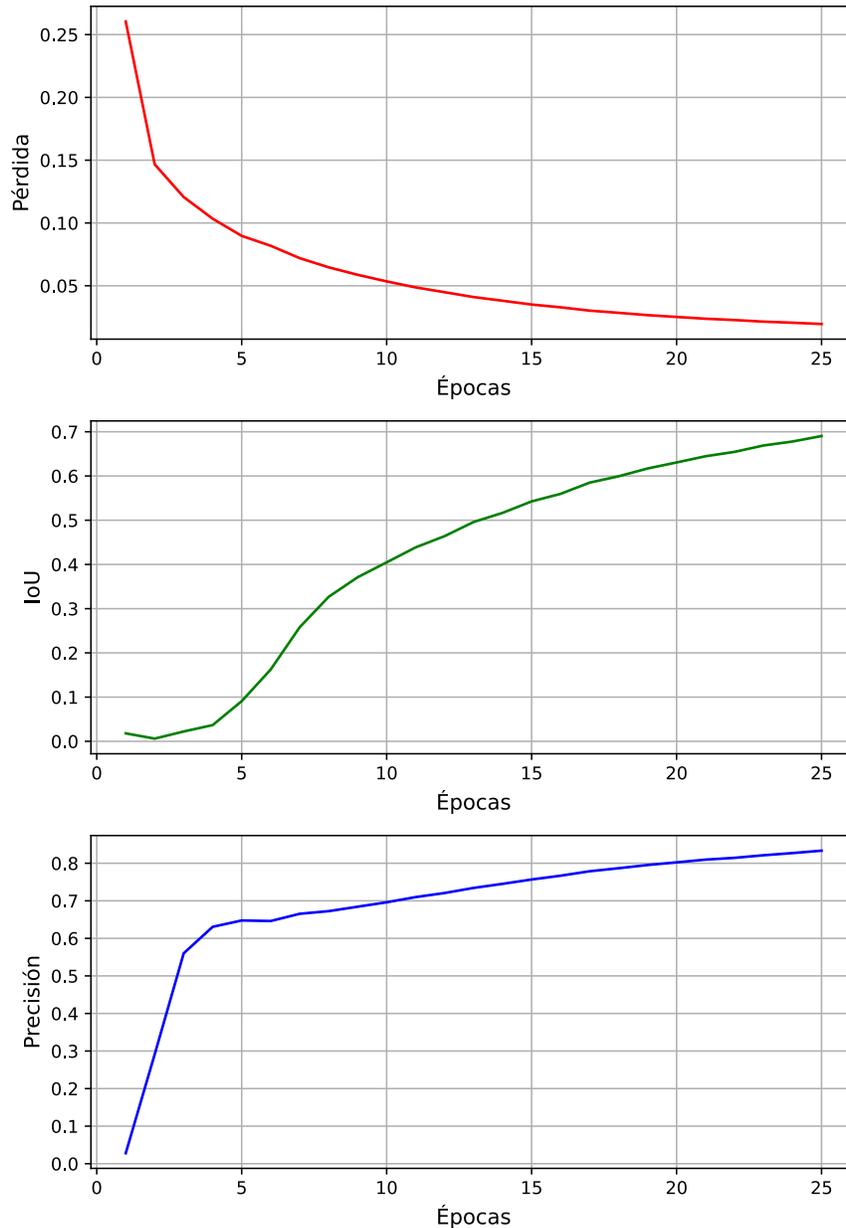
Inline 201 del conjunto Real 2 y su máscara binaria.



Nota. Se observa el inline 201 del conjunto Real 2 y su máscara binaria con valores de 1 para la interpretación de fallas geológicas resaltadas en color blanco y valores de 0 donde no hay fallas, además de sus dimensiones en píxeles.

Apéndices I.

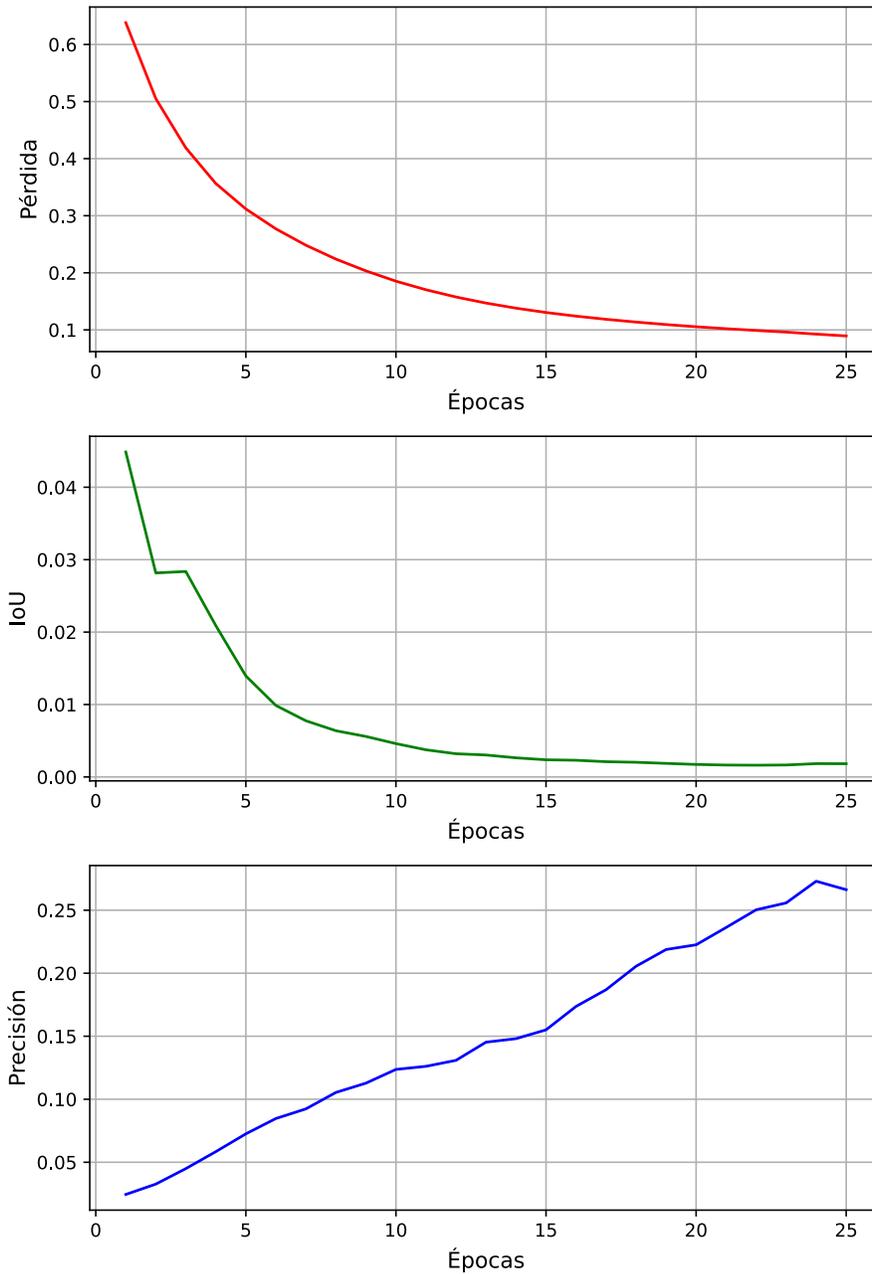
Gráficos de función de pérdida y métricas de precisión e Intersection over Union (IoU) durante el entrenamiento de la red Attention UNet.



Nota. Los gráficos representan la convergencia de la función de pérdida y el desempeño en las métricas de IoU y precisión durante el entrenamiento de la red neuronal U-Net con bloques de atención.

Apéndices J.

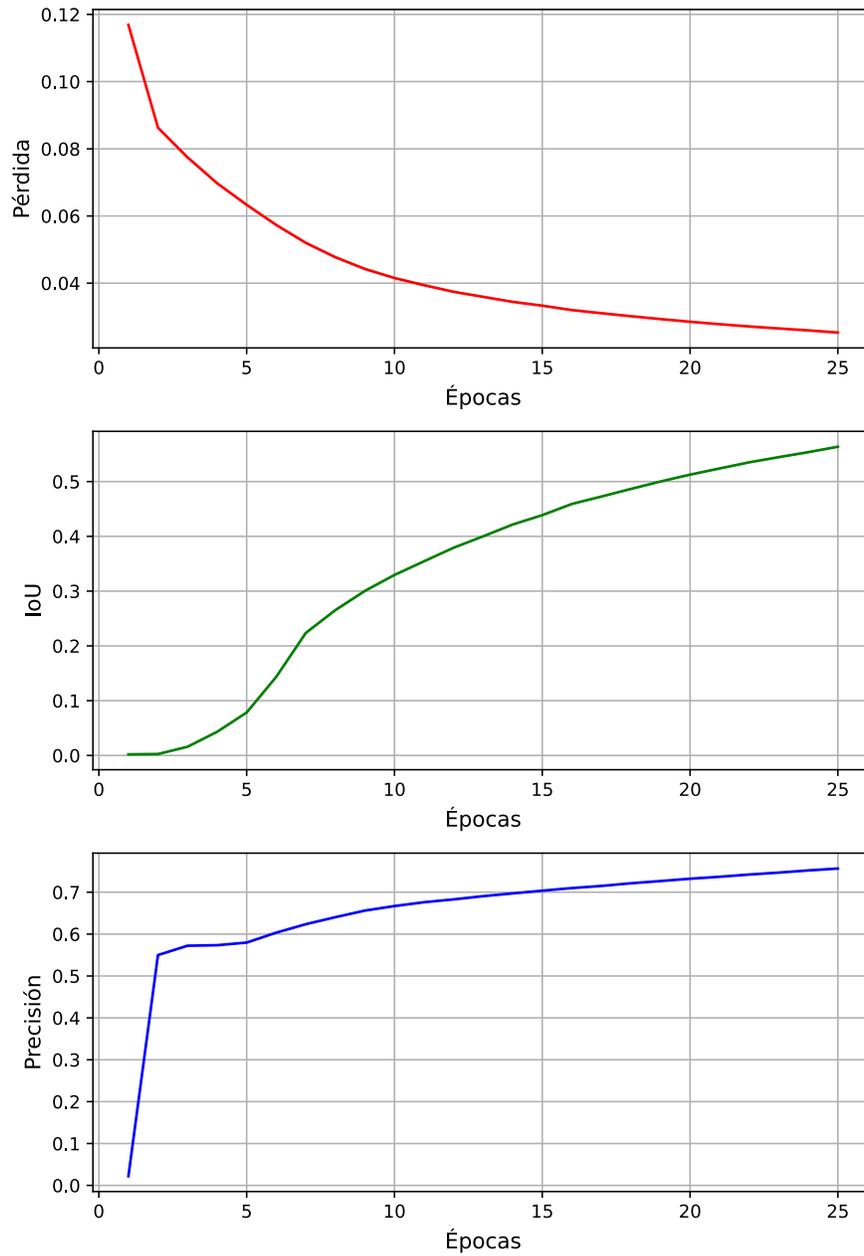
Gráficos de función de pérdida y métricas de precisión e intersección sobre unión (IoU) durante el entrenamiento de la red Inception U-Net.



Nota. Los gráficos representan la convergencia de la función de pérdida y el desempeño en las métricas de IoU y precisión durante el entrenamiento de la red neuronal Inception U-Net.

Apéndices K.

Gráficos de función de pérdida y métricas de precisión e Intersection over Union (IoU) durante el entrenamiento de la red U-Net++.



Nota. Los gráficos representan la convergencia de la función de pérdida y el desempeño en las métricas de IoU y precisión durante el entrenamiento de la red neuronal U-Net++.