

# ATENUACIÓN DE RUIDO EN IMÁGENES SÍSMICAS POST-APILADO 1

Aprendizaje supervisado y guiado por modelos generativos para la atenuación de ruido y corrección de daños estructurales en imágenes sísmicas post-apilado

Javier Andres Torres Quintero

Trabajo de Grado para Optar al Título de Ingeniero de sistemas

Director

Henry Arguello

PhD. en Ingeniería Eléctrica y Computación

Codirector

Paul Goyes Peñafiel

M.Sc. en Geofísica

Universidad Industrial de Santander

Facultad de Fisicomecánicas

Escuela de ingeniería de sistemas e informática

Ingeniería de sistemas

Bucaramanga

2024

**Dedicatoria**

*A mi padre y madre que siempre apoyaron mis decisiones y creyeron en mí.*

*A mi hermano que a pesar de mi ausencia me recibía con una sonrisa al volver a casa.*

*A mis amigos, los que me escucharon cuando tuve problemas.*

### **Agradecimientos**

*Este trabajo de grado fue realizado en el marco del proyecto No.3925. “Modelamiento matemático - computacional para el mejoramiento de imágenes sísmicas en cuencas emergentes colombianas utilizando aprendizaje profundo con adaptación de dominio”, financiado por la Vicerrectoría de Investigación y Extensión de la Universidad Industrial de Santander. El proyecto 3925 brindó el apoyo logístico para el uso de recursos computacionales, así como capacitación y asesoramiento.*

*Agradezco al director de grupo de investigación HDSP, Henry Arguello por permitirme elevar mi nivel de formación al ser parte del grupo.*

*A Paul Goyes, codirector de este trabajo, que me dio la oportunidad de formar parte del programa de investigación y por su guía en el desarrollo del proyecto.*

*A los compañeros de HDSP que me brindaron su ayuda, especialmente a Ana y Luis Miguel en quienes más me apoye durante la realización del proyecto.*

*A todas las personas, docentes, amigos, que de alguna manera contribuyeron a mi formación como estudiante y persona durante mi estadía en la universidad.*

**Tabla de Contenido**

	<b>Pág.</b>
Introducción .....	14
1. Objetivos.....	19
1.1 Objetivo General.....	19
1.2 Objetivos Específicos.....	19
2. Marco teórico .....	20
2.1 Imágenes sísmicas post-apilado .....	20
2.2 Atenuación de ruido sísmico.....	22
2.3 Aprendizaje profundo para el mejoramiento de imágenes sísmicas .....	24
2.3.1 Modelos generativos o de síntesis de imágenes.....	26
2.3.2 Red de atenuación de ruido .....	29
2.3.3 Transferencia de estilo ( <i>neural style transfer</i> ).....	30
3. Metodología .....	31
3.1 Fase 1: Construcción de un operador para generar la degradación de imágenes sísmicas .....	31
3.2 Fase 2: Desarrollo e implementación de un modelo de aprendizaje profundo para la generación de imágenes sísmicas post-apilado .....	32
3.3 Fase 3: Implementación y desarrollo de un esquema de atenuación de ruido mediante aprendizaje supervisado y guiado por modelos generativos.....	33
3.4 Fase 4: Evaluación de la eficiencia del esquema de atenuación de ruido sísmico en escenarios de imágenes sísmicas reales y sintéticas .....	34
4. Resultados .....	35
4.1 Operador de degradación de imágenes sísmicas.....	35

## ATENUACIÓN DE RUIDO EN IMÁGENES SÍSMICAS POST-APILADO 5

4.1.1 <i>Datasets de imágenes sísmicas</i> .....	35
4.1.1.1 Imágenes sísmicas post-apilado reales.....	36
4.1.1.2 Imágenes sísmicas post-apilado sintéticas..	37
4.1.2 <i>Métodos de degradación</i> .....	38
4.1.2.1 Procesamiento de imágenes. ....	39
A. Ruido aleatorio.....	39
B. Ruido no aleatorio. ....	41
4.1.2.2 Transferencia de estilo ( <i>Neural style transfer</i> ). ....	50
4.2 Modelo de aprendizaje profundo para la generación de imágenes sísmicas post-apilado.....	52
4.2.1 <i>Comparación de modelos</i> .....	52
4.2.1.1 Definición matemática del modelo. ....	54
4.2.1.2 Implementación de PGGAN.....	56
4.3 Esquema de atenuación de ruido mediante aprendizaje supervisado y guiado por modelos generativos .....	57
4.3.1 <i>Selección del modelo de atenuación</i> .....	57
4.3.1.1 Definición matemática del modelo. ....	58
4.3.2 <i>Esquema de atenuación de ruido</i> .....	58
4.3.2.1 Esquema de atenuación de ruido adaptable. ....	61
4.4 Evaluación del modelo.....	61
4.4.1 <i>Métricas del esquema de atenuación de ruido</i> .....	61
5.4.2 <i>Pruebas en datos reales y sintéticos</i> . ....	62
4.4.3 <i>Comparación del esquema propuesto con otros métodos del estado del arte</i> .....	67
6. Conclusiones.....	76

## ATENUACIÓN DE RUIDO EN IMÁGENES SÍSMICAS POST-APILADO 6

7. Recomendaciones .....	78
Referencias Bibliográficas .....	79
Apéndices.....	83

**Lista de Tablas**

	Pág.
Tabla 1 <i>Métodos de atenuación de ruido sísmico</i> .....	22
Tabla 2 <i>Imágenes reales resultantes y tamaño del archivo</i> .....	36
Tabla 3 <i>Imágenes sintéticas resultantes y tamaño del archivo</i> .....	38
Tabla 4 <i>Kernels de ruido correlacionado</i> .....	46
Tabla 5 <i>Variaciones y combinaciones de ruido correlacionado</i> .....	46
Tabla 6 <i>Síntesis de imágenes, duración por cantidad de muestras</i> .....	52
Tabla 7 <i>Métricas PSNR y SSIM de la atenuación de los 16 tipos de ruido</i> .....	62
Tabla 8 <i>Comparación de métodos Gaussiano</i> . .....	67
Tabla 9 <i>Comparación de métodos Poisson</i> .....	68
Tabla 10 <i>Tabla de comparación de métodos salt and pepper</i> . .....	68
Tabla 11 <i>Comparación de métodos speckle</i> .....	68
Tabla 12 <i>Comparación de métodos Lineal</i> . .....	69
Tabla 13 <i>Comparación de métodos Lineal v2</i> . .....	69
Tabla 14 <i>Comparación de métodos stripes</i> .....	70
Tabla 15 <i>Comparación de métodos Ondas/difracción</i> . .....	70
Tabla 16 <i>Comparación de métodos Ondas/difracción v2</i> .....	70
Tabla 17 <i>Comparación de métodos Correlacionado Blur</i> .....	71
Tabla 18 <i>Comparación de métodos Correlacionado g1</i> .....	71
Tabla 19 <i>Comparación de métodos Correlacionado g2</i> .....	71
Tabla 20 <i>Comparación de métodos g1vi</i> . .....	72

## ATENUACIÓN DE RUIDO EN IMÁGENES SÍSMICAS POST-APILADO 8

Tabla 21 <i>Comparación de métodos Correlacionado glv.</i> .....	72
Tabla 22 <i>Comparación de métodos SI.</i> .....	73
Tabla 23 <i>Comparación de métodos SI blur.</i> .....	73
Tabla 24 <i>Comparación de estimación rápida de la varianza del ruido</i> .....	75

**Lista de Figuras**

	Pág.
Figura 1 <i>Imágenes sísmicas post-apilado de 101×101 píxeles (imágenes tomadas de Kaggle Inc. (2018))</i> .....	20
Figura 2 <i>Imágenes sísmicas post-apilado ruidosas, (imágenes tomadas de Kaggle Inc. (2018) y Data Info of F3 Demo 2020 (<a href="https://terranubis.com/datainfo/F3-Demo-2020">https://terranubis.com/datainfo/F3-Demo-2020</a>))</i> .....	21
Figura 3 <i>Modelo directo (forward problem en inglés) con un operador de ruido P (Imágenes tomadas de Peng et al., 2023)</i> .....	24
Figura 4 <i>Esquema del modelo generativo GAN (Imagen tomada de Dash et al., 2021)</i> .....	26
Figura 5 <i>Trilema generativo (Imagen tomada de Xiao et al.,2022)</i> .....	28
Figura 6 <i>Arquitectura Attention U-net (adaptado de Oktay et al., 2018)</i> .....	29
Figura 7 <i>Transferencia de estilo (Imagen tomada de Gatys et al., 2015)</i> .....	30
Figura 8 <i>Transferencia de estilo en imágenes sísmicas (Imagen tomada de Du et al., 2022)</i> ....	30
Figura 9 <i>Ejemplo de imagen descartada y aceptada del dataset Blake ridge 3D</i> .....	36
Figura 10 <i>Ejemplos de imágenes de los datasets usados</i> .....	37
Figura 11 <i>Ejemplos de imágenes de los datasets sintéticos usados</i> .....	38
Figura 12 <i>Imágenes sísmicas post-apilado contaminadas con ruido aleatorio.</i> .....	39
Figura 13 <i>Ejemplo de líneas presentes en imágenes sísmicas</i> .....	41
Figura 14 <i>Imágenes sísmicas con poca nitidez</i> .....	43
Figura 15 <i>Daño vertical en imágenes sísmicas reales</i> .....	45
Figura 16 <i>Daños aplicados a una imagen sísmica sintética variando su intensidad</i> .....	47
Figura 17 <i>Daños aplicados a una imagen sísmica sintética variando su intensidad</i> .....	48

## ATENUACIÓN DE RUIDO EN IMÁGENES SÍSMICAS POST-APILADO 10

Figura 18 <i>Ejemplo de evento sísmico de gran y baja escala</i> .....	49
Figura 19 <i>Transferencia de estilo aplicada en imágenes sísmicas</i> .....	51
Figura 20 <i>Resultados: generación de imágenes por modelo</i> .....	53
Figura 21 <i>Esquema de entrenamiento PGGAN (Karras et al., 2017)</i> .....	54
Figura 22 <i>Imágenes aleatorias generadas tras la primera etapa de entrenamiento y el fine-tuning</i> .....	57
Figura 23 <i>Esquema de atenuación de ruido</i> .....	59
Figura 24 <i>Modelo evaluado en datos reales y sintéticos en imágenes de <math>128 \times 128</math> píxeles</i> .....	63
Figura 25 <i>Adaptación de dominio del patrón de ruido sísmico en parches <math>128 \times 128</math> píxeles de Kerry 3D</i> .....	64
Figura 26 <i>Atenuación de ruido en sísmica completa Alaska 2D</i> .....	65
Figura 27 <i>Sección de la atenuación resultante en Alaska 2D</i> .....	65
Figura 28 <i>Atenuación de ruido en sísmica completa de campo</i> .....	66
Figura 29 <i>Sección de la atenuación resultante en sección sísmica real</i> .....	66
Figura 30 <i>Comparación de métodos en aplicaciones reales Alaska 2D</i> .....	74
Figura 31 <i>Comparación de métodos en aplicaciones reales sección sísmica de campo</i> .....	74

**Lista de Apéndices**

**pág.**

Apéndice A. Enlace del repositorio de GitHub donde se aloja el código del proyecto..... 83

## Resumen

**Título:** Aprendizaje supervisado y guiado por modelos generativos para la atenuación de ruido y corrección de daños estructurales en imágenes sísmicas post-apilado\*

**Autor:** Javier Andres Torres Quintero \*\*

**Palabras Clave:** Atenuación de ruido de ruido, modelo generativo, imágenes sísmicas post-apilado, aprendizaje supervisado y guiado.

La adquisición de datos fiables del subsuelo es fundamental para la toma de decisiones en la exploración de materias primas como hidrocarburos, geotermia, depósitos minerales, y otros. Estos datos se usan para construir representaciones gráficas de las estructuras del subsuelo conocidas como imágenes sísmicas, mediante las que se pueden realizar interpretaciones y determinar áreas atractivas para la exploración. Debido a la naturaleza de la adquisición, las imágenes se ven afectadas por ruido o daños estructurales, lo cual disminuye su calidad, aumentando la dificultad de la interpretación sísmica. Estos daños han sido clasificados en dos tipos: aleatorio, relacionado con variables ambientales como el viento que no afectan directamente la señal; y coherente, que se relaciona con las fuentes de adquisición y afecta la señal directamente. Existen métodos que buscan solucionar este problema, por ejemplo, algunos enfoques tradicionales basados en el filtro de mediana o filtro pasa banda, y otros basados en aprendizaje profundo. Los métodos de la literatura requieren que el ruido siga una distribución específica como la gaussiana o Poisson que no representan la complejidad del ruido sísmico. Por otro lado, los basados en aprendizaje profundo suelen enfocarse en daños ya caracterizados como el *ground roll*, y aunque son eficientes en la tarea, si la imagen es distante del dominio usado para el entrenamiento, el rendimiento se ve reducido, afectando la capacidad de generalización. Por lo tanto, en este trabajo se presenta un esquema de atenuación que no depende de distribuciones específicas de ruido y añade variabilidad al dominio de entrenamiento aumentando la capacidad de generalización mediante aprendizaje supervisado y guiado por modelos generativos. El método consiste en una base de datos dinámica compuesta por un modelo generativo y un operador de degradación, que guía el entrenamiento de una red (*attention U-net*) encargada de la tarea de atenuación mediante la creación de los datos de entrada y las etiquetas, además, para los casos en que la red no puede atenuar satisfactoriamente, el operador puede adaptar el dominio de nuevo ruido a través de transferencia de estilo.

---

\* Trabajo de Grado

\*\* Facultad de Físicomecánicas. Escuela de ingeniería de sistemas e informática. Ingeniería de sistemas. Director: Henry Arguello. PhD. en Ingeniería Eléctrica y Computación. Codirector: Paul Goyes Peñafiel. M.Sc. en Geofísica

**Abstract**

**Title:** Guided and supervised learning by generative models in a seismic denoising scheme for post-stack seismic data \*

**Author(s):** Javier Andres Torres Quintero\*\*

**Key Words:** Seismic denoising, generative model, post-stack seismic images, guided and supervised learning.

Reliable seismic data acquisition is a task of major relevance for subsurface exploration. This data is processed to obtain post-stack seismic images, which geologists can interpret to identify promising areas for the exploration of mineral deposits, hydrocarbons, and geothermal resources. However, due to acquisition conditions, the data may be corrupted by noise, leading to less accurate interpretations. Seismic noise has been classified in two types, non-signal-dependent (random noise) and signal-dependent (coherent noise). To attenuate these types of seismic noise, multiple methods have been developed for example, traditional methods such as median and band-pass filtering and the state-of-the-art techniques that implement deep learning-based solutions. Nonetheless, the traditional methods assume specific noise distributions, such as Gaussian, Poisson or impulse, which are not representative of the complexity of seismic noise. On the other hand, Deep learning approaches are also often focused on the already characterized seismic noises like ground roll, even though they have proven to be successful in noise attenuation, their performance can decrease if the test data significantly deviates from the training domain, resulting in poor generalization. This work presents a scheme for seismic denoising that can learn new noisy patterns by adapting the domain from field noisy data, through guided and supervised learning by generative models. The scheme works by synthesizing clean post-stack images that in conjunction with a degradation operator, initially composed of 16 noise types as is shown in section 5.1, make a dynamic database used to train an attention U-net for data denoising. The proposed approach improves generalization by adding variability to the training data, ensuring the method is non-dependent on specific distributions. Experimental results with synthetic and field data have proven that the proposed method successfully attenuates complex noise patterns in post-stack seismic images.

---

\* Degree Work

\*\* Faculty of Physical Mechanics. School of Systems and Computer Engineering. Systems Engineering. Adviso: Henry Arguello, PhD in Electrical and Computer Engineering. Co-advisor: Paul Goyes Peñafiel, M.Sc. in Geophysics.

## Introducción

Las imágenes sísmicas post-apilado son representaciones gráficas de las estructuras presentes en el subsuelo que debido a la naturaleza ruidosa de adquisición están contaminadas por ruido, clasificado en dos tipos: Coherente dependiente de la señal y aleatorio independiente de la señal. Para solucionar el problema de la contaminación son sometidas a un flujo de trabajo conocido como “mejoramiento de datos sísmicos”. El mejoramiento de datos sísmicos constituye una tarea relevante en la exploración de recursos energéticos (hidrocarburos, geotermia, hidrógeno natural, depósitos minerales, entre otros (K. Gao et al., 2020; Malehmir et al., 2021), puesto que, impacta directamente en la etapa de interpretación sísmica. El mejoramiento puede abordarse desde tres enfoques: La atenuación de ruido en imágenes sísmicas pre-apiladas, la atenuación de ruido en imágenes sísmicas post-apilado, y la detección y remoción de eventos de difracción según Petroleum Geo-Services (PGS, s.f). De manera que, el aumento de la calidad de las imágenes sísmicas permite identificar con menor incertidumbre las estructuras geológicas y las características del subsuelo (Al-Heety & Thabit, 2022), lo cual provee información relevante para la determinación de áreas atractivas en la exploración de recursos energéticos (Fogat et al., 2023). Durante la etapa de adquisición, la señal captada por los receptores en superficie contiene ruido procedente de las actividades antropogénicas o defectos del sensor, por lo que luego del procesamiento de dicha señal se obtiene una imagen sísmica post-apilado con daños o artefactos. Esto aumenta sustancialmente el riesgo de una interpretación geológica errónea del experto encargado, lo que podría ocasionar que se descarte una zona de gran potencial energético o que, en caso agravado, se tome la decisión de explorar un área con nulo potencial energético,

provocando la pérdida de millones de dólares en la perforación de pozos (en el primer semestre de 2021, la empresa Ecopetrol destinó 48 millones de dólares en exploración (Ecopetrol, 2021))

Por consiguiente, desde las ciencias de la computación se ha abordado el problema de atenuación de ruido mediante la reconstrucción de datos, que ha ayudado a desarrollar técnicas computacionales que involucran filtrado, procesamiento de imágenes y procesamiento de señales. Para aplicar los métodos mencionados, en el estado del arte se han analizado los tipos de ruido que afectan a las imágenes sísmicas y se han propuesto algoritmos de atenuación más robustos. Según Al-Heety & Thabit. (2022), entre las técnicas tradicionales más comunes se encuentran el *median filtering*, usado para atenuar ruido distribuido aleatoriamente, y el *band-pass filtering*, que se enfoca en tratar el ruido relacionado a la señal mediante filtrado de frecuencias para obtener mayor nitidez en los datos. Estos métodos de atenuación no consideran patrones de ruido y daños estructurales más específicos relacionados con las imágenes sísmicas (como *stripes* blancos observables en conjuntos de datos de libre acceso como F3 Demo 2020, USGS Central Alaska, USGS Beaufort Sea - Artic Alaska encontrados en TerraNubis) (University of British Columbia, s.f; OpendTect, s.f; Al-Heety & Thabit, 2022)), lo que representa su principal falencia en el mejoramiento de las imágenes sísmicas.

Dadas las desventajas que poseen los métodos tradicionales usados para la atenuación de ruido (*median filtering* y *band-pass filtering*), se han desarrollado otras técnicas basadas en aprendizaje profundo (del inglés Deep learning) (Al-Heety & Thabit, 2022; Fogat et al., 2023; Gan et al., 2015; Wu et al., 2022) que permiten capturar una gran cantidad de características y obtener un mejor rendimiento comparado con los métodos convencionales. Específicamente, la eficacia del aprendizaje profundo en este campo se debe a la capacidad que tienen las redes neuronales convolucionales para extraer características y patrones, lo cual ha permitido su uso en diferentes

tareas como reconstrucción de datos sísmicos faltantes (Goyes-Penafiel et al., 2023), inversión sísmica (Gelboim et al., 2023) y atenuación de ruido (K. Zhang et al., 2016).

Por lo anterior, ha surgido una tendencia en la implementación de redes neuronales convolucionales para el mejoramiento de imágenes sísmicas post-apilado (Du et al., 2022; Peng et al., 2023; Wei et al., 2023). Estos métodos corresponden a técnicas de aprendizaje supervisado y, por lo tanto, requieren la imagen sísmica ruidosa y su equivalente etiqueta (imagen limpia) durante el entrenamiento. Para generar las imágenes degradadas, las imágenes sintéticas post-apilado limpias son contaminadas usando modelos matemáticos (operador), los cuales agregan diferentes tipos y niveles de ruido, como el gaussiano, Poisson, etc. (Fogat et al., 2023), con el objetivo de simular los tipos de daño que se pueden presentar en las imágenes sísmicas. A pesar de que, se obtienen mejores resultados utilizando estas estrategias con respecto a los métodos tradicionales, los daños se siguen modelando de acuerdo con las mismas representaciones matemáticas (Al-Heety & Thabit, 2022; Fogat et al., 2023). Actualmente, en el área de aprendizaje profundo también existen operadores más complejos para la degradación de imágenes sintéticas, los cuales consisten en métodos de adaptación de dominio haciendo uso de la técnica transferencia de estilo (del inglés Neural style transfer) que consiste en adaptar características de una imagen a otra, mientras se conserva la estructura de la imagen original (Du et al., 2022).

La forma tradicional de crear conjuntos de datos de imágenes limpias consiste en métodos matemáticos, como sismogramas sintéticos y ondículas (Chopra y Sharma, 2016). Sin embargo, debido a la necesidad que poseen las redes neuronales convolucionales de una elevada cantidad y variedad de muestras en la etapa de entrenamiento, es posible que los datos generados con los métodos tradicionales no cuenten con un volumen apropiado de información, lo que representa una desventaja en el entrenamiento, puesto que, el conjunto de datos usado de imágenes sintéticas

es estático (siempre se trabaja con las mismas imágenes), lo que puede reducir el rendimiento del método al ser probado con estructuras sísmicas que no estuvieran contempladas en el dominio de los datos de entrenamiento. (Du et al., 2022). Así que, para resolver el problema de la falta de datos sísmicos, en el campo de la síntesis de imágenes se han desarrollado técnicas de aumento de datos que emplean redes neuronales, como los modelos generativos (Mansimov et al., 2015). Estos métodos se enfocan en la producción de imágenes de acuerdo con el conjunto de datos con el que sean entrenados (Voetman et al., 2023), y han demostrado su utilidad para generar imágenes sísmicas sintéticas (Durall et al., 2022; Goyes-Penafiel et al., 2023).

En definitiva, el uso de métodos de atenuación basados en aprendizaje profundo, que comúnmente utilizan la arquitectura u-net (Fogat et al., 2023; Mandelli et al., 2019), tienen la capacidad de aprender las características de estos tipos de ruido y ofrecer una solución general de atenuación, para lo cual requieren conjuntos de datos con imágenes degradadas y etiquetas (imágenes limpias). De este modo, se aprovechó la oportunidad de aportar al mejoramiento de imágenes sísmicas al explorar soluciones alternativas más generalizables, por esto en este proyecto de grado se propuso el desarrollo de un esquema de atenuación de ruido y corrección de daños estructurales en imágenes sísmicas post-apilado usando aprendizaje supervisado y guiado por modelos generativos. El esquema consta de dos componentes: el primero es una base de datos dinámica que está constituida por un modelo generativo encargado de sintetizar imágenes sísmicas post-apilado limpias y un operador de degradación compuesto por 16 tipos de ruido base, que contamina cada imagen múltiples veces, consiguiendo aumento de los datos y por ende el dominio de entrenamiento. El segundo es la red encargada de la tarea de atenuación de ruido, en este proyecto se optó por una *attention U-net*, por la capacidad que tiene de aprender a estimar información relevante de las imágenes. En la tarea de atenuación, el entrenamiento de la red es

guiado por la base de datos sintética, aprendiendo a remover patrones de ruido y daños estructurales. Además, una vez en la etapa de inferencia, si una imagen de campo cuenta patrones de ruido no contemplados en el dominio de entrenamiento original, el método cuenta con la posibilidad de refinar la red mediante la adaptación del dominio de ese nuevo tipo de daño mediante transferencia de estilo, proceso que está contemplado en el operador de degradación y puede activarse el caso mencionado. Por lo tanto, el método es independiente a distribuciones específicas y adaptable a nuevos escenarios ruidosos, lo que aumenta la capacidad de generalización del problema,

## **1. Objetivos**

### **1.1 Objetivo General**

Desarrollar un algoritmo de aprendizaje supervisado y guiado por modelos generativos para la atenuación de ruido y corrección de daños estructurales en imágenes sísmicas post-apilado.

### **1.2 Objetivos Específicos**

1. Construir un operador para generar la degradación de imágenes sísmicas.
2. Desarrollar e implementar un modelo de aprendizaje profundo para la generación de imágenes sísmicas post-apilado.
3. Establecer un esquema de aprendizaje supervisado y guiado por modelos generativos para el entrenamiento de una red convolucional para el mejoramiento de imágenes sísmicas.
4. Evaluar la eficiencia del esquema de atenuación de ruido sísmico en escenarios de imágenes sísmicas obtenidas a partir de conjuntos de datos de campo y sintéticos.


## 2. Marco teórico

### 2.1 Imágenes sísmicas post-apilado

Las imágenes sísmicas post-apilado son una representación gráfica de las estructuras del subsuelo que pueden aportar información sobre la ubicación y extensión de capas sedimentarias, pliegues, desplazamiento de fallas geológicas, domos de sal, entre otras, que aportan información sobre los cuerpos de interés económico. (Du et al., 2022). En la Figura 1, se observan parches de imágenes sísmicas limpias, donde hay continuidad y claridad de las estructuras. Dicha representación es producto del procesamiento sísmico.

#### Figura 1


*Imágenes sísmicas post-apilado de 101×101 píxeles (imágenes tomadas de Kaggle Inc. (2018))*



No obstante, durante el proceso mencionado existen etapas que pueden introducir y/o acumular artefactos en la señal. Adicionalmente, los problemas durante la adquisición también afectan el procesamiento, estas circunstancias pueden ser ambientales o causadas por los instrumentos usados en la toma de datos (Al-Heety & Thabit, 2022; Fogat et al., 2023). Todo esto contribuye a que las imágenes sísmicas post-apilado tengan ruido y/o daños que afectan la calidad de la información (ver Figura 2). Según Fogat et al. (2023), los ruidos se han clasificado en dos tipos: aleatorio y coherente; el ruido aleatorio hace referencia a que el ruido no está directamente relacionado con la señal, es ocasionado por condiciones ambientales y no existen patrones predecibles, mientras que el ruido coherente implica patrones discernibles y fuentes específicas como la migración de artefactos o condiciones sísmicas como terremotos, lo que conlleva a una fuerte relación entre el ruido y la señal.

### **Figura 2**

*Imágenes sísmicas post-apilado ruidosas, (imágenes tomadas de Kaggle Inc. (2018) y Data Info of F3 Demo 2020 (<https://terrannubis.com/datainfo/F3-Demo-2020>))*



El estudio del ruido presente en las imágenes sísmicas para su mejoramiento ha desembocado en un campo de acción conocido como “atenuación de ruido sísmico”, en el que se

realizan esfuerzos constantes por encontrar soluciones para la remoción del ruido de las imágenes sísmicas post-apilado.

## 2.2 Atenuación de ruido sísmico

La atenuación de ruido sísmico aplicada a las imágenes sísmicas post-apilado consiste en aumentar la calidad de la información (Al-Heety & Thabit, 2022). Debido a la importancia de este tipo de imágenes sísmicas en la exploración de subsuelo, se han planteado diversos métodos para mejorarlas, como los mostrados en la Tabla 1.

**Tabla 1**

*Métodos de atenuación de ruido sísmico*

Método	Ventajas	Desventajas	Autor
<i>Dip-Steered median filter</i>	Atenuación de ruido aleatoriamente distribuido, y suavizado de datos sísmicos.	Solo es efectivo para el ruido aleatorio. Otros tipos de patrones de ruido o daños estructurales son omitidos.	OpendTect, s.f
<i>Band-pass filtering</i>	Atenuación de ruido coherente mediante el filtrado de frecuencias altas y bajas en la señal.	Aplicar este filtro puede comprometer significativamente la señal original.	University of British Columbia, s.f

ATENUACIÓN DE RUIDO EN IMÁGENES SÍSMICAS POST-APILADO 23

<p><i>Coherent noise removal with residual network</i></p>	<p>Atenuación de ruido coherente y conservación de la amplitud de los reflectores.</p>	<p>El uso de datos altamente ruidosos en el entrenamiento puede causar que la red clasifique los reflectores como ruido. En el caso contrario datos con un porcentaje muy bajo de ruido puede resultar en que la red no aprenda el <i>feature</i> del ruido coherente.</p>	<p>Ma et al., 2023</p>
<p><i>Denoising of seismic data with U-net</i></p>	<p>Puede restaurar datos corruptos con ruido aleatoriamente distribuido.</p>	<p>No están considerados otros tipos de ruido o daños estructurales presentes en los datos sísmicos.</p>	<p>Mandelli et al., 2019</p>
<p><i>Noise reduction and style transfer</i></p>	<p>Aprendizaje de patrones de ruido y daños estructurales específicos de muestras reales.</p>	<p>Rendimiento condicionado por la cantidad y diversidad de muestras usadas en el entrenamiento. Además, puede sobre corregir señales inestables o borrosas.</p>	<p>Du et al., 2022</p>

Estos métodos han probado ser funcionales para realizar la tarea en las imágenes sísmicas post-apilado. Sin embargo, se evidencia que muchas de las soluciones propuestas abarcan el ruido de manera generalizada, omitiendo patrones de ruido y daños estructurales específicos observables

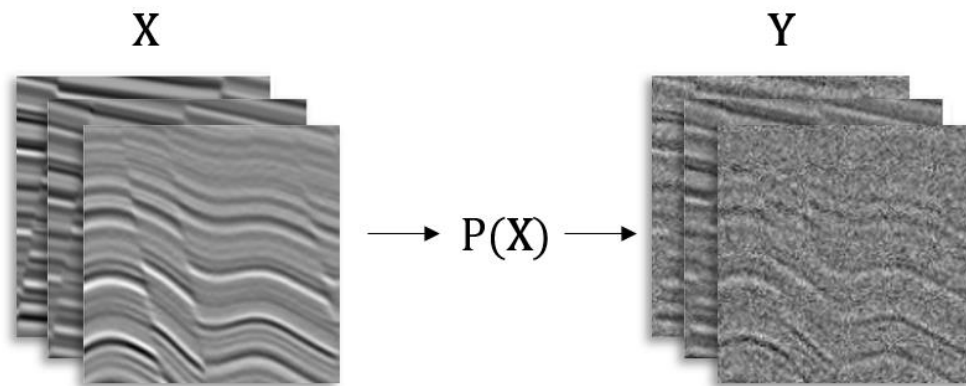
en el campo. Además de demostrar que una tendencia en el estado del arte para solucionar la problemática de atenuación de ruido en imágenes sísmicas es el aprendizaje profundo.

### 2.3 Aprendizaje profundo para el mejoramiento de imágenes sísmicas

Las imágenes sísmicas post-apilado ruidosas pueden ser modeladas como  $\mathbf{Y} = P(\mathbf{X})$ , esta formulación es conocida como el modelo directo (*forward problem* en inglés) (ver Figura 3), en el cual el objetivo es obtener  $\mathbf{Y}$  a partir de  $\mathbf{X}$ , donde  $\mathbf{Y}$  es la imagen con ruido,  $P$  es un operador que agrega ruido a la imagen sísmica y  $\mathbf{X}$  es la imagen limpia.

#### Figura 3

*Modelo directo (forward problem en inglés) con un operador de ruido  $P$  (Imágenes tomadas de Peng et al., 2023)*



De acuerdo con lo anterior, el problema del mejoramiento de imágenes sísmicas puede resolverse como un problema inverso para estimar la imagen limpia  $\mathbf{X}$  a partir de una imagen ruidosa  $\mathbf{Y}$  mediante aprendizaje supervisado con entradas  $\mathbf{Y}$  y etiquetas  $\mathbf{X}$ . En este enfoque, una red neuronal  $\mathcal{M}$  con pesos  $\mathbf{w}$  resuelve el problema inverso mediante:  $\mathcal{M}_{\mathbf{w}}(\mathbf{Y}) = \mathbf{X}^*$ , donde  $\mathbf{X}^*$  es aproximadamente  $\mathbf{X}$  durante el entrenamiento. El problema de optimización para ajustar los pesos  $\mathbf{w}$  de la red es el siguiente:

$$\mathbf{w}^* = \underset{\mathbf{w}}{\operatorname{argmin}} \|\mathcal{M}_{\mathbf{w}}(\mathbf{Y}) - \mathbf{X}\|_F^2 + R(\mathcal{M}_{\mathbf{w}}(\mathbf{Y})), \quad (1)$$

donde el objetivo es optimizar los pesos de la red  $\mathbf{w}$  para minimizar la función de pérdida definida por la norma de Frobenius  $L_F \|\cdot\|_F^2$ , con la ayuda de un regularizador  $R(\mathcal{M}_{\mathbf{w}}(\mathbf{Y}))$  que se calcula sobre la estimación de  $\mathcal{M}_{\mathbf{w}}$  para encontrar  $\mathbf{w}^*$  tal que  $\mathcal{M}_{\mathbf{w}^*}(\mathbf{Y}) \approx \mathbf{X}$ .

Basado en esto, el aprendizaje profundo ha sido comúnmente la herramienta empleada para la investigación de soluciones que puedan aportar gran precisión al momento de la atenuación de ruido (Mandelli et al., 2019; Wu et al., 2022). Por ejemplo, Mandelli et al., (2019) propone abordar el problema haciendo uso de una red neuronal con una arquitectura *U-net* (ver Figura 6), donde el problema de optimización es el siguiente:

$$\mathbf{w}^* = \underset{\mathbf{w}}{\operatorname{argmin}} \sum_{\mathbf{X}_k \in \mathcal{D}_T} \|\mathbf{X}_k - \mathcal{M}_{\mathbf{w}}(\mathbf{Y}_k)\|_F^2 + R(\mathcal{M}_{\mathbf{w}}(\mathbf{Y}_k)), \quad (2)$$

donde  $\mathcal{D}_T$  es el *dataset* de entrenamiento,  $\mathbf{X}_k \in \mathcal{D}_T$  denota el subconjunto de parches limpios pertenecientes al *dataset* de entrenamiento y  $\mathbf{Y}_k$  es el parche con ruido. En este caso el regularizador actúa sobre cada uno de los parches, una ventaja de este esquema es que los parches representan estructuras locales, lo cual incrementa el rendimiento de la red, debido a que, el modelo puede representar de manera más eficiente las características de alto y bajo nivel del conjunto de entrenamiento.

En la aplicación de los métodos anteriores es importante contar con un óptimo conjunto de datos  $\mathbf{X}$  para el entrenamiento de la red. Para la construcción de dicho conjunto existen soluciones que se enfocan en su elaboración, a partir de códigos y modelos matemáticos, como el uso de sismogramas sintéticos y ondículas (Chopra y Sharma, 2016). Como alternativa a esas soluciones existe una propuesta interesante para la creación de las imágenes  $\mathbf{X}$  y es el uso de modelos generativos, estos modelos pueden aportar versatilidad a la producción de imágenes, debido a que,

con un *dataset* lo suficientemente robusto se puede generar una gran cantidad de nuevas imágenes sísmicas que no están presentes en el *dataset* original.

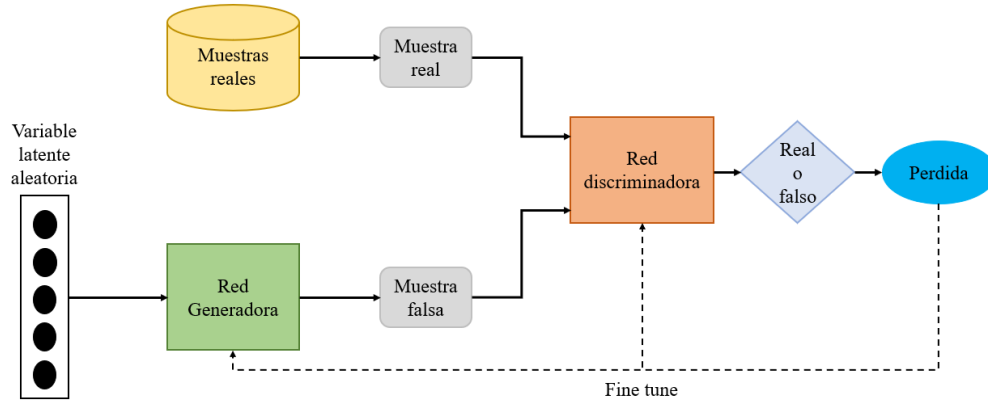
### ***2.3.1 Modelos generativos o de síntesis de imágenes***

Los modelos generativos son uno de los tipos de redes y esquemas neuronales existentes que son usados y están en constante desarrollo en el área de aprendizaje profundo, según Voetman et. al., (2023), su propósito se enfoca en la síntesis de datos, un proceso que se basa en la producción de información artificial. El proceso se basa en aprender la distribución de datos mediante redes neuronales para generar información que siga la distribución del conjunto de datos de entrenamiento. La síntesis puede abarcar imágenes, texto, etc. (Mansimov et al., 2016; Weng, 2021). Un modelo que se destaca en el campo de síntesis de datos son las Redes Generativas Adversativas (GAN).

- **Redes Generativas Adversarias (GAN):** Consiste en dos redes neuronales, un generador y un discriminador (ver Figura 4). El generador construye datos a partir de ruido aleatoriamente distribuido (sigue una distribución gaussiana), mientras que, el discriminador toma como referencia una muestra determinada de los datos de entrenamiento que representa el tipo de información que se planea sintetizar para evaluar los datos generados con respecto a dicha muestra, comparando si la información generada sigue la distribución del conjunto de datos. El objetivo está en que el generador sintetice datos con una semejanza a la muestra cada vez mayor en cada iteración de acuerdo con la clasificación realizada, para que aprenda a producir imágenes que puedan engañar fácilmente al discriminador (Mansimov et al., 2015). La velocidad de generación y la calidad de muestras que ofrece lo hacen un modelo óptimo para el problema a resolver.

#### **Figura 4**

Esquema del modelo generativo GAN (Imagen tomada de Dash et al., 2021)

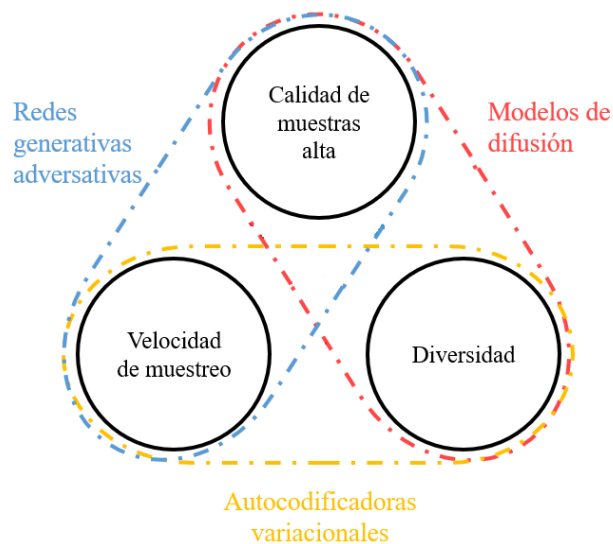


Además de las GAN existen otros dos modelos ampliamente tratados en el campo de la síntesis de imágenes: *Variational auto-encoder (VAE)* (Anello, 2021) que consiste en la reconstrucción de una imagen mediante un modelo (*decoder*) a partir de una distribución producida por un (*encoder*). Modelos de difusión probabilísticos (Durall et al., 2022), que se basa en transformar una imagen a una distribución conocida (generalmente gaussiana) para luego realizar el proceso inverso mediante una red neuronal para pasar de la distribución conocida a la imagen.

Cada modelo posee características específicas que según la aplicación que se planea implementar, causan que el rendimiento de uno pueda ser mayor a otro. Para la selección del modelo que se adaptase a las necesidades del problema se usó el Trilema generativo para analizar el tipo más adecuado, puesto que, expone las virtudes y desventajas de cada uno teniendo en cuenta los siguientes criterios: velocidad del muestreo, diversidad y calidad (ver Figura 5)(Xiao et al., 2021). Para el proyecto se decidió que la prioridad estaba en la calidad y velocidad de generación convirtiendo las GAN en los modelos óptimos.

**Figura 5**

*Trilema generativo (Imagen tomada de Xiao et al., 2022)*



En el área de la exploración sísmica se ha demostrado la capacidad de estos modelos en la síntesis del conjunto de imágenes  $\mathbf{X}$ , particularmente en la aplicación de aprendizaje guiado por modelos generativos, dicho método se enfoca en agregar diversidad y adaptabilidad en la etapa de entrenamiento de una red neuronal convolucional, al generar un *batch* de imágenes en cada época, sometiendo al modelo a un conjunto de entrada que cambia continuamente, evidenciado por Goyes-Peñañiel et al., (2023), donde se propone una aplicación de la técnica mencionada a partir de una arquitectura GAN. Un antecedente que puede trasladarse al área de la atenuación de ruido sísmico al explorar un modelo generativo.

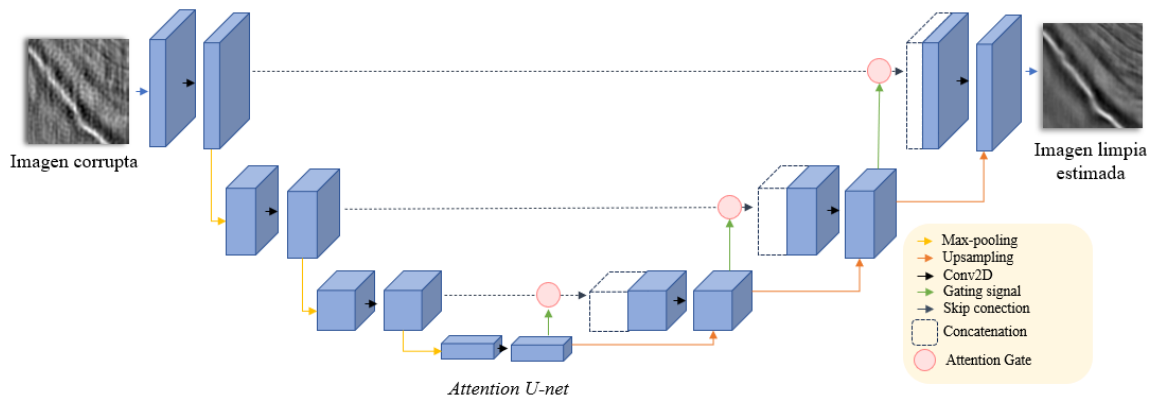
Además de generar un conjunto  $\mathbf{X}$ , es necesario contaminarlo, para tener el par  $\mathbf{X}, \mathbf{Y}$  y que una red pueda aprender cuáles son los ruidos y daños estructurales y cómo deben ser atenuados. Entre los métodos de degradación de imágenes sísmicas se han explorado técnicas de procesamiento de imágenes, agregando a la imagen, ruido gaussiano, *Poison noise*, entre otros (Fogat et al., 2023).

### 2.3.2 Red de atenuación de ruido

En la atenuación de ruido sísmico el uso de redes convolucionales ha sido uno de los métodos mayormente propuestos en el campo (Al-Heety & Thabit, 2022; Fogat et al., 2023), frecuentemente con el uso de una arquitectura *U-net* (ver Figura 6), nombrada así por la forma en la que suele representarse. Esta permite el aprendizaje de las características de los datos limpios y degradados para la reconstrucción de datos corruptos (Mandelli et al., 2019), partiendo de esta arquitectura como base, en la literatura se han desarrollado mejoras, como los mapas de atención que permiten extraer características de regiones importantes de los datos limpios, resultando en arquitecturas como la *Attention U-net* (Oktay et al., 2018).

**Figura 6**

*Arquitectura Attention U-net (adaptado de Oktay et al., 2018)*



Además, en el estado del arte han surgido propuestas interesantes de adaptación de dominio como la transferencia de estilo (Du et al., 2022), una técnica de adaptación que consiste en tomar datos de un contexto para resolver un problema a partir de otro. Para así considerar patrones de ruido y daños estructurales específicos en el entrenamiento de las redes.

### 2.3.3 Transferencia de estilo (*neural style transfer*)

La transferencia de estilo abordado por Du et al., (2022) en su propuesta, es un método tratado como un problema generalizado de la síntesis de texturas, lo que consiste en la extracción y transferencia de una textura del origen al objetivo (Jing et al., 2018). Normalmente, la implementación de esta técnica se dirige a propuestas artísticas, tomando información de una foto como el contenido y el estilo artístico de una obra de arte reconocida, para optimizar una imagen hacia la distribución deseada según la información del contenido y del estilo artístico (ver Figura 7) (Gatys et al., 2015; Jing et al., 2017).

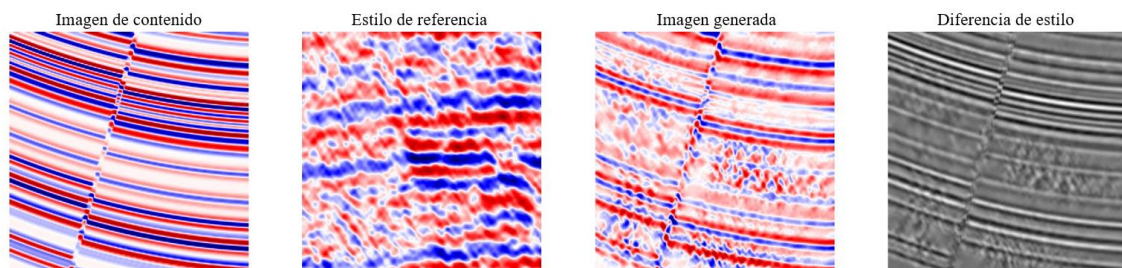
**Figura 7**

*Transferencia de estilo (Imagen tomada de Gatys et al., 2015)*



**Figura 8**

*Transferencia de estilo en imágenes sísmicas (Imagen tomada de Du et al., 2022)*



Aunque la principal aplicación es en el arte, esta técnica se ha implementado en otras áreas, puesto que, la transferencia de estilo puede considerarse un método de adaptación de dominio, como en el área de la sísmica (ver Figura 8). En (Du et al., 2022), se desarrolla un método donde se toma información sísmica real y se adapta a imágenes sintéticas para el entrenamiento de una clásica red convolucional profunda con una arquitectura VGG, que cumple con la tarea de atenuar ruido de acuerdo con los daños presentes en imágenes sísmicas post-apilado reales, de esta manera se evidencia que gracias al uso de la transferencia de estilo para la transformación de imágenes se pueden abordar patrones de ruido y daños estructurales que son usualmente omitidos debido a su alta complejidad para modelar matemáticamente.

### **3. Metodología**

Para el desarrollo de los objetivos específicos propuestos, se siguió un procedimiento dividido en 4 fases, con las actividades necesarias para la ejecución del plan de trabajo.

#### **3.1 Fase 1: Construcción de un operador para generar la degradación de imágenes sísmicas**

Esta fase consistió en la construcción de un operador de degradación de imágenes sísmicas post-apilado a partir de dos *datasets*, uno real y uno sintético. El real para el análisis visual de las imágenes, y desarrollo de los modelos matemáticos aproximados de los ruidos identificados. El sintético para pruebas de los modelos matemáticos del operador y para el entrenamiento del modelo generativo. Las siguientes actividades fueron realizadas:

ACTIVIDAD 1.1. Se exploraron bases de datos de libre acceso reales y sintéticas, entre las que se encuentran, *Blake Ridge Hydrates 3D*, *Kerry 3D*, *F3*, *TGS salt identification challenge*,

*SEAM challenge phase I, AGL Elastic Marmousi, 1994 BP migration from topography.*

Disponibles en TerraNubis (<https://terranubis.com/>) y en SEG wiki ([https://wiki.seg.org/wiki/Open\\_data](https://wiki.seg.org/wiki/Open_data)).

ACTIVIDAD 1.2. Se analizaron patrones de ruido y daños estructurales en el conjunto de datos de imágenes sísmicas reales usando el *software* SeiSee y la librería *segio* de Python como herramientas principales, y se realizó un inventario de tipos de ruido característicos en las imágenes sísmicas.

ACTIVIDAD 1.3. Se construyó el operador de degradación de imágenes con base en los patrones de ruido y daños estructurales identificados en la ACTIVIDAD 1.2, mediante métodos de procesamiento de imágenes, planteado funciones matemáticas.

ACTIVIDAD 1.4. Se implementó el método *Neural style transfer*, una técnica de adaptación de dominio como una alternativa a al operador de degradaciones.

### **3.2 Fase 2: Desarrollo e implementación de un modelo de aprendizaje profundo para la generación de imágenes sísmicas post-apilado**

Para remover el ruido identificado con el uso de una red neuronal convolucional esta debía aprender cuales son las características de las imágenes sísmicas post-apilado limpias. Debido a su naturaleza, obtener una imagen de este tipo es una tarea difícil, por lo tanto, se implementó un modelo generativo para la síntesis de imágenes sísmicas post-apilado sintéticas limpias. Para esto las actividades desarrolladas fueron:

ACTIVIDAD 2.1. Se consultó el estado del arte sobre la síntesis de imágenes en búsqueda de un modelo que cumpliera con equilibrar las características del trilema generativo (ver Figura 5), priorizando la velocidad y calidad con la que se producen las muestras y se seleccionó uno.

ACTIVIDAD 2.2. Se definió matemáticamente el modelo de generación de imágenes sísmicas post-apilado sintéticas limpias con base en la elección de la ACTIVIDAD 2.1.

ACTIVIDAD 2.3. Se adaptó el esquema de entrenamiento del modelo seleccionado para la resolución de imagen requerida por el proyecto.

ACTIVIDAD 2.4. El modelo fue implementado acorde a la ACTIVIDAD 2.3 para la generación de imágenes sísmicas post-apilado sintéticas limpias, usando el lenguaje de programación Python y la librería Pytorch.

ACTIVIDAD 2.5. Se Analizó el rendimiento de la red según la métrica del estado del arte para modelos generativos *Fréchet inception distance* (FID) que compara la información presente entre las imágenes generadas y el conjunto de datos de entrenamiento, para determinar la calidad de la síntesis.

### **3.3 Fase 3: Implementación y desarrollo de un esquema de atenuación de ruido mediante aprendizaje supervisado y guiado por modelos generativos**

En esta fase se recopilaban los productos de las etapas anteriores, para el planteamiento y la implementación de un esquema de atenuación de ruido, usando el lenguaje de programación Python y la librería Pytorch. Los pasos desarrollados fueron:

ACTIVIDAD 3.1. Se investigó el estado del arte sobre redes de atenuación de ruido en imágenes naturales y en imágenes sísmicas post-apilado y uno de los modelos comunes fue la U-net.

ACTIVIDAD 3.1.1. Se definió matemáticamente el procedimiento de la atenuación de ruido, con base en lo revisado en el estado del arte, haciendo uso de SSIM y L1.

ACTIVIDAD 3.1.2. Se planteó un esquema de entrenamiento para una red de atenuación de ruido, que se apoya en la computación en paralelo para generar un proceso de aprendizaje supervisado y guiado.

ACTIVIDAD 3.2. El esquema de la ACTIVIDAD 3.1.2. fue complementado añadiendo un componente de adaptabilidad a la red a través de *fine-tuning* con adaptación de dominio mediante transferencia de estilo.

ACTIVIDAD 3.3. Se implementó la red de atenuación de ruido según el esquema de entrenamiento formulado en la ACTIVIDAD 3.1.2. En esta actividad la red fue entrenada a partir de los conjuntos de imágenes sísmicas post-apilado sintéticas limpias generadas y ruidosas/corruptas con el operador de degradación definido en la ACTIVIDAD 1.3.

ACTIVIDAD 3.4. El esquema de mejora continua fue implementado según lo elaborado en la ACTIVIDAD 3.2. brindando a la red la capacidad de aprender nuevas características de daños para aumentar su capacidad de generalización.

### **3.4 Fase 4: Evaluación de la eficiencia del esquema de atenuación de ruido sísmico en escenarios de imágenes sísmicas reales y sintéticas**

Para comprobar que la solución al problema es acertada, la red de atenuación de ruido se evaluó con respecto a las métricas establecidas en el estado del arte, haciendo pruebas con imágenes sísmicas reales. Para lo anterior se proponen las actividades de esta fase:

ACTIVIDAD 4.1. Al consultar el estado del arte sobre atenuación de ruido sísmico se determinó que las métricas más comunes eran SSIM, PSNR y MSE.

ACTIVIDAD 4.2. La red fue probada con imágenes de campo y sintéticas, mostrando resultados satisfactorios en ambos casos. Además, al encontrar una imagen con un patrón de ruido difícil, la red se adaptó mediante *fine-tuning* con transferencia de estilo.

ACTIVIDAD 4.3. Se Analizaron los resultados, observando la atenuación de los daños en las imágenes sísmicas post-apilado y evaluando cuantitativamente la eficacia de acuerdo con las métricas definidas en el estado del arte.

ACTIVIDAD 4.4. Se compararon los resultados obtenidos de la atenuación del ruido en las imágenes sísmicas del método propuesto con otros métodos del estado del arte, de acuerdo con las métricas.

### **4. Resultados**

A continuación, se presentarán los resultados que evidencian cómo fueron cumplidos los objetivos de acuerdo con lo descrito en la sección 3. Metodología. Su implementación y los resultados que evidencian dicha afirmación.

#### **4.1 Operador de degradación de imágenes sísmicas**

Esta sección corresponde a la construcción del operador de degradación de imágenes sísmicas post-apilado y los resultados obtenidos en la aplicación de este, donde se evidencia la recopilación de los *datasets* reales y sintéticos junto con la definición de los patrones de ruido identificados para la construcción del operador de degradación de imágenes sísmicas sintéticas limpias y ruidosas para posteriormente realizar la implementación del *neural style transfer*.


##### ***4.1.1 Datasets de imágenes sísmicas***

A continuación, se evidencia la selección de los *datasets* usados como base para la elaboración del proyecto, donde se recopilaron *datasets* con imágenes sísmicas post-apilado sintéticas y reales.

**4.1.1.1 Imágenes sísmicas post-apilado reales.** Los *datasets* seleccionados para la elaboración del conjunto de datos reales fueron, el F3, Kerry 3D y *Blake ridge 3D*. Disponibles en la base de datos de libre acceso TerraNubis. Cada uno de los anteriores fue dividido en parches de  $128 \times 128$  píxeles, omitiendo aquellos que por un alto nivel de ruido, visualmente no aportaban información sísmica significativa, al no distinguirse estructuras claras de eventos sísmicos (ver Figura 9), resultando en una cantidad total de imágenes de 22649. En la Tabla 2, se presenta la cantidad de imágenes que aporta cada *dataset* y en la Figura 10 se pueden observar ejemplos de las imágenes de cada uno ellos.

**Figura 9**


*Ejemplo de imagen descartada y aceptada del dataset Blake ridge 3D*



**Tabla 2**

*Imágenes reales resultantes y tamaño del archivo*

<i>Dataset</i>	Cantidad de imágenes	Tamaño (MB)
F3	14957	113
Kerry 3D	4052	30,1
<i>Blake ridge 3D</i>	3640	23,3
Total	22649	166,4

**Figura 10***Ejemplos de imágenes de los datasets usados*

**4.1.1.2 Imágenes sísmicas post-apilado sintéticas.** La elaboración de este *dataset* se realizó con base en las imágenes presentes en conjuntos de datos abiertos como *TGS salt Identification challenge*, *SEAM Challenge Phase 1*, *1994 BP migration from topography*, *AGL Elastic Marmousi*. A todos los *datasets* se les realizó un análisis para seleccionar los datos limpios. Esta selección se realizó a partir de los parches de  $128 \times 128$  píxeles extraídos de cada *dataset* a excepción de *TGS salt Identification challenge*, cuyas imágenes disponibles eran de  $101 \times 101$  píxeles, por lo cual se tuvo que cambiar la dimensionalidad a  $128 \times 128$ , mediante una interpolación bilinear, para que los datos fuesen homogéneos, resultando en un conjunto de datos con una cantidad de 9177 imágenes. En la Tabla 3, se detalla que aporte hizo cada *dataset* al conjunto total y en la Figura 11 se pueden observar ejemplos de las imágenes de cada *dataset* utilizado.


**Tabla 3**

*Imágenes sintéticas resultantes y tamaño del archivo*

<i>Dataset</i>	<i>Cantidad de imágenes</i>	<i>Tamaño (MB)</i>
<i>TGS salt Identification challenge</i>	4150	49,9
<i>SEAM Challenge Phase 1</i>	4072	26,2
<i>1994 BP migration from topography</i>	803	4,15
<i>AGL Elastic Marmousi</i>	152	0,8
<b>Total</b>	<b>9177</b>	<b>81,05</b>

**Figura 11**

*Ejemplos de imágenes de los datasets sintéticos usados*



#### **4.1.2 Métodos de degradación**


En esta sección, se evidencia la recopilación de los métodos usados para la degradación de imágenes sísmicas post-apilado junto con el resultado de la aplicación de cada uno de los patrones identificados.

**4.1.2.1 Procesamiento de imágenes.** Los patrones de daños en las imágenes sísmicas poseen una gran variabilidad, lo que aumenta la dificultad de la clasificación y caracterización de estos. A continuación, se presentan los patrones identificados y los métodos de procesamiento de imágenes mediante los cuales se propusieron simulaciones aproximadas a los daños encontrados de acuerdo con el análisis de las imágenes sísmicas post-apilado del *dataset* real.

**A. Ruido aleatorio.** Es uno de los tipos de ruido de menor complejidad presentes en las imágenes sísmicas post-apilado, debido a que, no existe una relación directa entre el ruido y la señal. Ejemplos de este tipo de ruido pueden ser observados en la Figura 12.

**Figura 12**

*Imágenes sísmicas post-apilado contaminadas con ruido aleatorio.*



Para hacer simulaciones del ruido aleatorio se implementaron los siguientes métodos.

- a) **Ruido gaussiano.** A partir de la función de densidad de probabilidad normal es posible generar un tipo de ruido aleatorio aditivo conocido como ruido gaussiano (Gonzales & Woods, 2023). Debido a la facilidad para el manejo en los dominios; espacial y de frecuencia, los modelos de ruido gaussiano son ampliamente utilizados en la práctica (Fogat et al., 2023) y se pueden definir como:

$$P(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-\mu)^2/2\sigma^2}, \quad (3)$$

donde  $\mu$  es la media igual a 0 y  $\sigma$  es la desviación estándar igual a 1. En la Figura 16, se puede apreciar cómo afecta el método anterior a las imágenes una vez es aplicado, incluyendo variaciones sobre su intensidad.

- b) **Poisson**. Es una función de densidad de probabilidad, a partir de la cual se puede generar un tipo de ruido no aditivo que sigue dicha función. Está basado en la incertidumbre inherente asociada a la medición de la luz debido a su naturaleza cuantizada (Fogat et al., 2023). Como este tipo de ruido depende de la señal, para el caso de las imágenes el valor está determinado por la intensidad de cada píxel. Se define como:

$$P(x) = \frac{\lambda^x e^{-\lambda}}{x!} \quad (4)$$

donde  $\lambda$  representa el valor del píxel y  $x$  la cantidad de ocurrencias 0.

En la Figura 16, se puede apreciar cómo afecta este método a las imágenes una vez es aplicado.

- c) **Speckle**. Es un tipo de ruido áspero que existe de forma natural. Se origina como resultado del procesamiento coherente de señales *backscattered* y se puede obtener a partir de la multiplicación de ruido aleatorio, en este caso con una distribución gaussiana, que se multiplica por la imagen original (Fogat et al., 2023). El ruido *Speckle* se define como:

$$f(g) = \mathbf{X} \times g, \quad (5)$$

donde  $\mathbf{X}$  es la imagen original y  $g$  es el ruido aleatorio (ambos  $\mathbf{X}$  y  $g$  son matrices) (3) con  $\mu = 0$  y  $\sigma = 1$ .

En la Figura 16, se puede apreciar cómo afecta este método a las imágenes una vez es aplicado, incluyendo variaciones sobre su peso.

- d) ***Salt and pepper***. Este es un tipo de ruido aditivo que solo tiene dos valores 255 (brillante) y 0 (oscuro), los cuales se distribuyen sobre la imagen, como resultado de la aplicación se observan puntos oscuros y brillantes (Fogat et al., 2023). Este ruido se define de la siguiente manera:

$$p(z) = \begin{cases} P_a & \text{for } z = a \\ P_b & \text{for } z = b \\ 0 & \text{otherwise} \end{cases}, \quad (6)$$


donde  $P_a$  es el valor oscuro (0) original y  $P_b$  es el valor brillante (255). Así como se puede apreciar en la Figura 16.

**B. Ruido no aleatorio.** Estos tipos de ruido son más complejos que los aleatorios y requieren operaciones matemáticas más elaboradas. Ejemplos de estos tipos de ruido pueden ser observados en la Figura 13.

- a) ***Stripes***. En las imágenes sísmicas post-apilado reales se pueden notar interrupciones en las señales que se pueden interpretar como líneas, como se aprecia en la Figura 13.

### **Figura 13**

*Ejemplo de líneas presentes en imágenes sísmicas*



De acuerdo con lo anterior, para modelar el comportamiento de dichas líneas se propuso la siguiente ecuación:

$$f(x) = \text{sen}(2\pi Fx) \quad (7)$$


donde  $x$  es un vector que representa una línea que se produce a partir de una malla entre dos arreglos unidimensionales y  $F$  la frecuencia con la que este afecta la imagen a partir de una función senoide, así como se muestra en la Figura 16, donde se usa un valor estático de  $F = 15$  y se varía su intensidad.

- b) **Lineal.** Este es otro método implementado para aproximarse a las líneas presentes en las imágenes reales. Consiste en seleccionar un píxel aleatorio  $i$  de la imagen  $\mathbf{X}$ , para tomar su valor y reemplazar  $k$  vectores de  $\mathbf{X}$  por  $i$ . El comportamiento de este ruido puede observarse en la Figura 16, donde se varía la cantidad de líneas que corrompen la imagen.
- c) **Blur Gaussiano.** Frecuentemente este método es usado para el mejoramiento de imágenes ya que puede ser útil para suavizarlas. Pero, para el proyecto se tomó un enfoque de degradación ya que el *blur* al ser aplicado de manera agresiva puede

reducir significativamente la calidad de las imágenes, asemejándose a la baja nitidez encontrada en algunas imágenes sísmicas post-apilado (ver Figura 14).

**Figura 14**

*Imágenes sísmicas con poca nitidez*



Para este método se aplica la ecuación (3) mediante un kernel, una matriz pequeña con la que se realiza el proceso de convolución con la imagen. Esta operación se define como:

$$(q * f)(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(q, t) f(x - s, y - t), \quad (8)$$

donde  $*$  es el operador de convolución,  $f$  es la imagen a la que se desea aplicar el *blur* y  $w$  es el Kernel. La convolución evalúa todos los valores de las variables  $x$  y  $y$ , de modo que el centro de  $w$  visite cada píxel en  $f$ . Cabe resaltar que no se aplica *padding* con el método utilizado. En la Figura 17 se puede observar el resultado de la implementación con variaciones en la intensidad.

- d) **Ondas/difracciones.** En las imágenes sísmicas se suelen presentar daños o artefactos luego del procesamiento, esto puede resultar en la formación de un daño

que se puede asemejar a parábolas de diferentes amplitudes, su simulación se planteó a partir de la siguiente ecuación:

$$f(x) = \text{sen}(x + ay^2), \quad (9)$$


donde  $a$  es la amplitud y  $x$  y  $y$  representan coordenadas de la imagen.

Variaciones de este método pueden aplicarse para obtener resultados con una mayor variabilidad, al hacer uso de desplazamientos acompañados de amplitudes grandes, tal que:

$$f(x) = \text{sen}(x + a(y + b)^2), \quad (10)$$

donde  $b$  es el desplazamiento que va a recibir la función. En la Figura 16 y Figura 17 se muestra la aplicación de este método, como ondas/difracción para la ecuación (9) y ondas/difracción v2 para la ecuación (10), donde se puede ver como este tipo de daño afecta a la imagen con diferentes intensidades.

- e) **Lineal v2.** Al observar imágenes sísmicas post-apilado reales, se hace notorio un patrón de daño que se podría describir como trazos de información incoherente que interrumpen la continuidad de la señal original, así como se observa en la Figura 15.

**Figura 15***Daño vertical en imágenes sísmicas reales*

Para realizar simulaciones del ruido se planteó el siguiente procedimiento. Tomar un vector  $v$  de la imagen  $\mathbf{X}$  y reemplazar  $k$  vectores de  $\mathbf{X}$  por  $v$ . En la Figura 16 se puede ver la implementación de este método variando la cantidad de trazos.

- f) **Ruido aditivo correlacionado.** Durante el proceso de construcción de los métodos anteriores se planteó la idea de explorar la literatura en el área de procesamiento de imágenes sobre tipos de ruido que ya han sido estudiados y modelados, que se pudieran transferir al dominio de las imágenes sísmicas post-apilado. El trabajo de Makinen et al., (2020), propone las ecuaciones presentes en la Tabla 4, las cuales modelan el ruido estacionario correlacionado mediante convoluciones con ruido gaussiano, tal que:

$$\eta = r \circledast g, \quad (11)$$

donde  $\eta$  es el ruido resultante de la convolución  $\circledast$  entre  $r$  que es ruido gaussiano con media cero y varianza uno  $\mathcal{N}(0,1)$  y  $g$  es el kernel definido por las ecuaciones

mencionadas, este ruido es posteriormente añadido a una imagen  $\mathbf{X}$  para obtener  $\mathbf{Y}$ .

**Tabla 4**

*Kernels de ruido correlacionado*

$g_1$	$\text{máx} \{0,1 -  x^{(2)} \} \text{máx} \{0,16 -  x^{(1)} \}$
$g_2$	$\cos \left( \left( (x^{(1)})^2 + (x^{(2)})^2 \right)^{1/2} \right)$

Modificaciones y combinaciones de las ecuaciones de la Tabla 4 fueron implementadas para obtener resultados variados con una mayor aproximación a los daños presentes en las imágenes sísmicas (ver Tabla 5).

**Tabla 5**

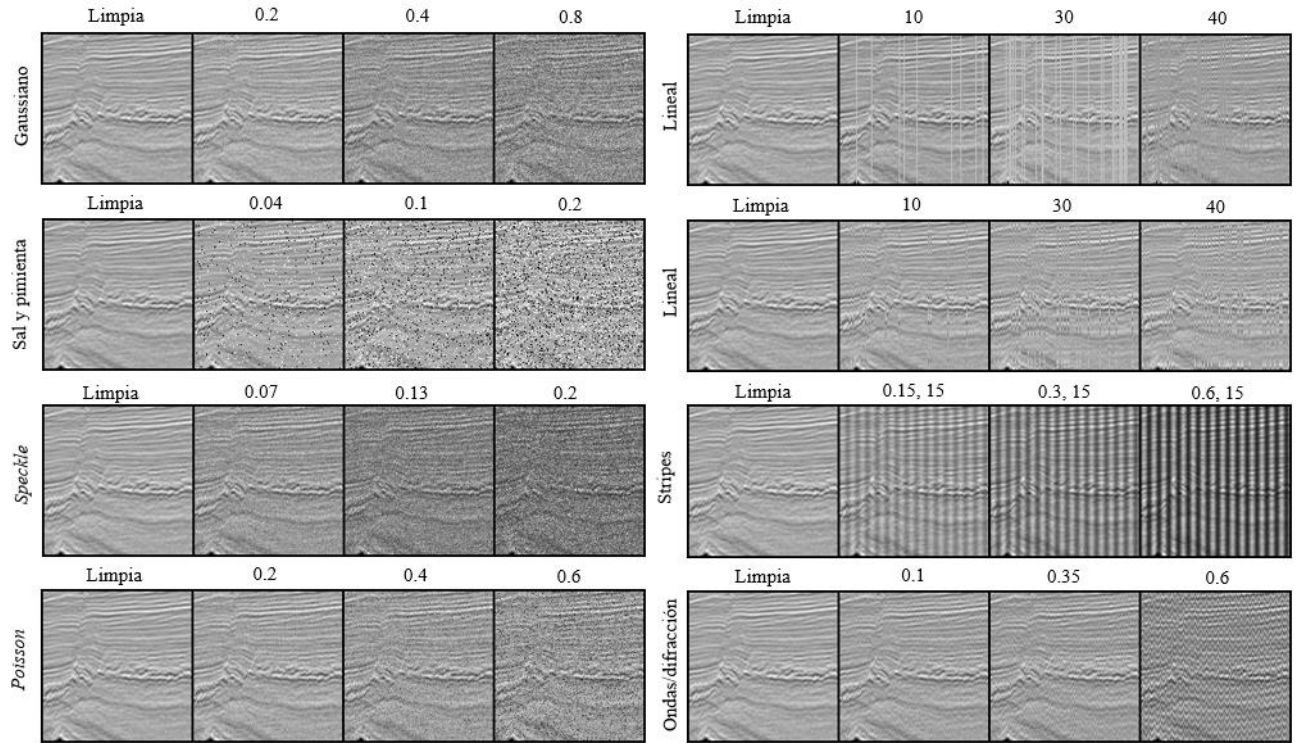
*Variaciones y combinaciones de ruido correlacionado*

$s_1$	$g_1 + g_2$
$s_1 \text{ blur}$	$(q * s_1)(x, y)$
$g_{v1}$	$\text{máx} \{0,16 -  x^{(2)} \} \text{máx} \{0,16 -  x^{(2)} \} \{0,1 -  x^{(1)} \}$
$g_{vi1}$	$g_{v1} \otimes (6)$

En la Figura 17 se puede observar cómo afectan estos tipos de ruido a las imágenes sísmicas sintéticas con variaciones en su intensidad.

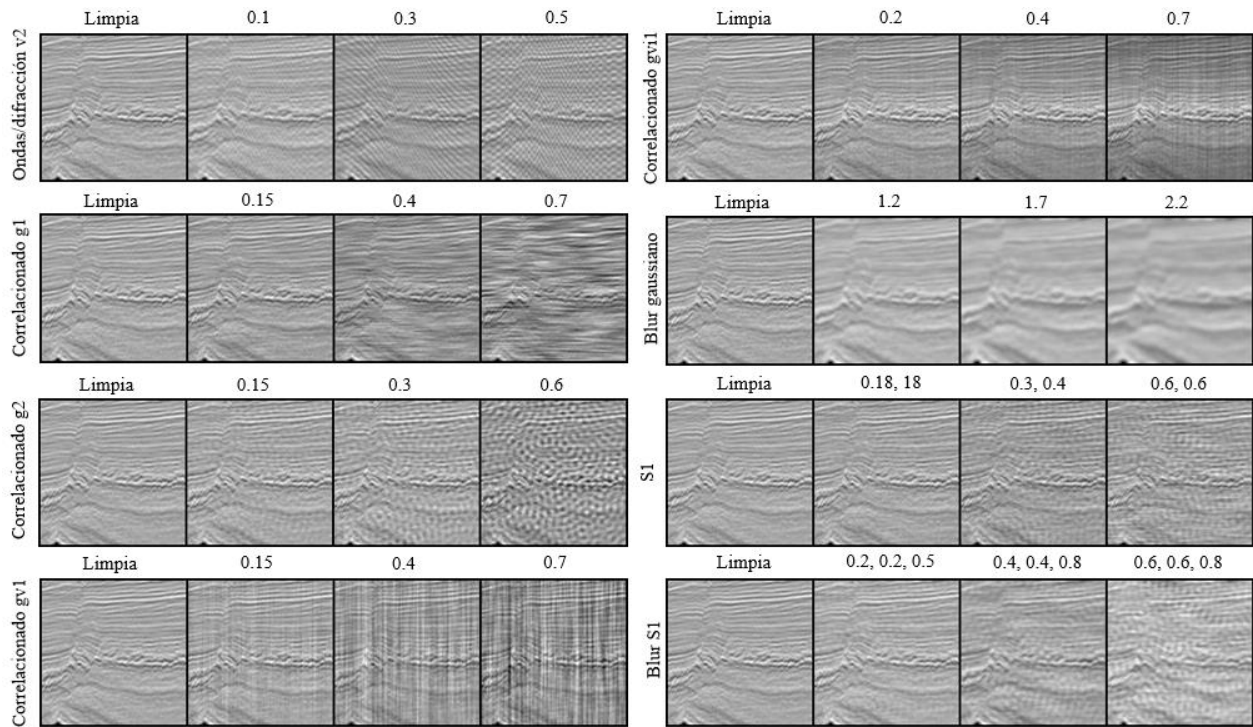
**Figura 16**

*Daños aplicados a una imagen sísmica sintética variando su intensidad*



**Figura 17**


*Daños aplicados a una imagen sísmica sintética variando su intensidad*



Al observar las imágenes presentes en las figuras anteriores (Figura 16 y Figura 17) es notable que los eventos sísmicos de menor escala dejan de ser perceptibles por la degradación aplicada a partir de un nivel medio de ruido. Los de gran escala pueden ser apreciados incluso con un nivel alto de ruido, pero la información que pueden aportar no es significativa, por lo que dejan de ser útiles para la interpretación, así como se observa en la Figura 18. De acuerdo con el análisis anterior se tomaron los valores mínimos y máximos para la aplicación de cada daño durante el entrenamiento en el esquema de atenuación.

**Figura 18**

*Ejemplo de evento sísmico de gran y baja escala*



- Evento sísmico de baja escala
- Evento sísmico de gran escala

**4.1.2.2 Transferencia de estilo (*Neural style transfer*).** Es un método de adaptación de dominio que probó ser eficiente, para trasladar patrones de daños de imágenes sísmicas reales a sintéticas (Du et al., 2022). Su funcionamiento consiste en la minimización de dos distancias, la distancia  $D_c$  que calcula la diferencia de contenido entre dos imágenes y  $D_s$  que realiza la misma operación, pero con el estilo. Este proceso es realizado con la imagen de entrada para minimizar tanto su distancia de contenido con la imagen de contenido como su distancia de estilo con la imagen de estilo (Gatys et al., 2015; Jing et al., 2017). El método puede ser modelado a partir de dos funciones de pérdida, la de contenido:

$$D_c(\mathbf{X}, C) = \sum_L \|F_{XL} - F_{CL}\|^2, \quad (12)$$

donde  $F_{XL}$  es el mapa de características de una capa  $L$  en una red que procesa la imagen  $\mathbf{X}$  y la de contenido  $C$ ,  $F_{CL}$  son los mapas de características de la imagen de contenido, los cuales deben ser conocidos para calcular la distancia de contenido  $\|F_{XL} - F_{CL}\|^2$ , siendo el error cuadrático entre los mapas de características lo que determina la distancia de contenido ponderada  $D_c(X, C)$ .

Por otro lado, la función de pérdida de estilo.

$$G_{XL} = \frac{\hat{F}_{XL}\hat{F}_{XL}^T}{KM}, \quad (13)$$

$$D_s = \sum_L \|G_{XL} - G_{SL}\|^2, \quad (14)$$

donde  $G_{XL}$  es una matriz de Gram que se calcula a partir de  $\hat{F}_{XL}$ ,  $F_{XL}L\hat{F}_{XL}K \times NK$  es el número de mapas de características  $L$ ,  $N$  es la longitud de cualquier mapa de características vectorizado

$\hat{F}_{XL}^k$ ,  $KM$  es el número total de los elementos en la matriz que se usa para normalizar la matriz de Gram y contrarrestar el hecho de que las matrices  $\hat{F}_{XL}$  con una gran dimensión en  $N$  producen valores más grandes en la matriz de Gram. Estos valores más grandes harán que las primeras capas (antes de las capas de *pooling*) tengan un impacto mayor durante el descenso del gradiente,  $\|G_{XL} - G_{SL}\|^2$  es la distancia de estilo, calculada mediante el error cuadrático (Jing et al., 2017).


Con las dos funciones de pérdida anteriores se obtiene la función de pérdida total según Jing et al., (2017), la cual es la suma ponderada de la pérdida de estilo y contenido en todas las capas, tal que:

$$\mathcal{L}_{\text{total}}(\mathbf{X}, C, S) = \alpha D_C(\mathbf{X}, C) + \beta D_S(\mathbf{X}, S) \quad (15)$$

Esta transferencia se aplica utilizando una arquitectura de VGG19. La aplicación de este método para la transferencia de patrones de daños sísmicos se puede observar en la Figura 19, donde se toma una imagen sintética como la de contenido y una real como de estilo, para obtener una imagen sintética con una degradación coherente con el ruido de la imagen real.

### Figura 19

*Transferencia de estilo aplicada en imágenes sísmicas*



## 4.2 Modelo de aprendizaje profundo para la generación de imágenes sísmicas post-apilado

Esta sección corresponde a la implementación del modelo de aprendizaje profundo para la generación de imágenes sísmicas post-apilado y los resultados obtenidos, donde se evidencia la comparación de modelos con los factores de selección y la definición matemática del mismo.

### 4.2.1 Comparación de modelos

De acuerdo con el objetivo del proyecto los aspectos más importantes que se tuvieron en cuenta considerando los criterios del trilema generativo para la selección de un modelo, fueron la velocidad de generación y la calidad de las muestras, ya que este es el responsable de guiar el aprendizaje de la red encargada de la atenuación de ruido. Por lo tanto, siguiendo la literatura sobre síntesis de imágenes, las redes GAN eran las que se adecuaban a los requerimientos mencionados, debido a esto se plantearon e implementaron los modelos en la Tabla 6, entrenándolos con un conjunto de imágenes de campo y sintéticas, para comparar su eficacia en inferencia en busca del modelo más apto.


**Tabla 6**

*Síntesis de imágenes, duración por cantidad de muestras*

Referencia	Modelo	FID	Cantidad de muestras	Tiempo de generación en CPU (s)
(Larsen et al., 2015)	VAE-GAN	58,244	1000	<b>12</b>
(Razavi et al., 2019)	VQ-VAE2	19,027	1000	> 1200
(Gulrajani et al., 2017)	WGAN-GP	60,738	1000	152
(Karras et al., 2017)	PGGAN	<b>10,250</b>	1000	65

**Figura 20**

*Resultados: generación de imágenes por modelo*

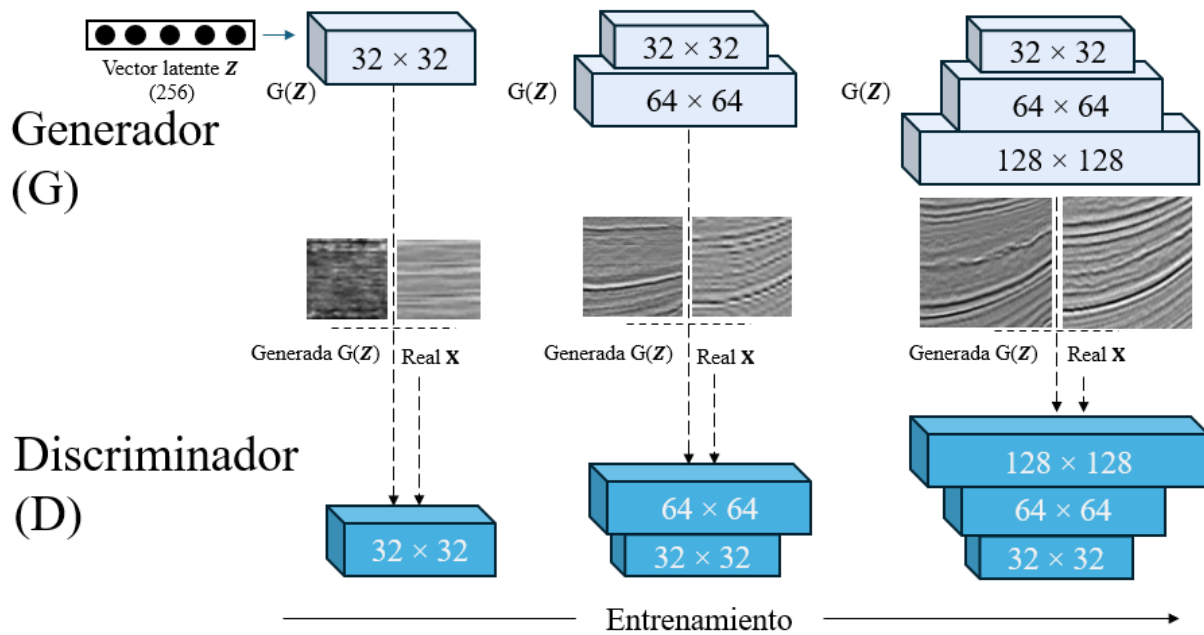


El reto más grande en la selección del modelo fue la resolución requerida ( $128 \times 128$ ), debido a que los modelos que contaban con una alta velocidad de generación fallaban en generar imágenes de alta calidad coherentes con el dominio de entrenamiento, así como se observa en la Figura 20, y al probar con un modelo enfocado en la calidad, el tiempo de generación fue demasiado elevado. Por lo tanto, de acuerdo con los resultados presentados en la Tabla 6 y Figura 20, el modelo seleccionado fue PGGAN, que ofrecía la mejor calidad de imágenes de acuerdo con la métrica FID y un tiempo de generación adecuado.

**4.2.1.1 Definición matemática del modelo.** El enfoque propuesto por Karras et al., (2017), se basa en el aumento progresivo de la resolución de las imágenes generadas, escalando progresivamente tanto en el generador, como en el discriminador. El proceso se puede observar en la Figura 21. El generador empieza a sintetizando imágenes de baja resolución y el discriminador reduce las imágenes reales a la misma resolución para calcular la distancia de Wasserstein. En este proceso luego se van aumentando las capas de cada modelo tomando como partida el conocimiento adquirido en la capa anterior suavizando la transición del escalado hasta llegar a la resolución deseada.

**Figura 21**

*Esquema de entrenamiento PGGAN (Karras et al., 2017)*



De acuerdo con lo descrito anteriormente el aprendizaje de la red está sujeto a la siguiente función de costo (Gulrajani et al., 2017; Karras et al., 2017).

$$\begin{aligned}
 \mathbf{G}^*, \mathbf{D}^* = \underset{\mathbf{G}}{\operatorname{argmin}} \underset{\mathbf{D}}{\operatorname{argmax}} & \mathbb{E}_{\mathbf{X} \sim \mathbb{P}_r} [\mathbf{D}(\mathbf{X})] - \mathbb{E}_{\mathbf{X}^* \sim \mathbb{P}_g} [\mathbf{D}(\mathbf{X}^*)] \\
 & + \lambda \mathbb{E}_{\mathbf{X}^* \sim \mathbb{P}_{\mathbf{X}^*}} (\|\nabla \mathbf{X}^* \mathbf{D}(\mathbf{X}^*)\|_2 - 1)^2 + a \mathbb{E}[(\mathbf{D}(\mathbf{X}^*))^2]
 \end{aligned} \tag{16}$$


Donde  $\mathbf{G}^*$  son los pesos optimizados de la red generadora y  $\mathbf{D}^*$  los de la red discriminadora, que se consiguen a partir de la minimización del cálculo de la distancia de Wasserstein y ,  $\underset{\mathbf{D}}{\operatorname{argmax}} \mathbb{E}_{\mathbf{X} \sim \mathbb{P}_r} [\mathbf{D}(\mathbf{X})] - \mathbb{E}_{\mathbf{X}^* \sim \mathbb{P}_g} [\mathbf{D}(\mathbf{X}^*)]$ , donde  $\mathbb{P}_r$  es la distribución de los datos reales,  $\mathbf{X}$  las imágenes limpias,  $\mathbb{P}_g$  es la distribución del modelo,  $\mathbf{X}^*$  las imágenes generadas,  $\mathbb{E}_{\mathbf{X} \sim \mathbb{P}_r} [\mathbf{D}(\mathbf{X})]$  es la esperanza de las muestras reales en el discriminador y  $\mathbb{E}_{\mathbf{X}^* \sim \mathbb{P}_g} [\mathbf{D}(\mathbf{X}^*)]$  es la esperanza de las muestras estimadas  $\mathbf{X}^*$ . Al cálculo de la distancia de Wasserstein se le suma la penalización como un regularizador  $\lambda \mathbb{E}_{\mathbf{X}^* \sim \mathbb{P}_{\mathbf{X}^*}} (\|\nabla \mathbf{X}^* \mathbf{D}(\mathbf{X}^*)\|_2 - 1)^2$  donde,  $\lambda$  es el coeficiente de penalización (10 fue el valor usado en el proyecto),  $\mathbb{P}_{\mathbf{X}^*}$  es la distribución de las muestras estimadas,  $\|\cdot\|_2$  es la norma euclidiana que se aplica al gradiente de la salida del discriminador  $\nabla \mathbf{X}^* \mathbf{D}(\mathbf{X}^*)$  al que se le sustrae 1, para asegurar que el gradiente no se desvíe y se aproxime a una norma de 1, y se eleva al cuadrado para asegurar que los valores siempre sea positivos. Además del regularizador que penaliza el gradiente, se suma otro con el propósito de que la salida del discriminador no se aleje demasiado de 0, por lo tanto, se usa  $a \mathbb{E}_{\mathbf{X} \sim \mathbb{P}_r} [\mathbf{D}(\mathbf{X})^2]$ , donde  $a$  es un coeficiente pequeño (0.001 fue usado en el proyecto) y se calcula la esperanza de las  $\mathbf{X}$  al cuadrado arrojadas por el discriminador.

**4.2.1.2 Implementación de PGGAN.** Debido a que el modelo PGGAN fue propuesto para imágenes de alta resolución, el esquema de entrenamiento se tuvo que adaptar. Originalmente el modelo empezaba con una resolución de  $4\times 4$ , pero al realizar experimentos, se observó que la información reflejada en resoluciones tan bajas no era significativa para las imágenes sísmicas, ya que estas cuentan con menos características que imágenes naturales como los rostros. Por ende, debido al tamaño definido de  $128\times 128$  píxeles, se encontró que la resolución inicial que mejor se adaptaba era de  $32\times 32$ , consiguiendo así resultados satisfactorios.

Para el entrenamiento de la red se usó una combinación de 8000 imágenes resultantes de la selección de las mejores imágenes reales y sintéticas, consto de 1000 épocas en una primera etapa, repartidas en 100, 350 y 550 respectivamente entre las capas  $32\times 32$ ,  $64\times 64$  y  $128\times 128$ , ya que se observó que mientras más pequeña la capa, menos épocas eran necesarias para obtener los resultados deseados. El entrenamiento se detuvo en la época 160 de la capa de  $128\times 128$  debido a que las imágenes generadas ya eran coherentes con las imágenes de entrenamiento. Posteriormente al realizar un análisis visual más riguroso se tomó la decisión de hacer un *fine-tuning* de 65 épocas a las capas de  $64\times 64$ ,  $128\times 128$  para afinar detalles y mejorar los resultados. En la Figura 22 se puede notar como las imágenes mejoran su definición luego del *fine-tuning*, lo que es notorio ya que en las imágenes de la primera etapa aún existen artefactos por la baja resolución, mientras en *fine-tuning* las imágenes son suaves.

**Figura 22**

*Imágenes aleatorias generadas tras la primera etapa de entrenamiento y el fine-tuning*



### **4.3 Esquema de atenuación de ruido mediante aprendizaje supervisado y guiado por modelos generativos**

Esta sección corresponde a la elaboración e implementación del esquema de atenuación de ruido y los resultados alcanzados.

#### ***4.3.1 Selección del modelo de atenuación***

Siguiendo la literatura sobre atenuación de ruido sísmico mediante aprendizaje profundo, se encontró que un método común era el uso del modelo *U-net* y variaciones de este (Fogat et al., 2023; Z. Gao et al., 2024; H. Zhang et al., 2023), por lo tanto, se decidió utilizar una implementación que permitiese conservar las características sísmicas de las imágenes post-apilado. Para lograr dicha tarea se optó por una *attention U-net*.

**4.3.1.1 Definición matemática del modelo.** La red de atenuación  $\mathcal{M}$  recibe como entrada las imágenes corruptas  $\mathbf{Y}$  tal que  $\mathcal{M}_{\mathbf{w}}(\mathbf{Y}) = \mathbf{X}^*$ , donde  $\mathbf{X}^*$  es aproximadamente  $\mathbf{X}$  las imágenes limpias durante el entrenamiento. La función de costo utilizada para abordar el problema de optimización fue la siguiente:

$$\mathbf{w}^* = \underset{\mathbf{w}}{\operatorname{argmin}} \|\mathcal{M}_{\mathbf{w}}(\mathbf{Y}) - \mathbf{X}\|_1 + (1 - \operatorname{SSIM}(\mathbf{X}^*, \mathbf{X})), \quad (17)$$

donde  $\|\cdot\|_1$  es la norma  $l_1$  a la cual se le suma el regularizador SSIM, para preservar características perceptuales. Esto se realizó debido que el componente perceptual en imágenes resulta en un acercamiento más fiel a la realidad. SSIM se define como:

$$\operatorname{SSIM}(\mathbf{x}, \mathbf{y}) = [l(\mathbf{x}, \mathbf{y})]^\alpha \cdot [c(\mathbf{x}, \mathbf{y})]^\beta \cdot [s(\mathbf{x}, \mathbf{y})]^\gamma$$

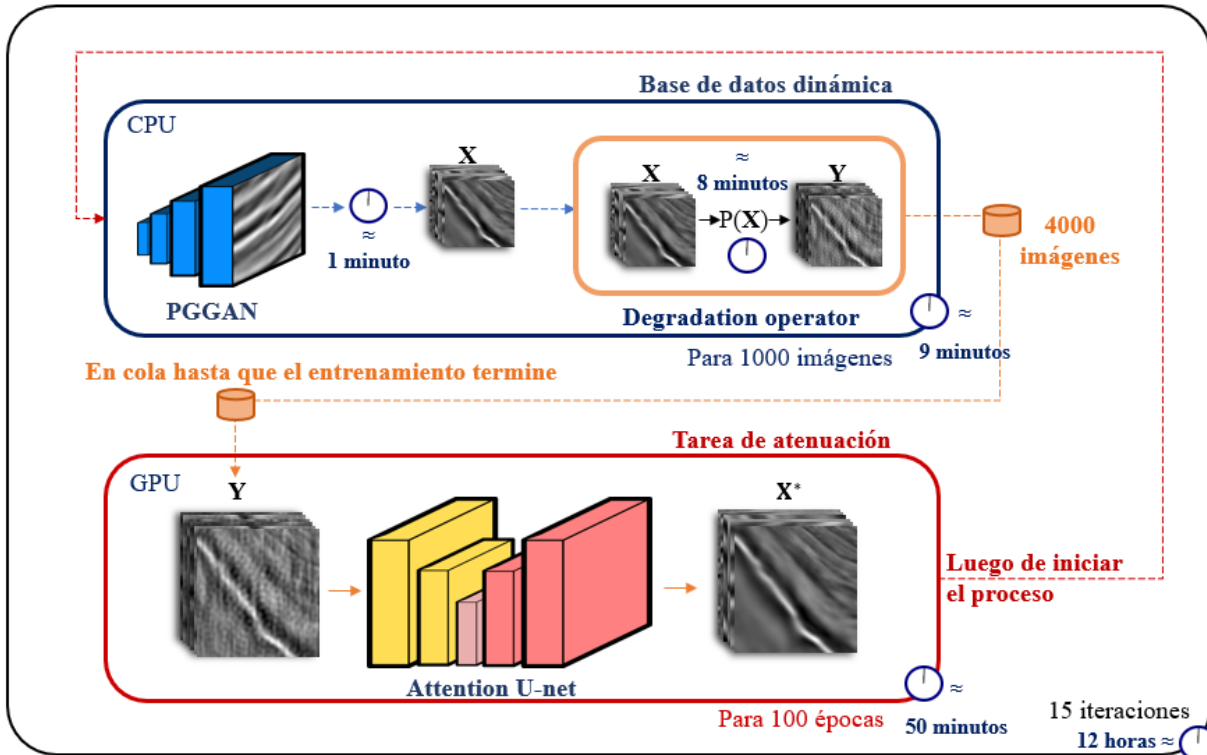
donde  $\operatorname{SSIM}(\mathbf{x}, \mathbf{y})$  es el resultado del producto punto entre  $[l(\mathbf{x}, \mathbf{y})]^\alpha$  que representa luminancia,  $[c(\mathbf{x}, \mathbf{y})]^\beta$  contraste,  $[s(\mathbf{x}, \mathbf{y})]^\gamma$  estructura y  $\alpha > 0, \beta > 0, \gamma > 0$ , la importancia relativa de cada característica.

#### ***4.3.2 Esquema de atenuación de ruido.***

De acuerdo con los objetivos planteados, el esquema diseñado para atenuar ruido es el siguiente:

**Figura 23**

*Esquema de atenuación de ruido*



Como se puede observar en la Figura 23 el esquema cuenta con dos procesos, el de generación de imágenes y el de reconstrucción, ambos son ejecutados en paralelo, la síntesis de imágenes en CPU y el entrenamiento en GPU. Esta aproximación permite maximizar el rendimiento del entrenamiento al no ocupar la VRAM para la producción de los datos, lo que es posible gracias a la velocidad de síntesis del modelo generativo. El flujo de la atenuación empieza con la definición de la cantidad de iteraciones, lo que sigue con la generación del primer conjunto de datos sintéticos mediante la red generativa, que luego son corruptos por el operador de degradación, el cual retorna dos cubos de imágenes, uno que contiene las limpias y otro las degradadas, este par de datos son luego usados para el entrenamiento de la red encargada de la atenuación de ruido y durante el aprendizaje se inicia en paralelo otro proceso de generación de

datos que al finalizar queda en cola, esperando que la red termine la iteración en la que se encuentre. El esquema se ejecutará hasta que se hayan terminado las iteraciones definidas. El siguiente pseudocódigo describe el proceso con mayor claridad.

---

**Inicio.**

$\mathcal{M} \leftarrow$  red de atenuación de ruido

$G \leftarrow$  Modelo generativo

$M \leftarrow$  Numero de muestras

$N \leftarrow$  numero de iteraciones

**Mientras**  $N = 0$  **hacer**

**Para**  $i == 0$  **hasta**  $M - 1$  **con paso 1 hacer**

$z =$  latent vector

$x = G(z)$

**FinPara**

**Para**  $i$  **en**  $x$  **hacer**

$y = P(i)$

**FinPara**

**Para**  $i == 0$  **hasta**  $\text{épocas} - 1$  **con paso 1 hacer**

$x^* = \mathcal{M}(y)$

$Loss(x^*, x)$

**FinPara**

$N \leftarrow N - 1$

**FinMientras**

**Fin.**

---

**4.3.2.1 Esquema de atenuación de ruido adaptable.** Este esquema está basado en el mencionado anteriormente, la lógica del flujo de entrenamiento es la misma. La variación se encuentra en el operador de degradación, en este caso se además de los ruidos caracterizados se añade otro tipo de daño, basado en el estilo ruidoso de una imagen de campo corrupta, este proceso se hace mediante *neural style transfer* con el objetivo de adaptar el dominio de imágenes ruidosas que no se contempló en el análisis de los patrones de degradación, para permitir que la red sea capaz de aprender nuevos tipos de daños.

### **4.4 Evaluación del modelo.**

En esta sección se recopilan resultados obtenidos a partir de la implementación del esquema en una tarjeta gráfica NVIDIA GeForce RTX 4090 con 24GB disponibles de VRAM y una unidad de procesamiento AMD Ryzen 7 5800x3d con 128GB disponibles de RAM, con un entrenamiento de 15 iteraciones del esquema, ejecutando 100 épocas para red de atenuación en cada iteración resultando en un total de 1500. La evaluación se realizó sobre datos sintéticos y de campo externos al dominio original, según lo encontrado en la literatura sobre atenuación de ruido sísmico para evaluar el rendimiento de la atenuación de ruido son *peak signal to noise ratio* (PSNR) y *structural similarity index* (SSIM).

#### **4.4.1 Métricas del esquema de atenuación de ruido**

Para evaluar el modelo se realizó una prueba con una imagen sísmica post-apilado limpia externa al dominio de entrenamiento, se contaminó y atenuó cada tipo de ruido 1000 veces, variando la intensidad del ruido, evaluando las métricas PSNR y SSIM. El promedio resultante por experimento se encuentra en la Tabla 7.

**Tabla 7**

*Métricas PSNR y SSIM de la atenuación de los 16 tipos de ruido.*

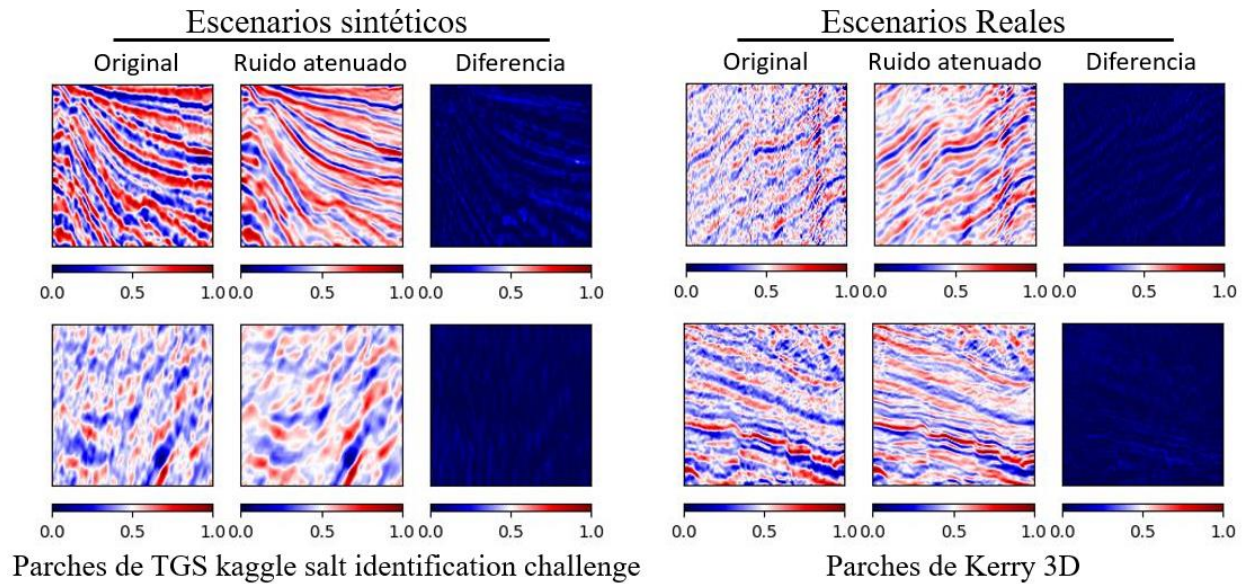
Tipos de ruido	PSNR (dB)	SSIM
Sal y pimienta	39,252	0,997
Lineal	36,507	0,992
Lineal v2	35,371	0,988
<i>Stripes</i>	32,718	0,997
Ondas/difracción	31,577	0,988
Correlacionado $g_{v1}$	30,529	0,995
$s_1$	29,036	0,978
Correlacionado $g_{v11}$	28,705	0,993
Correlacionado $g_2$	28,630	0,972
Gaussiano	28,194	0,974
Poisson	27,805	0,974
<i>Speckle</i>	25,881	0,970
$s_1$ blur	25,757	0,952
Ondas2/difracción	25,718	0,969
Correlacionado $g_1$	27,506	0,955
Blur	25,271	0,967

#### ***5.4.2 Pruebas en datos reales y sintéticos.***

A continuación, en la Figura 24 se presentan algunos ejemplos de la inferencia del modelo (solo los 16 tipos de ruido implementados en su conocimiento) en imágenes sísmicas post-apilado corruptas con patrones de ruido sintéticos y reales, de los cuales no se conoce su contraparte limpia.

**Figura 24**

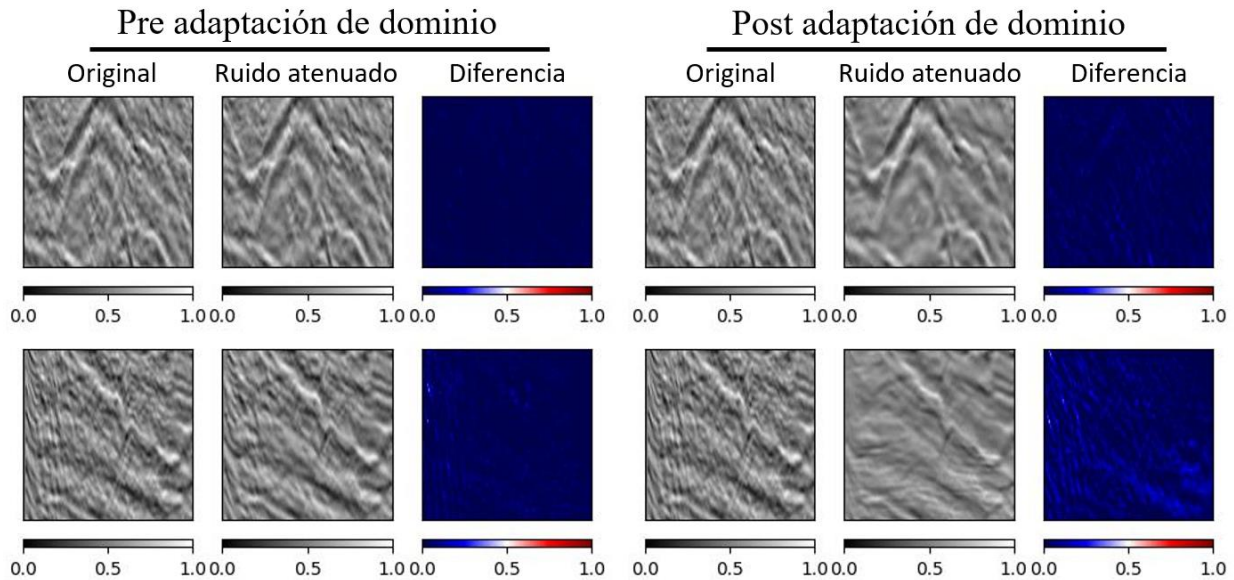
*Modelo evaluado en datos reales y sintéticos en imágenes de  $128 \times 128$  píxeles*



Al observar la Figura 24, es notable la mejoría en la calidad de las imágenes, especialmente en los datos sintéticos, en los reales, también se observa una atenuación de ruido adecuada. En otras imágenes se presentaron ruidos que escapaban del dominio de la red, lo que ocasionó que no fueran correctamente atenuados. Por lo tanto, en la Figura 25 se muestran ejemplos de cómo, después de adaptar el dominio de patrones de daños de imágenes sísmicas post-apilado reales con transferencia de estilo, se consigue un rendimiento mayor en la atenuación de ruido sísmico en esos escenarios de campo.

**Figura 25**

*Adaptación de dominio del patrón de ruido sísmico en parches  $128 \times 128$  píxeles de Kerry 3D*

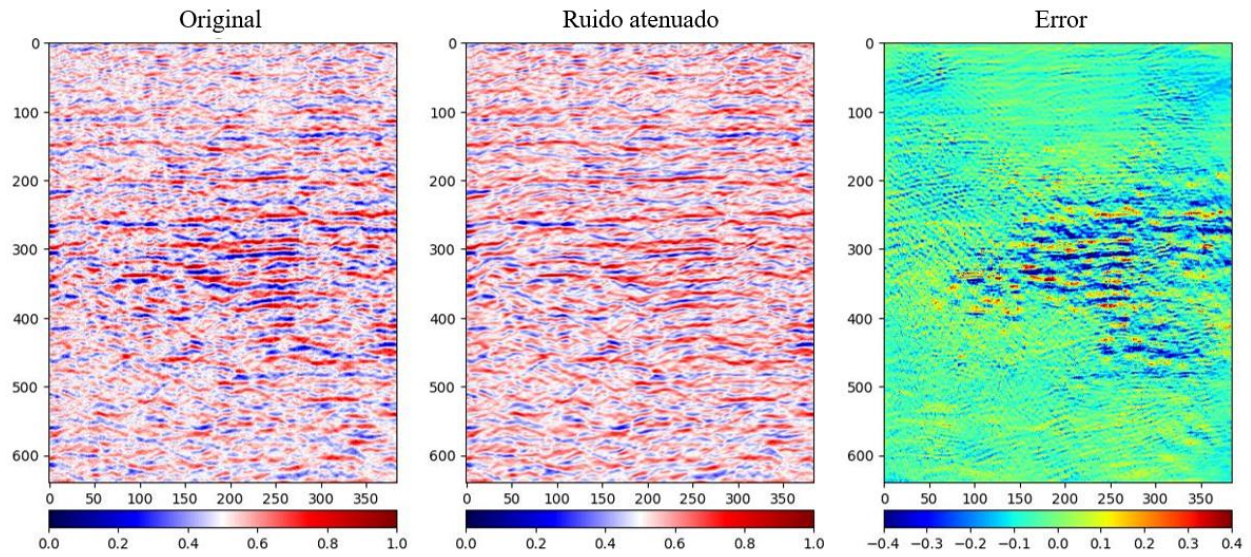


Para obtener los resultados mostrados en la Figura 25 se utilizó el esquema de atenuación adaptable y se entrenó la red de atenuación de ruido durante 30 épocas.

Adicional a las pruebas evaluadas con imágenes de dimensiones  $128 \times 128$ , se realizaron experimentos para comprobar la efectividad del método con secciones sísmicas completas, como se observa en la Figura 26 y Figura 27, donde se presenta un ejemplo realizado a partir de la imagen sísmica post-apilado Alaska 2D. La ejecución de la prueba consistió en dividir la imagen en parches de  $128 \times 128$ , con un desplazamiento a través de la imagen de 32 píxeles por paso, obteniendo un total de 33153 para el tamaño original de  $640 \times 384$ . Posteriormente estos parches fueron atenuados por la red neuronal encargada de la tarea de la atenuación de ruido (*Attention U-net*), tomando 4 segundos para el procesamiento del conjunto completo de parches en una tarjeta gráfica NVIDIA GeForce GTX 1650 con 4GB disponibles de VRAM, y 7 segundos en la reconstrucción de la imagen, realizada mediante el cálculo de la mediana de los parches superpuestos con un procesador AMD Ryzen 5 4600H.

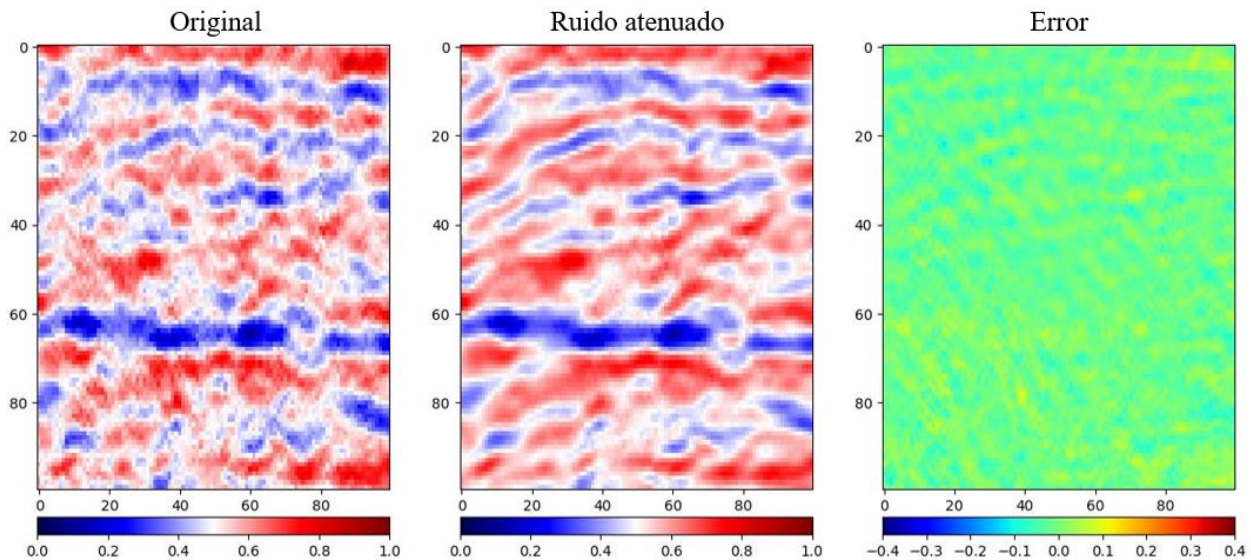
**Figura 26**

*Atenuación de ruido en sísmica completa Alaska 2D*



**Figura 27**

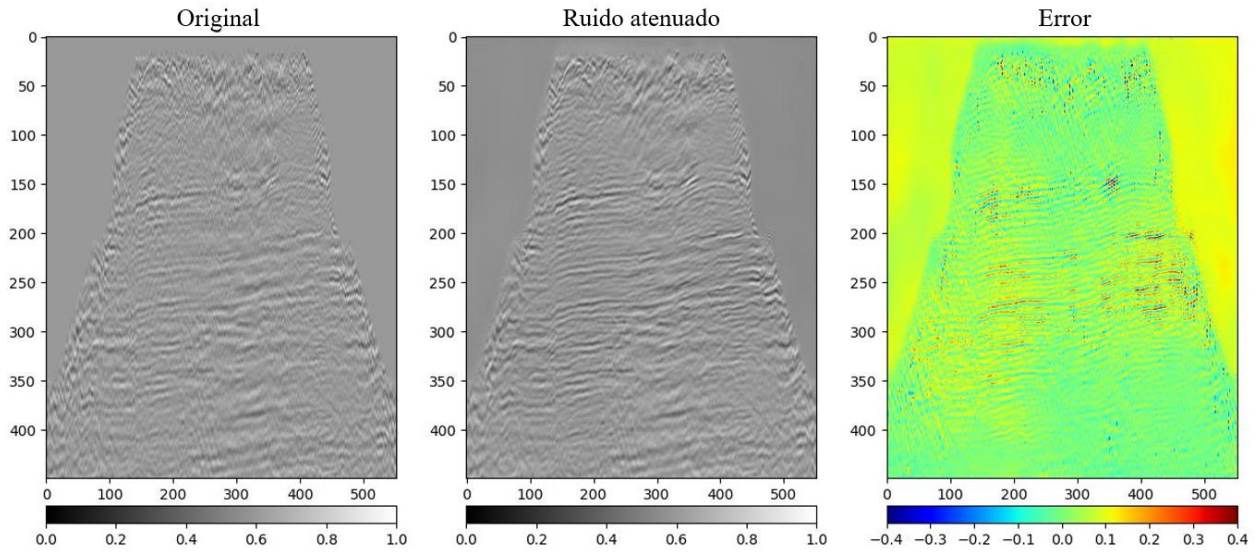
*Sección de la atenuación resultante en Alaska 2D*



El mismo procedimiento se realizó para otra sección sísmica real, con un tiempo de 4 segundos en el proceso de atenuación y 6 en la reconstrucción de la imagen. Los resultados se pueden observar en la Figura 28 y Figura 29.

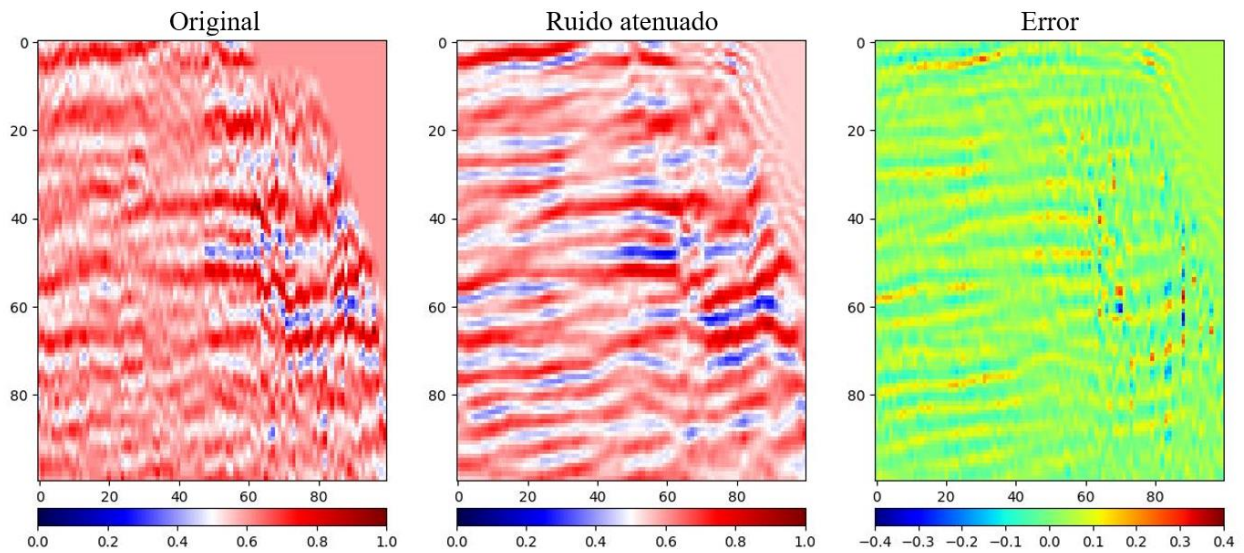
**Figura 28**

*Atenuación de ruido en sísmica completa de campo*



**Figura 29**

*Sección de la atenuación resultante en sección sísmica real*



La imagen del centro en la Figura 26, Figura 27, Figura 28 y Figura 29 deja en evidencia la eficiencia del método al momento de enfrentarse a imágenes sísmicas completas, consiguiendo atenuar el ruido presente mientras se conserva la integridad de la señal original.

**4.4.3 Comparación del esquema propuesto con otros métodos del estado del arte.**

**Desde la Tabla 8 hasta**

Tabla 23 se hace la comparación del método propuesto con otros comúnmente usados en la literatura para la tarea de atenuación de ruido sísmico como: *Deep Image Prior* (DIP)(Ulyanov et al., 2017), S2S-WTV (Xu et al., 2022) que atenúa el ruido mediante una optimización que procura preservar la señal, filtro de la mediana y el método base el cual es la red *Attention U-net* sin el proceso de la base de datos dinámica. Cada una de las tablas contiene el tipo de ruido, su intensidad y las métricas obtenidas de cada experimento, con cada método, resaltando en negrita los valores superiores. Adicionalmente, se usaron dos secciones sísmicas reales una de campo y Alaska 2D para comparar su eficiencia en aplicaciones reales, resultados visuales se encuentran en la Figura 30 y Figura 31, donde se evidencia que el método propuesto tiene un mejor desempeño en la tarea de atenuación de ruido, preservando con mayor fidelidad la señal original.

**Tabla 8**

*Comparación de métodos Gaussiano.*

Ruido	Gaussiano					
	0,1		0,2		0,3	
Intensidad	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	23,361	0,804	22,971	0,785	22,509	0,760
DIP	33,147	0,97	32,059	0,965	30,769	0,959
S2S-WTV	29,477	0,957	28,962	0,953	28,624	0,945
Base	33,584	0,988	31,761	0,977	29,629	0,960
<b>Propuesto</b>	<b>35,324</b>	<b>0,989</b>	<b>33,428</b>	<b>0,986</b>	<b>31,620</b>	<b>0,980</b>

**Tabla 9**

*Comparación de métodos Poisson.*

Ruido	Poisson					
Intensidad	0,1		0,2		0,3	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	23,375	0,804	22,951	0,786	22,371	0,761
DIP	32,958	0,966	32,492	0,964	30,542	0,954
S2S-WTV	30,009	0,961	28,857	0,951	26,612	0,943
Base	33,427	0,988	31,4291	0,976	29,016	0,959
<b>Propuesto</b>	<b>35,562</b>	<b>0,989</b>	<b>34,2412</b>	<b>0,987</b>	<b>32,940</b>	<b>0,983</b>

**Tabla 10**

*Tabla de comparación de métodos salt and pepper.*

Ruido	<i>Salt and pepper (SnP)</i>					
Intensidad	0,1		0,2		0,3	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	22,319	0,773	20,862	0,717	19,318	0,647
DIP	28,735	0,909	27,945	0,866	27,405	0,869
S2S-WTV	23,334	0,832	21,376	0,723	17,516	0,637
Base	25,724	0,941	22,249	0,831	19,681	0,704
<b>Propuesto</b>	<b>39,231</b>	<b>0,997</b>	<b>35,743</b>	<b>0,993</b>	<b>32,791</b>	<b>0,986</b>

**Tabla 11**

*Comparación de métodos speckle.*

Ruido	<i>Speckle</i>					
Intensidad	0,1		0,2		0,3	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	19,045	0,702	14,633	0,549	13,683	0,438
DIP	<b>29,109</b>	0,943	27,609	0,910	25,102	0,871
S2S-WTV	20,787	0,906	15,562	0,779	14,064	0,659
Base	24,093	0,927	17,765	0,804	16,251	0,690
<b>Propuesto</b>	<b>28,570</b>	<b>0,969</b>	<b>27,633</b>	<b>0,935</b>	<b>25,806</b>	<b>0,897</b>

**Tabla 12**

*Comparación de métodos Lineal.*

Ruido	Lineal					
Intensidad	20		30		40	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	19,810	0,632	18,789	0,558	18,002	0,490
DIP	29,314	0,948	29,723	0,952	28,678	0,940
S2S-WTV	25,458	0,889	23,153	0,828	22,250	0,801
Base	28,463	0,956	26,421	0,927	24,856	0,894
<b>Propuesto</b>	<b>38,694</b>	<b>0,996</b>	<b>36,848</b>	<b>0,994</b>	<b>35,035</b>	<b>0,991</b>

**Tabla 13**

*Comparación de métodos Lineal v2.*

Ruido	Lineal v2					
Intensidad	20		30		40	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	21,726	0,723	20,969	0,676	20,316	0,631
DIP	26,820	0,911	26,491	0,903	25,040	0,868
S2S-WTV	24,310	0,856	23,680	0,807	22,291	0,761
Base	27,015	0,93	24,887	0,886	23,111	0,834
<b>Propuesto</b>	<b>37,699</b>	<b>0,996</b>	<b>34,472</b>	<b>0,992</b>	<b>31,877</b>	<b>0,983</b>

**Tabla 14**

*Comparación de métodos stripes.*

Ruido	<i>Stripes</i>					
Intensidad, frecuencia	0,1 - 15		0,2 - 15		0,3 - 15	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	21,825	0,751	18,581	0,633	16,107	0,516
DIP	32,684	0,965	33,306	0,964	32,162	0,962
S2S-WTV	25,322	0,914	19,903	0,800	16,835	0,680
Base	29,413	0,986	24,735	0,964	21,454	0,893
<b>Propuesto</b>	<b>38,804</b>	<b>0,998</b>	<b>39,961</b>	<b>0,998</b>	<b>39,318</b>	<b>0,998</b>

**Tabla 15**

*Comparación de métodos Ondas/difracción.*

Ruido	Ondas/difracción					
Intensidad	0,1		0,2		0,3	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	23,138	0,798	22,173	0,771	21,061	0,740
DIP	30,925	0,959	31,622	0,958	30,411	0,954
S2S-WTV	29,285	0,956	28,736	0,956	25,630	0,936
Base	33,072	0,986	31,521	0,976	30,213	0,965
<b>Propuesto</b>	<b>35,959</b>	<b>0,994</b>	<b>35,828</b>	<b>0,991</b>	<b>34,171</b>	<b>0,989</b>

**Tabla 16**

*Comparación de métodos Ondas/difracción v2.*

Ruido	Ondas/difracción v2					
Intensidad	0,1		0,2		0,3	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la Mediana	19,755	0,693	19,654	0,682	19,497	0,671
DIP	32,102	0,9550	29,897	0,924	28,722	0,936
S2S-WTV	19,049	0,770	21,477	0,772	19,411	0,745
Base	22,074	0,856	21,6878	0,845	21,222	0,829

**Propuesto** | **32,807**    **0,986** | **31,347**    **0,985** | **30,429**    **0,980**

**Tabla 17**

*Comparación de métodos Correlacionado Blur.*

Ruido	<i>Blur</i>					
Intensidad	1		1,5		2	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	19,592	0,697	16,565	0,499	16,044	0,345
DIP	33,822	0,959	29,474	0,909	27,983	0,843
S2S-WTV	20,425	0,787	16,627	0,520	16,069	0,344
Base	22,267	0,862	18,045	0,584	0,353	16,944
<b>Propuesto</b>	<b>33,427</b>	<b>0,991</b>	<b>22,229</b>	<b>0,788</b>	<b>26,354</b>	<b>0,923</b>

**Tabla 18**

*Comparación de métodos Correlacionado g1.*

Ruido	Correlacionado g1					
Intensidad	0,1		0,2		0,3	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	23,298	0,805	22,735	0,785	22,290	0,757
DIP	31,174	0,954	29,238	0,947	28,203	0,931
S2S-WTV	28,515	0,950	27,739	0,944	25,561	0,909
Base	31,81	0,986	29,372	0,968	27,143	0,942
<b>Propuesto</b>	<b>33,802</b>	<b>0,985</b>	<b>30,937</b>	<b>0,973</b>	<b>28,585</b>	<b>0,957</b>

**Tabla 19**

*Comparación de métodos Correlacionado g2.*

Ruido	Correlacionado g2					
Intensidad	0,1		0,2		0,3	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	23,382	0,806	22,958	0,787	22,428	0,759
DIP	33,697	0,966	31,048	0,957	30,218	0,951

ATENUACIÓN DE RUIDO EN IMÁGENES SÍSMICAS POST-APILADO 72

S2S-WTV	29,755	0,960	28,915	0,950	26,858	0,915
Base	32,464	0,988	31,041	0,980	29,4984	0,966
<b>Propuesto</b>	<b>35,889</b>	<b>0,990</b>	<b>34,502</b>	<b>0,989</b>	<b>32,394</b>	<b>0,982</b>

**Tabla 20**

*Comparación de métodos g1vi.*

Ruido	g1vi					
	0,1 - 1		0,2 - 1		0,3 - 1	
Intensidad g1, Intensidad SnP						
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	23,359	0,811	22,452	0,799	21,147	0,784
DIP	32,415	0,963	<b>34,015</b>	0,970	<b>33,463</b>	0,973
S2S-WTV	28,682	0,954	27,379	0,956	23,804	0,943
Base	33,404	0,991	31,262	0,989	29,1411	0,985
<b>Propuesto</b>	<b>34,985</b>	<b>0,998</b>	33,542	<b>0,990</b>	32,618	<b>0,994</b>

**Tabla 21**

*Comparación de métodos Correlacionado g1v.*

Ruido	Correlacionado g1v					
	0,1		0,2		0,3	
Intensidad						
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	23,289	0,804	22,735	0,782	22,003	0,750
DIP	32,863	0,960	34,439	0,968	31,964	0,959
S2S-WTV	29,299	0,957	28,094	0,950	27,518	0,945
Base	32,908	0,991	31,700	0,988	30,552	0,983
<b>Propuesto</b>	<b>36,616</b>	<b>0,995</b>	<b>36,050</b>	<b>0,997</b>	<b>35,061</b>	<b>0,995</b>

**Tabla 22**

*Comparación de métodos S1.*

Ruido	S1					
Intensidad G1, G2	0,1 - 0,1		0,2 - 0,2		0,3 - 0,3	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	23,429	0,808	23,164	0,798	22,779	0,783
DIP	32,673	0,966	30,973	0,952	29,541	0,945
S2S-WTV	29,617	0,958	28,726	0,955	27,983	0,945
Base	32,608	0,989	31,330	0,982	29,875	0,972
<b>Propuesto</b>	<b>35,224</b>	<b>0,988</b>	<b>33,592</b>	<b>0,986</b>	<b>31,962</b>	<b>0,979</b>


**Tabla 23**

*Comparación de métodos S1 blur.*

Ruido	S1 blur					
Intensidad G1, G2 y blur	0,1 - 0,1 - 1		0,2 - 0,2 - 1		0,3 - 0,3 - 1	
Método	PSNR(dB)	SSIM	PSNR(dB)	SSIM	PSNR(dB)	SSIM
Filtro de la mediana	19,534	0,694	19,447	0,685	19,228	0,670
DIP	32,165	0,956	29,114	0,947	30,089	0,943
S2S-WTV	20,996	0,79	20,474	0,774	20,017	0,745
Base	22,254	0,860	22,141	0,853	21,991	0,841
<b>Propuesto</b>	<b>32,820</b>	<b>0,988</b>	<b>31,501</b>	<b>0,982</b>	<b>30,307</b>	<b>0,974</b>

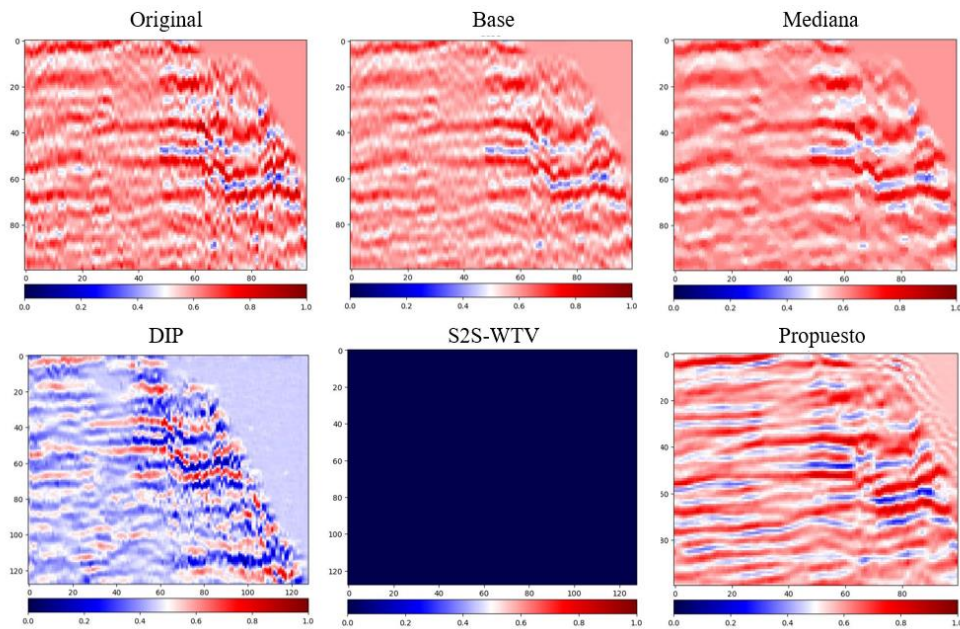
**Figura 30**

*Comparación de métodos en aplicaciones reales Alaska 2D*



**Figura 31**

*Comparación de métodos en aplicaciones reales sección sísmica de campo*



Para estimar el ruido de la imagen real se utilizó la estimación rápida de la varianza del ruido, un método que mediante el cálculo de la varianza determina la suavidad de una imagen y se comparó con los métodos mencionados anteriormente (ver Tabla 24), destacándose el esquema propuesto sobre los demás en la sección sísmica de campo, con respecto a la sección sísmica Alaska 2D debido a la sobre suavización de los métodos DIP y S2S-WTV la métrica dio a favor de ellos, a pesar de que el método preserva mejor la señal original como se puede observar en la Figura 30 y Figura 31.

**Tabla 24**

Comparación de estimación rápida de la varianza del ruido

Sección sísmica de campo		Alaska 2D	
Método	Estimación rápida de la varianza del ruido	Método	Estimación rápida de la varianza del ruido
Original	0,0050	Original	0,0165
Filtro de la mediana	0,0048	Filtro de la mediana	0,0080
DIP	0,0057	DIP	0,0014
S2S-WTV	0,0002	S2S-WTV	N/A
Base	0,0127	Base	0,0127
Propuesto	<b>0,0024</b>	Propuesto	<b>0,0048</b>

El estudio de métricas de estimación de ruido es un campo abierto, puesto que no se conoce la imagen sin ruido. Lo que representa un gran reto al momento de evaluar métodos de atenuación de ruido. Por ejemplo, la métrica utilizada en la Tabla 24 no tiene en cuenta la fidelidad de los datos, por lo tanto, puede causar algunas imprecisiones al comparar los métodos.

## 6. Conclusiones

Se construyó un operador de degradación a partir del análisis sistemático de datos de campo como F3, Kerry 3D y *Blake Ridge Hydrates 3D*, resultando en 16 tipos de ruido identificados y modelados matemáticamente, además de implementar un modelo de transferencia de estilo para adaptar patrones ruidosos de imágenes sísmicas reales. Este operador actúa degradando cada imagen 4 veces, 3 con los ruidos identificados y por último una combinación aleatoria de ruidos para agregarle complejidad similar a la encontrada en datos sísmicos reales. Adicionalmente, para casos especiales de ruido se usa el modelo de transferencia de estilo para incorporar el caso especial entre las degradaciones mencionadas. Con este operador se comprueba la factibilidad de representar ruido sísmico a través de algoritmos computacionales que apuntan a representaciones fieles de la complejidad del ruido sísmico que no dependen exclusivamente de distribuciones conocidas como gaussiana, Poisson, *speckle*, entre otras. Con lo cual se dio por cumplido el objetivo 1.

Se seleccionó y se planteó matemáticamente el modelo generativo PGGAN para la generación de imágenes sísmicas posts-apilados limpias, luego de la implementación y comparación de varios modelos. El modelo seleccionado fue entrenado con imágenes limpias de datos reales y sintéticos que fueron escogidas de los siguientes conjuntos de datos F3, Kerry 3D, *TGS salt Identification challenge*, *SEAM Challenge Phase 1*, *1994 BP migration from topography* y *AGL Elastic Marmousi*. Consiguiendo un modelo confiable para la generación de imágenes sísmicas posts-apilado limpias, coherente con las estructuras presentes en el subsuelo. Comprobando que es posible tener representaciones realistas de escenarios sísmicos 2D limpios haciendo uso de modelos generativos. Dando por cumplido el objetivo 2.

A partir del operador de degradación construido y el modelo generativo implementado se diseñó el esquema de atenuación de ruido, usando los dos componentes anteriores para plantear una base de datos dinámica que guiara el entrenamiento de una red neuronal encargada de la tarea de la atenuación de ruido, para lo cual se escogió una *Attention U-net* que permitió aprender las características de los datos limpios conservando la integridad de las imágenes en el proceso de atenuación. Además, El flujo del esquema se planteó para ejecutar los dos procesos en paralelo, mientras la red está en el proceso de entrenamiento, la base de datos dinámica está generando el siguiente conjunto de imágenes para el entrenamiento de la red. Incrementando la capacidad de generalización de la red mediante la variabilidad del dominio de entrenamiento, el aumento de datos y las representaciones complejas de ruido. Obteniendo así un esquema adaptable a cualquier escenario de atenuación de ruido independientemente de la complejidad. Con lo que se cumplió el objetivo 3.

Se evaluó el esquema realizando ajustes en los parámetros para alcanzar la configuración óptima. Y se comparó su rendimiento con métodos de la literatura como: el filtro de la mediana, S2S-WTV y DIP. Además de realizar la comparación con el método base. De acuerdo con el análisis de métricas el esquema propuesto mostró superioridad en métricas como SSIM y PSNR en cada uno de los 16 tipos de ruido, alcanzando una diferencia de 8,013 dB en promedio para PSNR y 0,130 para SSIM. Adicionalmente se evaluó con datos reales y se comparó el rendimiento con los métodos mencionados, lo que permitió determinar la calidad de la atenuación de ruido en la propuesta y su validez como método. Con lo que se dio por cumplido el objetivo 4.

El esquema propuesto basado en la generación de datos para aumentar la capacidad de generalización en la tarea de atenuación de ruido sísmico en imágenes sísmicas post-apilado, presenta una ventaja, ya que permite aumentar la calidad de las imágenes sísmicas

independientemente del tipo de daño que se presente a la vez que reduce costos computacionales, lo que es de suma importancia en la etapa de interpretación sísmica donde los daños presentes son altamente variables y los métodos más eficientes suelen requerir de equipos de alto rendimiento.

## **7. Recomendaciones**

En trabajos futuros el esquema propuesto podría enfocar la solución de manera alternativa agregando sentido geológico a las redes utilizadas, por ejemplo, que el generador tenga en cuenta los tipos de fallas caracterizados en sísmica, este tipo de cambios podría causar que la red encargada de la atenuación de ruido este menos sesgada con respecto a los tipos de características que debe remover de la imagen, incrementando posiblemente la eficiencia de la tarea.

### Referencias Bibliográficas

- Al-Heety, A. J. R., & Thabit, H. A. (2022). Random and coherent noise attenuation for 2D land seismic reflection line acquired in Iraq. *NRIAG Journal of Astronomy and Geophysics*, *11*(1), 337–354. <https://doi.org/10.1080/20909977.2022.2118982>
- Anello, E. (2021). Variational Autoencoder with Pytorch. DataSeries. Recuperado el 6 de febrero de 2024 de <https://medium.com/dataseries/variational-autoencoder-with-pytorch-2d359cbf027b>
- Chopra, S., & Sharma, R. K. (2016). Synthetic Seismograms for PS Seismic Data. *AAPG (American Association of Petroleum Geologists)*. Recuperado el 31 de enero de 2024, de <https://explorer.aapg.org/story/articleid/28472>
- Du, H., An, Y., Ye, Q., Guo, J., Liu, L., Zhu, D., Childs, C., Walsh, J., & Dong, R. (2022). Disentangling Noise Patterns From Seismic Images: Noise Reduction and Style Transfer. *IEEE Transactions on Geoscience and Remote Sensing*, *60*. <https://doi.org/10.1109/TGRS.2022.3219117>
- Durall, R., Ghanim, A., Fernandez, M., Ettrich, N., & Keuper, J. (2022). *Deep Diffusion Models for Seismic Processing*. <https://doi.org/10.1016/j.cageo.2023.105377>
- Ecopetrol. (2021). Resultados segundo semestre de 2021. Recuperado de <https://www.ecopetrol.com.co/wps/wcm/connect/434f97f9-897e-47a9-a85e-7c83584030af/ESP+-+Resultados+Ecopetrol+2T21.pdf?MOD=AJPERES&attachment=false&id=1628027753144>
- 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 EuropeEC - Europe Energy Conference Featured at the 84th EAGE Annual Conference and Exhibition, EURO 2023*. <https://doi.org/10.2118/214392-MS>

- Gan, S., Wang, S., Chen, Y., & Chen, X. (2015). *Separation of simultaneous sources using a structural-oriented median filter in the flattened dimension.*
- Gao, K., Huang, L., & Cladouhos, T. (2020). *Three-dimensional seismic characterization and imaging of the Soda Lake geothermal field.* <http://arxiv.org/abs/2008.08003>
- Gao, Z., Chen, H., Li, Z., & Ma, B. (2024). Multiscale Residual Convolution Neural Network for Seismic Data Denoising. *IEEE Geoscience and Remote Sensing Letters.* <https://doi.org/10.1109/LGRS.2024.3374810>
- Gatys, L. A., Ecker, A. S., & Bethge, M. (2015). *A Neural Algorithm of Artistic Style.* <http://arxiv.org/abs/1508.06576>
- Gelboim, M., Adler, A., Sun, Y., & Araya-Polo, M. (2023). *Deep Compressed Learning for 3D Seismic Inversion.* <http://arxiv.org/abs/2311.00107>
- Goyes-Penafiel, P., Suarez-Rodriguez, L., Correa, C., & Arguello, H. (2023). *GAN-supervised Seismic Data Reconstruction: An Enhanced-Learning for Improved Generalization.* <http://arxiv.org/abs/2311.10910>
- Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. (2017). *Improved Training of Wasserstein GANs.* <http://arxiv.org/abs/1704.00028>
- Jing, Y., Yang, Y., Feng, Z., Ye, J., Yu, Y., & Song, M. (2017). *Neural Style Transfer: A Review.* <http://arxiv.org/abs/1705.04058>
- Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2017). *Progressive Growing of GANs for Improved Quality, Stability, and Variation.* <http://arxiv.org/abs/1710.10196>
- Ma, X., Yao, G., Yuan, S., Zhang, F., & Wu, D. (n.d.). *Seismic Coherent Noise Removal with Residual Network and Synthetic Seismic Simples.*

- Makinen, Y., Azzari, L., & Foi, A. (2020). Collaborative Filtering of Correlated Noise: Exact Transform-Domain Variance for Improved Shrinkage and Patch Matching. *IEEE Transactions on Image Processing*, 29, 8339–8354. <https://doi.org/10.1109/TIP.2020.3014721>
- Malehmir, A., Markovic, M., Marsden, P., Gil, A., Buske, S., Sito, L., Bäckström, E., Sadeghi, M., & Luth, S. (2021). Sparse 3D reflection seismic survey for deep-targeting iron oxide deposits and their host rocks, Ludvika Mines, Sweden. In *Solid Earth* (Vol. 12, Issue 2, pp. 483–502). Copernicus GmbH. <https://doi.org/10.5194/se-12-483-2021>
- Mandelli, S., Lipari, V., Bestagini, P., & Tubaro, S. (2019). *Interpolation and Denoising of Seismic Data using Convolutional Neural Networks*. <http://arxiv.org/abs/1901.07927>
- Mansimov, E., Parisotto, E., Ba, J. L., & Salakhutdinov, R. (2015). *Generating Images from Captions with Attention*. <http://arxiv.org/abs/1511.02793>
- Oktay, O., Schlemper, J., Folgoc, L. Le, 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*. <http://arxiv.org/abs/1804.03999>
- OpendTect. (s.f.). Dip-Steered Median Filter. Recuperado el 30 de enero de 2024, de [https://doc.opendtect.org/6.6.0/doc/dgb\\_userdoc/content/default\\_attribute\\_sets/dip-steered\\_median\\_filter.htm](https://doc.opendtect.org/6.6.0/doc/dgb_userdoc/content/default_attribute_sets/dip-steered_median_filter.htm)
- Peng, J., Li, Y., Liao, Z., Wang, X., & Yang, X. (2023). *Seismic Data Strong Noise Attenuation Based on Diffusion Model and Principal Component Analysis*. <http://arxiv.org/abs/2309.04944>
- Terranubis. (s.f.). TerraNubis - Commercial marketplace for seismic products, <https://terranubis.com/>
- University of British Columbia. (s.f.). Filtering of Seismic Data. Recuperado el 30 de enero de 2024, from [https://www.eoas.ubc.ca/courses/eosc350/content/methods/meth\\_10d/filter](https://www.eoas.ubc.ca/courses/eosc350/content/methods/meth_10d/filter)

- Ulyanov, D., Vedaldi, A., & Lempitsky, V. (2017). *Deep Image Prior*. <https://doi.org/10.1007/s11263-020-01303-4>
- Voetman, R., Aghaei, M., & Dijkstra, K. (2023). *The Big Data Myth: Using Diffusion Models for Dataset Generation to Train Deep Detection Models*. <http://arxiv.org/abs/2306.09762>
- Wei, X., Zhang, C., Wang, H., Tan, C., Xiong, D., Jiang, B., Zhang, J., & Kim, S.-W. (2023). *Seismic Data Interpolation based on Denoising Diffusion Implicit Models with Resampling*. <http://arxiv.org/abs/2307.04226>
- Wu, H., Zhang, B., & Liu, N. (2022). Self-adaptive denoising net: Self-supervised learning for seismic migration artifacts and random noise attenuation. *Journal of Petroleum Science and Engineering*, 214. <https://doi.org/10.1016/j.petrol.2022.110431>
- Xiao, Z., Kreis, K., & Vahdat, A. (2021). *Tackling the Generative Learning Trilemma with Denoising Diffusion GANs*. <http://arxiv.org/abs/2112.07804>
- Xu, Z., Luo, Y., Wu, B., & Meng, D. (2022). *S2S-WTV: Seismic Data Noise Attenuation Using Weighted Total Variation Regularized Self-Supervised Learning*. <https://doi.org/10.1109/TGRS.2023.3268554>
- Zhang, H., Alkhalifah, T., Liu, Y., Birnie, C., & Di, X. (2023). Improving the Generalization of Deep Neural Networks in Seismic Resolution Enhancement. *IEEE Geoscience and Remote Sensing Letters*, 20. <https://doi.org/10.1109/LGRS.2022.3229167>
- Zhang, K., Zuo, W., Chen, Y., Meng, D., & Zhang, L. (2016). *Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising*. <https://doi.org/10.1109/TIP.2017.2662206>

## Apéndices

**Apéndice A.** Enlace del repositorio de GitHub donde se aloja el código del proyecto.

[https://github.com/TJaqui/Seismic\\_denoising\\_scheme](https://github.com/TJaqui/Seismic_denoising_scheme)