

Algoritmo de reconstrucción de fuentes sísmicas usando aprendizaje profundo basado en los
datos adquiridos

Luis Miguel Rodríguez López

Trabajo de Grado para Optar al Título de Ingeniero de Sistemas

Director

Laura Viviana Galvis

PhD. en Ingeniería Eléctrica y Computación

Codirector

Henry Arguello Fuentes¹, Kareth Marcela León López²

PhD. en Ingeniería Eléctrica y Computación¹, PhD. en Ciencias de la Computación²

Universidad Industrial de Santander

Facultad de Fisicomecánicas

Escuela de Ingeniería de Sistemas e Informática

Ingeniería de Sistemas

Bucaramanga

2023

Dedicatoria

A mis padres y familia, que desde el comienzo me brindaron su apoyo.

A mis docentes y compañeros, que hicieron parte del aprendizaje y crecimiento.

A mis amigos del Valorant, que este año si lleguemos a Radiant.

A mi bebé gorda Natasha.

A Lionel Andrés Messi, que ganando la Copa del Mundo me enseñó a nunca rendirme.

Agradecimientos

Este trabajo de grado fue realizado en el marco del proyecto con código 110287780575 - “Nuevas tecnologías computacionales para el diseño de geometrías de adquisición sísmica 3D con muestreo compresivo para la reducción de costos económicos e impactos ambientales en la exploración de hidrocarburos en cuencas terrestres colombianas”, financiado con recursos provenientes del Convenio 785-2019, suscrito entre la Agencia Nacional de Hidrocarburos, el MINISTERIO y el Fondo Nacional de Financiamiento para la Ciencia, la Tecnología y la Innovación Francisco José de Caldas.

Personalmente, agradezco a Dios por darme la fuerza y sabiduría para afrontar cada reto en el transcurso de mi vida.

Al director del grupo de investigación HDSP, Henry Arguello Fuentes, por su apoyo y por darme la oportunidad de crecer como estudiante y persona, al ser parte del grupo.

A Laura Viviana Galvis, directora de este proyecto, por su gran apoyo y su valioso asesoramiento.

A Kareth Marcela León, codirectora de este proyecto, por acompañarme desde el principio en mi estadía en el grupo HDSP, por su gran apoyo, su paciencia y su guía.

A mis compañeros y amigos del grupo HDSP, en especial a Paul Goyes, quien de forma desinteresada e incondicionalmente brindó un valioso apoyo y asesoramiento en la realización de este proyecto.

A mi familia y cada uno de mis amigos, compañeros y profesores de la Universidad Industrial de Santander, que de uno u otra forma contribuyeron en mi desarrollo como estudiante y como persona.

Tabla de Contenido

	Pág.
Introducción	11
1. Planteamiento del problema y justificación	14
2. Objetivos	16
2.1. Objetivo General	16
2.2. Objetivos específicos	16
3. Marco de referencia	17
3.1. Adquisición sísmica	17
3.1.1. Unidad de geometría Cross-spread	19
3.1.2. Pérdida de datos en una unida de geometría Cross-spread	20
3.2. Problema de reconstrucción de datos sísmicos	22
3.3. Algoritmos de reconstrucción de datos sísmicos	23
3.3.1. Algoritmos de aprendizaje profundo para la reconstrucción de datos sísmicos	24
3.3.2. Metodología DIP para la reconstrucción de datos sísmicos	27
4. Metodología	30
4.1. Formulación matemática del modelo de adquisición.....	30
4.2. Formulación del problema de reconstrucción usando DL basado en DIP	31
4.2.1. Datos de entrada.....	33
4.2.2. Operador de correlación.....	34
4.2.3. Arquitectura de la red neuronal convolucional	37
4.3. Modelo de reconstrucción de datos sísmicos usando DL basado en DIP	38

4.4. Implementación del modelo de reconstrucción de datos sísmicos	41
4.4.1. Pseudocódigo del algoritmo.....	41
4.4.2. Implementación computacional del algoritmo de reconstrucción de disparos	42
5. Configuración experimental.....	44
5.1. Métricas.....	44
5.1.1. Proporción máxima de señal a ruido (PSNR)	44
5.1.2. Medida del índice de similitud estructural (SSIM).....	45
5.2. Conjuntos de datos sísmicos	45
5.2.1. Datos sísmicos sintéticos	45
5.2.2. Datos sísmicos reales	46
5.3. Diseño de experimentos.....	47
5.3.1. Configuración del modelo base	48
5.3.2. Configuración modelo SRDIP	50
6. Análisis de resultados	51
6.1. Evaluación del algoritmo	51
6.2. Comparación con algoritmos de estado del arte	54
6.3. Resultados datos sísmicos reales	56
6.3.1. Extensión del método propuesto a datos marinos.....	57
7. Conclusiones	61
8. Trabajo futuro	63
Referencias Bibliográficas	64

Lista de Tablas

	Pág.
Tabla 1 Métricas PSNR y SSIM para cada variación de parámetros.	52
Tabla 2 Métricas PSNR y SSIM de los disparos con índice 7 y 12 correspondiente a los datos sintéticos en el dominio TX y FK.	53
Tabla 3 Evaluación de desempeño entre el método propuesto SRDIP, SBI y CE, con las métricas PSNR, SSIM, PSNR en dominio TX y FK y tiempo de ejecución.	55
Tabla 4 Métricas PSNR y SSIM de los disparos con índice 7 y 12 correspondiente a los datos reales en el dominio TX y FK.	57
Tabla 5 Métricas PSNR y SSIM de los disparos con índice 7 y 12 correspondiente a los datos marinos en el dominio TX y FK.	59

Lista de Figuras

	Pág.
Figura 1 Geometría de adquisición. Adaptado de Chaouch & Mari (2006).....	18
Figura 2 Bosquejo de la trayectoria de la señal de la fuente en el dominio Cross-spread. Adaptado de Liner (2016).	19
Figura 3 Representación de una variación en el diseño de una unidad de geometría Cross-spread.	20
Figura 4 Ilustración de los datos sísmicos correspondientes cuando se adquieren usando una unidad de geometría Cross-spread.	21
Figura 5 Geometría ortogonal 3D adquirida en Colombia.	22
Figura 6 Arquitectura de aprendizaje profundo U-Net (Kuijpers, 2021).....	26
Figura 7 Esquema de modelo de reconstrucción de trazas.	29
Figura 8 Ilustración del operador de muestreo.	31
Figura 9 Representación de la expansión de los datos observados.....	33
Figura 10 Representación de la suma entre los datos observados expandidos y el ruido aleatorio uniforme.	34
Figura 11 Representación del funcionamiento del operador de correlación.....	35
Figura 12 U-Net 3D para la reconstrucción de disparos.....	38
Figura 13 Esquema del modelo de reconstrucción de disparos con SRDIP.	39
Figura 14 Esquema del modelo entrenado para estimar disparos.....	40
Figura 15 Captura implementación en Colaboratory.....	43
Figura 16 Datos sintéticos utilizados para las simulaciones y experimentos.	46

Figura 17 Datos reales utilizados para las simulaciones y experimentos.	47
Figura 18 Esquema de adquisición cross-spread con las 5 fuentes eliminadas.	48
Figura 19 Esquema del modelo base de reconstrucción de disparos.	49
Figura 20 Comparativa visual de los resultados obtenidos en la reconstrucción de disparos correspondiente a los datos sintéticos en el dominio TX y FK.....	53
Figura 21 Comparativa visual de los resultados obtenidos en la reconstrucción de disparos con el método propuesto SRDIP, SBI y CE en el dominio TX y FK.....	54
Figura 22 Comparativa visual de los resultados obtenidos en la reconstrucción de la traza 60 con el método propuesto SRDIP, SBI y CE en el dominio TX.....	55
Figura 23 Comparativa visual de los resultados obtenidos en la reconstrucción de disparos correspondiente a los datos reales en el dominio TX y FK.	56
Figura 24 Comparativa visual de los resultados obtenidos en la reconstrucción de disparos de los datos marinos.	58
Figura 25 Comparativa visual de los resultados obtenidos en la reconstrucción de disparos correspondientes a los datos marinos en el dominio TX y FK.	59

Resumen

Título: Algoritmo de reconstrucción de fuentes sísmicas usando aprendizaje profundo basado en los datos adquiridos.

Autor: Luis Miguel Rodríguez López.

Palabras Clave: Reconstrucción de fuentes sísmicas, Aprendizaje profundo, Aprendizaje profundo únicamente con datos observados, Dominio de propagación cruzada.

Descripción: Los levantamientos sísmicos a menudo se ven afectados por la irregularidad y el muestreo resultante de las limitaciones en la adquisición, como obstáculos y restricciones ambientales. Por lo tanto, se han desarrollado varios algoritmos para reconstruir estos datos faltantes, incluida la interpolación basada en transformadas y métodos de reconstrucción basados en aprendizaje profundo, donde este último permite extraer estructuras más completas, pero requiere bases de datos sísmicos externos. Alternativamente, los métodos de imagen-previa-profunda (DIP del inglés *Deep Image Prior*) mitigan el uso de información de entrenamiento extensa al considerar solo los datos observados, mostrando resultados prometedores en la recuperación de trazas sísmicas. Este trabajo propone una red neuronal convolucional basada en DIP para recuperar fuentes perdidas en un levantamiento sísmico tridimensional (3D) que explota, como datos previos, los datos adquiridos y la estructura de la red neuronal convolucional. Además, teniendo en cuenta la correlación en el dominio de origen, se emplea un operador para desplazar verticalmente el conjunto de trazas para tener la máxima correlación de datos en la red. Experimentos numéricos muestran que la red propuesta recupera el conjunto completo de trazas en cada toma-recopilación, donde la información y los eventos se conservan, aunque no se adquiriera la fuente.

Abstract

Title: Seismic sources reconstruction algorithm using deep learning based on the acquired data.

Author(s): Luis Miguel Rodríguez.

Key Words: Shots recovering, Deep learning, Deep image prior, Cross-spread domain.

Description: Seismic surveys are often affected by irregularity and coarse sampling resulting from limitations at the acquisition such as obstacles and environmental constraints. Thus, various processing algorithms have been developed to reconstruct these missing data, including interpolation based on transforms and deep learning-based reconstruction methods, where the latter allows the extraction of more complete structures, but require external seismic databases. Alternatively, deep-image-prior (DIP) methods mitigate the use of extensive training information by considering only the data under observation, showing promising results in recovering seismic traces. This work proposes a DIP-based convolutional neural network for recovering missing sources in a three-dimensional (3D) seismic survey which exploits as priors the data acquired and the structure of the 3D network. Additionally, considering the correlation across the source domain, an operator is employed for vertically shifting the set of traces to have the maximum data correlation in the network. Numerical experiments show that the proposed network recovers the complete set of traces in each shot-gather, where the information and events are preserved even though the source is not acquired.

Introducción

Los datos sísmicos en dos o tres dimensiones permiten representar las características geológicas del subsuelo a través de la propagación de ondas generadas por fuentes que miden el comportamiento del suelo a lo largo de una superficie. Estos datos juegan un papel importante en la industria del petróleo, ya que brindan información para la exploración de petróleo e hidrocarburos tales como la caracterización e información de límites de los yacimientos petroleros, fallas geológicas y detección de fluidos (Hatton, 1986). A partir de estos y utilizando diferentes tipos de procesamiento (como el análisis de velocidades, corrección de corrimiento normal (NMO del inglés normal moveout), apilado bruto, migración e inversión sísmica) es posible obtener imágenes con la variación de la velocidad y la densidad del subsuelo (ANH, 2010). En la exploración sísmica, se busca adquirir datos con alta resolución y calidad, ya que esto impacta de manera directa el procesamiento sísmico y las imágenes sísmicas resultantes del subsuelo, para lograr dichos estándares, se debe garantizar un diseño de geometrías de adquisición densa y uniforme (Chaouch, 2006).

El levantamiento sísmico consiste en distribuir en el terreno de interés una serie de fuentes que generan ondas que se propagan por el subsuelo, y cuya energía se refleja y/o transmite de acuerdo a las propiedades físicas de sus capas. Luego, la energía reflejada que llega a la superficie es captada por un conjunto de receptores o geófonos (ANH, 2010). Las coordenadas de las fuentes y los receptores con separación uniforme y densa conforman la geometría diseñada (también llamado pre-plot). Sin embargo, durante la adquisición, la geometría puede presentar variaciones, debido a que en un levantamiento sísmico tridimensional se pueden llegar a afrontar factores que

afectan la calidad del diseño sísmico tales como factores operacionales, económicos o geológicos. Estos factores pueden producir cambios que impactan el número de fuentes o receptores en el pre-plot, ocasionando que no se logre recolectar suficiente información del subsuelo, limitando así el levantamiento sísmico (ANH, 2010; Liner, 2016), el diseño resultante de este proceso es conocido como post-plot. Dado que existe la posibilidad de perder un disparo completo (o un conjunto de trazas) o el requerimiento suplir la información faltante (para lograr mayor resolución) al conjunto de datos, se han planteado diferentes metodologías para reconstruir disparos o trazas faltantes tanto de forma regular como irregular (Kong, 2020; Villarreal, 2019; Goyes, 2022). Reconstruir datos en forma regular implica que los datos faltantes están ubicados de manera equidistante o periódica a una tasa constante en cuadrículas uniformes, y de forma irregular, que los datos faltantes están ubicados aleatoriamente.

Los enfoques propuestos en la literatura, hasta la fecha, principalmente han buscado la reconstrucción de trazas, es decir, la respuesta de las ondas en un solo receptor (Lui, 2015; Yang, 2012; Kong, 2020; Liu, 2021). Para realizar estas reconstrucciones se han desarrollado diferentes técnicas de interpolación o estimación a partir de metodologías basadas en filtros, en el operador de campo de onda por medio de transformadas (Fourier) y en algoritmos basados en la escasez de la señal (*sparse*) (Lui, 2015; Yang, 2012; Kazemi, 2016). Actualmente en el área de aprendizaje profundo (DL del inglés *deep learning*) se han aplicado variedad de métodos para la reconstrucción de datos sísmicos utilizando diferentes arquitecturas para el modelo de aprendizaje computacional (Chai, 2020; Mandelli, 2018), ya que ha mostrado ser una herramienta muy útil para extraer características de los datos y realizar una mejor interpolación en comparación con métodos convencionales (Kelleher, 2019). Una desventaja de DL es el requerimiento de grandes volúmenes

de datos, y en la industria sísmica no siempre es posible contar con los mismos, debido a las restricciones de acceso a la información y confidencialidad. Por lo tanto, se ha generado un nuevo campo de investigación en aplicación de nuevas técnicas que aborden esta problemática usando solamente los datos adquiridos para el entrenamiento de los modelos. Actualmente, en el estado del arte, se ha propuesto una metodología de DL sin datos de entrenamiento (o DIP del inglés *deep image prior*) (Ulyanov, 2018), también llamada DL a partir de datos observados, que solo requiere los datos bajo observación o adquiridos y una red neuronal convolucional lo suficientemente profunda para extraer todas las características necesarias para la reconstrucción de la imagen o tarea en específico a realizar, tal como eliminación de ruido o superresolución. Dicha metodología ha sido implementada para la reconstrucción de datos sísmicos, en específico la reconstrucción de trazas (Kong, 2020; Liu, 2021), esta particularidad ayuda a reducir el costo computacional del entrenamiento y, a su vez, la gran carga de datos requerida para generalizar un modelo basado en DL. Actualmente, esta metodología no ha sido explorada para la reconstrucción de disparos completos, dicha implementación lograría reducir costos de adquisición en el levantamiento sísmico y un conjunto de datos con información más densa o completa que pueda representar el subsuelo.

En este proyecto se desarrolla un algoritmo de reconstrucción de disparos sísmicos desde medidas incompletas bajo el enfoque de aprendizaje profundo únicamente partir de los datos observados, enfocado directamente en las problemáticas actuales en adquisición sísmica antes mencionadas. El algoritmo evalúa sobre datos sísmicos reales y sintéticos adquiridos en el dominio de propagación cruzada (o *cross-spread* en inglés).

1. Planteamiento del problema y justificación

Antes de realizar un levantamiento sísmico se define una geometría para determinar las coordenadas geográficas de las fuentes y los receptores, pero existen ciertas limitantes que obstaculizan la implementación total del diseño de dicha geometría, de tal manera que se impide obtener la información completa de la zona geográfica debido a que las posiciones de las fuentes y receptores se pueden ver restringidas por ciertos factores ambientales. Por otro lado, también existen limitantes económicas que tienen que ver con el presupuesto disponible para cubrir los costos del proceso, así como limitantes geofísicas, que corresponden a los parámetros de la adquisición relacionados con la calidad final de la adquisición. Debido a estas limitaciones que influyen en el posicionamiento de las fuentes y receptores usadas en la adquisición (ANH, 2010) se produce una falta de información en el conjunto resultante de datos. Por lo tanto, se han desarrollado diversos algoritmos de procesamiento para la reconstrucción de estos datos (Ochoa, 2017), donde la interpolación basada en el uso de transformadas es una de las técnicas más usadas en la industria (Lui, 2015; Yang, 2012).

En el área de aprendizaje profundo, se han planteado métodos de reconstrucción o estimación de esta información (Goyes, 2022; Chai, 2020). En particular, la metodología DIP basada en datos observados ha mostrado excelentes resultados en problemas inversos estándar (Ulyanov, 2018). Este enfoque permite reducir el número de datos de entrenamiento a solo los datos observados, lo que constituye una gran ventaja ya que reduce costos computacionales y de procesamiento de datos. Adicionalmente, en sísmica esto es de gran importancia debido a la dificultad de generar bases de datos extensas para el entrenamiento de una red neuronal

convolucional, por la confidencialidad que tienen los datos, o la escasa variedad de características para la reconstrucción. Por lo tanto, estas restricciones dificultan obtener un conjunto de datos óptimo para el entrenamiento de una red convolucional, que da como resultado reconstrucciones con baja calidad (Liu, 2021).

Actualmente, en el estado del arte se ha comprobado la funcionalidad del enfoque DIP en la reconstrucción de trazas (Kong, 2020; Liu, 2021). Sin embargo, hasta la fecha, éste no ha sido explorado en la reconstrucción de conjuntos de trazas o disparos de interés para levantamientos sísmicos 3D con pérdida de disparos completos. Por lo tanto, este trabajo busca explorar el enfoque DIP en la reconstrucción de disparos sísmicos tomando ventaja de la geometría *cross-spread* de los datos 3D para así aprovechar su correlación.

2. Objetivos

2.1. Objetivo General

Desarrollar un algoritmo de reconstrucción de fuentes sísmicas usando aprendizaje profundo basado en los datos adquiridos en arreglos ortogonales *cross-spread*.

2.2. Objetivos específicos

- Determinar el modelo matemático de un sistema de adquisición de disparos sísmicos parcialmente observados en el dominio *cross-spread* (ver sección 4.1).
- Plantear el problema de reconstrucción de disparos sísmicos usando un enfoque de aprendizaje profundo basado en los datos observados (ver sección 4.2).
- Implementar un algoritmo para resolver el problema de reconstrucción planteado (ver sección 4.4).
- Evaluar el algoritmo propuesto usando datos reales y simulados (ver sección 6).

3. Marco de referencia

3.1. Adquisición sísmica


La adquisición de datos sísmicos se realiza a través de un levantamiento sísmico que consiste en generar ondas sísmicas por medio de fuentes, generalmente creadas con dinamita o por instrumentos mecánicos colocados en vehículos. El tipo de fuente es seleccionada dependiendo la importancia de mantener la integridad del terreno, por ejemplo, la dinamita puede causar daños a su entorno (ANH, 2010). Las ondas generadas recorren el subsuelo reflejándose o transmitiéndose a medida que las propiedades físicas del terreno cambian, a esto se les llama interfaces. Estas reflexiones son capturadas por receptores o geófonos, donde se capta la variación de la ondícula a través del tiempo. Luego, esta información se guarda de forma digital para un procesamiento posterior que permite conocer la velocidad de las ondas reflejadas, en donde la calidad de esta estimación depende de la densidad tanto de fuentes como de receptores (ANH, 2010).

En los últimos años, se ha evidenciado un gran progreso en la adquisición de datos sísmicos en 3D debido a que estos datos se utilizan cada vez más como herramienta para el proceso de exploración y producción (Liner, 2016). Para adquirir los datos, primeramente, se debe realizar una planificación previa, dicha planificación está formada por el testeado de parámetros ambientales, requisitos de seguridad, el entorno, entre otros. En la planificación previa de los levantamientos 3D, es de suma importancia asegurar la calidad de los datos a adquirir. Los datos deben cumplir con diferentes parámetros, como la estructura, requisitos de litología y estratigrafía. La litología estudia las propiedades que conforman una determinada formación geológica y la estratigrafía estudia la historia y evolución del subsuelo (Chaouch, 2006; Glossary, 2022).

En la planificación, se diseña la geometría de adquisición, la cual define las posiciones de las líneas de fuentes y receptores, y el número de cada una de estas por línea, como se muestra en la Figura 1.

Figura 1

Geometría de adquisición. Adaptado de Chaouch & Mari (2006).



En general, existen diferentes geometrías tales como la de andana (o *swath* en inglés), franja, perímetro, ortogonal, entre otras (Liner, 2016). En el siguiente inciso se va a profundizar en una unidad de una geometría de adquisición ortogonal fundamental llamada propagación cruzada. Es importante mencionar que, aunque se tenga una geometría base, en un levantamiento sísmico los costos económicos o dificultades ambientales generan un muestreo no uniforme que


da como resultado datos incompletos, estos son elementos que influyen a su vez a la hora de escoger la geometría de adquisición a ser usada.

3.1.1. Unidad de geometría *Cross-spread*

La adquisición basada en la unidad de geometría *cross-spread* está compuesta por una línea de fuentes y una de receptores ubicados de forma ortogonal entre sí, formando así un área de cobertura de puntos medios tal y como se ilustra en la Figura 2, conjuntamente se produce un área de punto de reflexión en la superficie reflectante la cual hace que parte de la onda o señal generada por las fuentes viaje nuevamente a la superficie y sea captada por los receptores.

Figura 2

Bosquejo de la trayectoria de la señal de la fuente en el dominio Cross-spread. Adaptado de Liner (2016).




Al realizar un levantamiento con esta geometría se tienen en cuenta varios parámetros, tales como las coordenadas para cada fuente y receptor, distribución de azimuth (que se logra al trazar una línea que conecta cada par de receptor con un disparo), y tamaño del contenedor (o *bin* en inglés), que es el área en la que se superpone una cuadrícula en el levantamiento. En particular, el tamaño natural del contenedor se determina por los parámetros de adquisición y los intervalos de punto medio, el cual, a su vez, determina la resolución de los datos (Liner, 2016).

3.1.2. Pérdida de datos en una unidad de geometría *Cross-spread*

La Figura 3 muestra un ejemplo de una unidad de geometría *Cross-spread*, donde el pre-plot fue diseñado con 4 disparos alineados. No obstante, debido a diferentes causas logísticas o ambientales, un disparo (en color negro) no fue adquirido en campo, siendo esto una variación respecto a la geometría diseñada (ANH, 2010). Por lo cual, se dice que hubo una pérdida de la información en la fase de adquisición.

Figura 3

*Representación de una variación en el diseño de una unidad de geometría *Cross-spread*.*




Un levantamiento sísmico con una unidad de geometría *Cross-spread* representa una ventaja desde el punto de vista de organización matricial de los datos, ya que cada disparo es registrado por la misma línea de receptores lo que permite generar cubos a partir de un apilamiento (o *stacking* en inglés) de cada fuente sísmica como se muestra en la Figura 4. A partir de este cubo de datos es posible generar diferentes enfoques de reconstrucción que consisten en determinar la mejor estimación de una rebanada dentro del cubo a partir de la información cercana o adyacente (ANH, 2010).

Partiendo de la variación en el diseño de una unidad de geometría *cross-spread* ilustrada en la Figura 3, se tiene como resultado un conjunto o cubo de datos sísmicos con un disparo perdido (en negro), teniendo un cubo únicamente con 3 disparos como se puede observar en la Figura 4.

Figura 4

Ilustración de los datos sísmicos correspondientes cuando se adquieren usando una unidad de geometría Cross-spread.




En la Figura 5 se muestra un conjunto de datos reales adquiridos en Colombia, en donde se puede observar con una mayor claridad como se compone un conjunto de datos en el dominio

cross-spread, en el cual se adquirieron 32 disparos, cada disparo está compuesto por 180 receptores y una separación de 20 metros entre ellos (López, 2019).

Figura 5

Geometría ortogonal 3D adquirida en Colombia.



3.2. Problema de reconstrucción de datos sísmicos

En el problema de reconstrucción de datos sísmicos, se tiene una señal sísmica que se puede representar como una matriz tridimensional $\mathbf{X} \in \mathbb{R}^{M \times N \times L}$, donde M , N y L son el número de muestras en el tiempo, receptores y fuentes sísmicas respectivamente. En una adquisición sísmica donde se tiene variaciones respecto a la geometría (como se muestra en la Figura 4) se obtiene como resultado unas medidas comprimidas $\mathbf{Y}$, donde los disparos faltantes se representan con ceros o se remueven de la matriz de datos completos según el enfoque. El proceso de adquisición ha sido

modelado matemáticamente como un sistema lineal (López, 2019) o como operadores que actúan sobre las matrices de los datos completos (Lui, 2021).

A partir de lo mencionado anteriormente se tiene que el problema de reconstrucción de datos sísmicos consiste en estimar $\mathbf{X}$ a partir de $\mathbf{Y}$. Esto se puede expresar como un problema de optimización a partir de la minimización de un término de fidelidad de los datos y otros términos de regularización basados en información previa del dato, dicho problema de optimización se puede representar de la siguiente forma:

$$\hat{\mathbf{X}} = \underset{\mathbf{X}}{\text{minimizar}} \left\{ \left(\frac{1}{2} \right) \|\mathbf{Y} - \mathcal{H}(\mathbf{X})\|_2^2 + \lambda \mathcal{R}(\mathbf{X}) \right\}, \quad (1)$$

donde $\mathcal{H}$ es un operador que modele el proceso de adquisición sísmica, el primer término es el modelo de adquisición para establecer la fidelidad de los datos, y el segundo término es un regularizador que establece un condicionamiento el cual es controlado por λ (Goyes, 2022).

3.3. Algoritmos de reconstrucción de datos sísmicos

Para la reconstrucción de datos sísmicos se han propuesto algoritmos de preprocesamiento y post-procesamiento, que permiten estimar o completar la información a partir de los datos adquiridos (Villarreal, 2019; Goyes, 2022; Ochoa, 2017; Galvis, 2020). Entre las estrategias más destacadas durante el flujo de procesamiento sísmico está la interpolación 5D, la cual es una interpolación sísmica 3D que como base considera cinco variables: CMPX, CMPY, offset, azimut, tiempo/frecuencia (Ochoa, 2017). También existen otros algoritmos basados en la proyección sobre conjuntos convexos (POCS del inglés *Projection Onto Convex Sets*) (Yang, 2012) o algoritmos basados en la descomposición en valores propios truncados (T-SVD) (Ochoa, 2017).

Los algoritmos mencionados anteriormente reconstruyen receptores o trazas. No obstante, cuando existe la pérdida de información causada por la ausencia de una fuente sísmica, todas las trazas que comparten una fuente en común deben ser reconstruidas. Esto causa un aumento en la complejidad del problema de reconstrucción.

Actualmente, en el estado del arte se han propuesto metodologías para la reconstrucción de disparos/fuentes sísmicas basados en el muestreo compresivo, como la propuesta por Goyes (2022) Consensus Equilibrium (CE) la cual incorpora varios operadores de regularización para modelar diferentes datos. También existen algoritmos de interpolación basados en la escasez (SBI), como el propuesto por Villarreal (2019), resuelto con el algoritmo ADMM. A partir de la ecuación (1) el algoritmo SBI propone el siguiente problema de optimización para la solución del problema de reconstrucción:

$$\hat{\mathbf{x}} = \underset{\mathbf{x}}{\text{minimizar}} \left\{ \left(\frac{1}{2} \right) \|\mathbf{Y} - \Phi \mathbf{x}\|_2^2 + \lambda \|\Psi^T \mathbf{x}\|_1 \right\}, \quad (2)$$

siendo $\mathcal{H}(\mathbf{X}) = \Phi \mathbf{x}$, donde $\mathbf{x}$ es la vectorización de $\mathbf{X}$ y Φ es una matriz de muestreo cuya diagonal representa en unos los disparos adquiridos y con ceros los disparos eliminados, $\lambda=0.001$ y como regularizador se tiene la norma L1 que promueve la escasez en una base de transformación Ψ wavelet. La principal desventaja de esta metodología es el ruido de los datos sísmicos ya que afecta la representación en otros dominios, de forma que la señal no es totalmente *sparse*.

3.3.1. Algoritmos de aprendizaje profundo para la reconstrucción de datos sísmicos

El aprendizaje profundo (DL, por sus siglas en inglés) es una forma de aprendizaje automático en la que una red neuronal aprende características a partir de un conjunto voluminoso

de datos llamados datos de entrenamiento (Kelleher, 2018; LeCun, 2015). DL ha sido usado en diferentes aplicaciones tales como la conducción autónoma, procesamiento de imágenes médicas, reconocimiento automático de imágenes, predicción de series de tiempo, generación de texto, entre otros (Ibtehaz, 2020; Ronneberger, 2015). Para las diferentes aplicaciones se han desarrollado una gran variedad de arquitecturas a partir de los tipos de redes, como las redes neuronales profundas (DNN del inglés *Deep Neural Network*), redes neuronales convolucionales (CNN del inglés *Convolutional Neural Network*), redes neuronales recurrentes (RNN del inglés *Recurrent Neural Network*), entre otras.


Particularmente, las CNN han estado a la vanguardia en numerosas tareas como reconocimiento visual, clasificación y reconstrucción, tanto de señales e imágenes (Ibtehaz, 2020; Ronneberger, 2015). Las CNN están compuestas por capas convolucionales, las cuales realizan una operación de convolución entre el dato de entrada y filtro o kernel (Kelleher, 2018; LeCun, 2015).

Dentro de las diferentes arquitecturas basadas en redes neuronales del estado del arte, se destaca la arquitectura U-Net, inicialmente desarrollada para segmentación de imágenes médicas (Chai, 2020; Ibtehaz 2020; Ronneberger, 2015), y posteriormente, extrapolada a problemas como reconstrucción de trazas sísmicas (Chai, 2020). La estructura de la U-Net es tipo codificador-decodificador, el codificador extrae las características más representativas de la señal y el decodificador genera una reconstrucción de la señal a partir de las características extraídas en el codificador. En la Figura 6 se ilustra el esquema de la arquitectura U-Net, donde cada cuadro representa el mapa de características, los asteriscos representan las capas convolucionales las

cuales van acompañadas de una función de activación y una normalización, las flechas hacia abajo representan la función de *downsampling*, las cuales reducen el tamaño del dato, las flechas hacia arriba representan la función de *upsampling*, las cuales aumentan el tamaño del dato, y por último en cada nivel se encuentra una flecha horizontal que representa una conexión de salto (o *skip connection* en inglés) esto con el fin de minimizar la pérdida de rendimiento en este tipo de redes tan profundas.

Figura 6

Arquitectura de aprendizaje profundo U-Net (Kuijpers, 2021).



Actualmente, en el estado del arte, se ha implementado DL para la reconstrucción tanto de trazas (datos 2D) y en menor medida de disparos (datos 3D), implementando redes neuronales convolucionales con arquitecturas tipo autoencoder o U-Net (Chai, 2020; Mandelli, 2018; Mandelli, 2019). Cabe resaltar que para realizar las simulaciones se usa un banco de datos sísmicos sintéticos ya que existen varias dificultades para adquirir datos sísmicos reales. El problema de

optimización basado en DL para la reconstrucción de datos sísmicos se puede representar de la siguiente forma:

$$\theta^* = \underset{\theta}{\text{minimizar}} \left\{ \left(\frac{1}{n} \right) \sum_{i=0}^n ||\mathbf{X}_i - f_{\theta}(\mathbf{Y}_i)||_2^2 \right\}, \quad (3)$$

donde n es el número de muestras para el entrenamiento de la CNN f_{θ} , con el fin de encontrar los pesos óptimos de la red θ^* y reducir la diferencia entre la salida de f_{θ} y cada una de las muestras del conjunto de datos de entrenamiento $\mathbf{X}_i$.

Se suelen usar datos sintéticos debido a que mientras el conjunto de datos sea más extenso la red puede extraer una mayor cantidad de características, lo que a su vez genera un mayor costo computacional. Debido a esto, los métodos propuestos pueden presentar malas reconstrucciones al aplicarlos en zonas geográficas con propiedades diferentes a las de los datos de entrenamiento.

3.3.2. Metodología DIP para la reconstrucción de datos sísmicos

Recientemente se ha implementado una metodología de reconstrucción de imágenes naturales basada solamente en los datos observados (o DIP de las siglas *Deep image prior*) (Ulyanov, 2019), que ha mostrado que la estructura de una red neuronal convolucional es suficiente para capturar una gran cantidad de estadísticas de imágenes de bajo rango con resultados prometedores en la solución de problemas inversos estándar. Al aplicar esta metodología solo se requieren los datos observados para entrenar la red, esta es la gran ventaja de este enfoque ya que reduce el número de datos o muestras necesarias para el entrenamiento a únicamente los datos observados o datos adquiridos, esto da como resultado un menor costo computacional el cual permite tener una óptima reconstrucción de manera más rápida.

En el estado del arte se ha comprobado la funcionalidad de esta metodología en la reconstrucción de trazas sísmicas (que representan las columnas en una matriz de datos sísmicos) (Liu, 2021) siguiendo un modelo como la que se muestra en la Figura 7, en donde se requiere una arquitectura tipo U-Net f_θ , la entrada de la CNN es un ruido aleatorio $\mathbf{Z}$ y a la salida se le aplica el operador de muestreo $\mathcal{H}$ para reducir las dimensiones o simular la pérdida de información en el dato, con el fin de calcular la función de pérdida solo con los datos adquiridos hasta reducir la diferencia entre ambos actualizando los pesos de la red θ como se muestra en la siguiente ecuación:


$$\theta^* = \underset{\theta}{\text{minimizar}} \left\{ \left(\frac{1}{2} \right) \|\mathbf{Y} - \mathcal{H}(f_\theta(\mathbf{Z}))\|_2^2 \right\}. \quad (4)$$

Una vez se resuelve el problema de optimización (4) es posible reconstruir el dato sísmico usando siguiente ecuación:

$$\hat{\mathbf{X}} = f_{\theta^*}(\mathbf{Z}). \quad (5)$$

Figura 7

Esquema de modelo de reconstrucción de trazas.



De esta manera se infiere que si la red puede predecir las trazas adquiridos también puede predecir los disparos que se quieren reconstruir, debido a que estos datos siguen cierto patrón o características, y el propósito es que la red pueda capturar estos patrones para la reconstrucción. Actualmente no se ha implementado este tipo de metodologías para la reconstrucción de disparos completos, lo cual en una adquisición sísmica representa una gran pérdida de información, por lo tanto, para esta tesis se plantea implementar un algoritmo basado en DIP para la reconstrucción de disparos sísmicos.

4. Metodología

4.1. Formulación matemática del modelo de adquisición

Para el desarrollo y posterior implementación de un algoritmo de reconstrucción de datos sísmicos, en específico disparos, se propuso modelar matemáticamente el proceso de adquisición sísmica en una unidad de geometría *cross-spread* en donde se eliminan fuentes sísmicas en unas posiciones determinadas.


En el problema de reconstrucción de disparos sísmicos, la señal sísmica que contiene toda la información que se planteó adquirir correspondiente a la geometría diseñada se puede representar de forma discreta como una matriz tridimensional $\mathbf{X} \in \mathbb{R}^{M \times N \times L}$, donde M representa las muestras adquiridas a lo largo del tiempo, N es el número de receptores o trazas y L el número de disparos. En la adquisición sísmica existen limitantes que afectan la geometría, por lo tanto, se reduce la cantidad de disparos sísmicos. Esto genera una matriz de mediciones $\mathbf{Y} \in \mathbb{R}^{M \times N \times l}$, donde $l < L$. El proceso de adquisición por lo tanto se puede formular matemáticamente introduciendo un operador de muestreo $\mathcal{H}$, tal que:

$$\mathbf{Y} = \mathcal{H}(\mathbf{X}), \quad (6)$$

donde $\mathcal{H}$ requiere las posiciones o índices l_d de los disparos removidos de modo que la cantidad de disparos removidos S depende el tamaño de l_d , de manera que $l = L - S$. La eliminación se representa en la Figura 8, donde se eliminan los disparos en las posiciones l_d .

Figura 8

Ilustración del operador de muestreo.



4.2. Formulación del problema de reconstrucción usando DL basado en DIP

Para la reconstrucción de disparos sísmicos usando una metodología de aprendizaje profundo basado en DIP, se partió del problema planteado por Liu (2021) para la reconstrucción de trazas, donde se tiene como objetivo encontrar los pesos óptimos de la red neuronal convolucional f_θ , como se observa en el siguiente problema de optimización:

$$\theta^* = \underset{\theta}{\text{minimizar}} \{ \mathcal{L}(\mathcal{H}(f_\theta(\mathbf{Z})), \mathbf{Y}) \}, \quad (7)$$

donde θ^* es el parámetro óptimo de la red neuronal convolucional, $\mathbf{Z}$ es una matriz de ruido aleatorio y $\mathbf{Y}$ son los datos adquiridos.

La función de pérdida $\mathcal{L}$ como datos de entrada recibe los datos adquiridos $\mathbf{Y}$ y la salida del operador de muestreo $\mathcal{H}$, donde los datos de la salida del operador de muestreo se representan en la ecuación (8).

$$\hat{\mathbf{Y}} = \mathcal{H}(f_\theta(\mathbf{Z})). \quad (8)$$

Por lo tanto, el objetivo es que $\hat{\mathbf{Y}}$ sea lo más cercano a los datos observados $\mathbf{Y}$ bajo una métrica dada, para ello se debe encontrar el valor mínimo de la función de pérdida $\mathcal{L}$, la cual está definida por la siguiente ecuación:

$$\mathcal{L}(\mathbf{Y}, \hat{\mathbf{Y}}) = \text{MSE}(\mathbf{Y}, \hat{\mathbf{Y}}) + \lambda \text{MSE}(\text{FK}(\mathbf{Y}), \text{FK}(\hat{\mathbf{Y}})), \quad (9)$$

donde $\mathcal{L}$ se calcula en el dominio del tiempo (TX) y en el dominio frecuencia número de onda (FK), siendo λ una constante de compensación para tener control de la información en ambos dominios

La función de pérdida descrita en la ecuación (9) tiene en consideración la función del error cuadrático medio (MSE), que matemáticamente se calcula de la siguiente manera:

$$\text{MSE}(y, \hat{y}) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (\hat{y}_{i,j} - y_{i,j})^2, \quad (10)$$

donde y es el disparo original adquirido y $\hat{y}$ la reconstrucción con el algoritmo propuesto.

Inspirados en Liu (2021) para la reconstrucción de trazas, en esta tesis se llevó a cabo la implementación de una metodología para la reconstrucción de disparos basado en el problema de reconstrucción formulado en esta sección, donde se proponen las siguientes modificaciones y operadores específicos:

- Datos de entrada $\mathbf{Y}_\Delta + \mathbf{Z}$.
- Operador de correlación.
- Arquitectura U-Net 3D f_θ .


En las siguientes secciones se definen estas modificaciones y operadores que se proponen para la reconstrucción de disparos.

4.2.1. Datos de entrada

Inicialmente la metodología DIP para la reconstrucción de trazas tiene como dato de entrada solamente ruido aleatorio, para resolver el problema de optimización para la reconstrucción de disparos se propone realizar un reacondicionamiento a los datos adquiridos $\mathbf{Y}$ al cual se le agrega un ruido aleatorio $\mathbf{Z}$. Primero, se realiza una expansión de $\mathbf{Y}$ añadiendo ceros en las posiciones l_d con los disparos faltantes, generando así $\mathbf{Y}_\Delta$ como se muestra en la en la Figura 9.

Figura 9


Representación de la expansión de los datos observados.



Posteriormente, se agrega el ruido aleatorio con una distribución predefinida, dicha operación se representa en la Figura 10, donde se tiene como resultado $\mathbf{Y}_\Delta + \mathbf{Z}$.

Figura 10

Representación de la suma entre los datos observados expandidos y el ruido aleatorio uniforme.




En la Figura 10 se observa que el ruido aleatorio se suma con los datos en cero y datos donde existe la información adquirida en campo. Esto se realiza con el objetivo de preservar las características de cada disparo adquirido en los datos de entrada de la red para el uso del operador de correlación descrito en la sección 4.2.2. Finalmente, para los disparos con ceros correspondientes a las posiciones de los disparos faltantes, el resultado de la suma es el ruido aleatorio.

4.2.2. Operador de correlación

Para analizar la variación temporal de los eventos en cada uno de los disparos se propuso un operador en donde se toma un disparo de referencia en la posición *ref*, que en este caso es el disparo del medio o el más cercano a la línea de receptores; a los demás disparos adquiridos solo se les realiza un movimiento vertical para alinear los eventos y aumentar el valor de correlación de Pearson como se muestra en la Figura 11.

Figura 11

Representación del funcionamiento del operador de correlación.



Donde el coeficiente de correlación de Pearson se calcula de la siguiente manera:

$$P(y_m, y_{ref}) = \frac{\sum_{i=1}^n (y_{m_i} - \bar{y}_m) (y_{ref_i} - \bar{y}_{ref})}{\sqrt{\sum_{i=1}^n (y_{m_i} - \bar{y}_m)^2} \sqrt{\sum_{i=1}^n (y_{ref_i} - \bar{y}_{ref})^2}}, \quad (11)$$

teniendo como y_m el disparo de muestra y y_{ref} el disparo de referencia. Cabe resaltar que se debe realizar una vectorización de cada uno de los disparos para poder aplicar la ecuación (11) en el operador.

La motivación de este operador es explotar la correlación de los datos del *cross-spread* y así la CNN pueda aprender de forma óptima las características necesarias para la reconstrucción de los disparos

Los pasos que realiza el operador de correlación $\mathcal{T}$ están definidos en el siguiente pseudocódigo:

Algoritmo 1: Operador de correlación de disparos sísmicos

Entrada: $\mathbf{Y}_\Delta + \mathbf{Z}$, L , ref , $step$, l_d

Salida: $\mathbf{Y}_\Delta + \mathbf{Z}_{corr}$, ω^*

```

1  Se extrae el disparo de referencia  $x_{ref}$  de  $\mathbf{Y}_\Delta + \mathbf{Z}$ 
2   $\mathbf{Y}_\Delta + \mathbf{Z}_{corr} \leftarrow []$ ,  $\omega^* \leftarrow []$ ,  $i \leftarrow 0$ 
3  mientras  $i < L$  hacer
4  |    $\omega \leftarrow []$ ,  $p \leftarrow []$ 
5  |   si  $i$  no está en  $l_d$  entonces
6  |   |    $j \leftarrow 0$ 
7  |   |   mientras  $j < step * 2$  hacer
8  |   |   |    $m \leftarrow step - j$ 
9  |   |   |   Se extrae el disparo en la posición  $i$  de  $\mathbf{Y}_\Delta + \mathbf{Z}$  y se guarda en  $x_i$ 
10 |   |   |   Movimiento vertical a  $x_i$  definido por  $m$  y se guarda en  $temp$ 
11 |   |   |   // Se calcula el coeficiente de correlación de Pearson usando la ecuación (11)
12 |   |   |    $\rho \leftarrow P(temp, x_i)$ 
13 |   |   |   Se agrega  $\rho$  a la lista  $p$ 
14 |   |   |   Se agrega  $m$  a la lista  $\omega$ 
15 |   |   fin
16 |   |    $p_{max} \leftarrow$  valor máximo de  $p$ 
17 |   |   Se halla el índice del valor máximo de  $p$  y se guarda en  $p_{i-max}$ 
18 |   |   Movimiento vertical a  $x_i$  de  $\omega$  en la posición  $p_{i-max}$  y se guarda en  $temp^*$ 
19 |   de lo contrario
20 |   |   Se extrae el disparo en la posición  $i$  de  $\mathbf{Y}_\Delta + \mathbf{Z}$  y se guarda en  $temp^*$ 
21 |   fin
22 Se agrega  $temp^*$  a la matriz  $\mathbf{Y}_\Delta + \mathbf{Z}_{corr}$ 
23 fin

```

El operador de correlación inverso $\mathcal{T}^{-1}$ reacomoda los disparos observados a sus posiciones originales, para ello requiere la salida de la CNN y la salida ω^* del operador $\mathcal{T}$. Los pasos que realiza el operador inverso están definidos en el siguiente pseudocódigo:

Algoritmo 2: Operador de correlación inverso de disparos sísmicos

Entrada: $\hat{\mathbf{X}}_{\text{corr}}, L, l_d, \omega^*$

Salida: $\hat{\mathbf{X}}$

```

1   $\hat{\mathbf{X}} \leftarrow 0, i \leftarrow 0$ 
2  mientras  $i < L$  hacer
3  |   si  $i$  no está en  $l_d$  entonces
4  |   |   Se extrae el valor de  $\omega^*$  en la posición  $i$  y se guarda en  $\omega$ 
5  |   |   Se extrae el disparo en la posición  $i$  de  $\hat{\mathbf{X}}_{\text{corr}}$  y se guarda en  $temp$ 
6  |   |   Movimiento vertical  $temp$  por el negativo de  $\omega$  y se guarda en  $temp^*$ 
7  |   |   Se agrega  $temp^*$  a la matriz  $\hat{\mathbf{X}}$ 
8  |   de lo contrario
9  |   |   Se extrae el disparo en la posición  $i$  y se guarda en  $temp^*$ 
10 |   |   Se agrega  $temp^*$  a la matriz  $\hat{\mathbf{X}}$ 
11 |   fin
12 fin

```


4.2.3. Arquitectura de la red neuronal convolucional

La red neuronal convolucional f_θ es una U-Net 3D ilustrada en la Figura 12, donde las flechas verdes representan cada capa convolucional con un filtro de tamaño $3 \times 3 \times 3$, seguido de una normalización por lotes (o *batch normalization* en inglés) y una función de activación sigmoide. Las flechas naranjas representan el proceso para hacer el *downsampling* el cual consiste de una capa convolucional con un filtro de tamaño $3 \times 3 \times 3$ y el argumento *stride* para realizar la reducción de la dimensión, seguido de una normalización por lotes y una función de activación sigmoide. Las flechas amarillas representan la función de *upsampling* para aplicar el aumento en la dimensión. Las flechas grises representan las conexiones de salto en cada nivel de la

arquitectura. Finalmente, la flecha morada representa una capa convolucional con un filtro de tamaño $1 \times 1 \times 1$, seguido de una normalización por lotes y una función de activación sigmoide. Cada recuadro azul representa el dato a través de la arquitectura y el número arriba de éste define el número de filtros aplicados en la capa convolucional anterior. Para esta red se ajustó un tamaño de entrada fijo de $128 \times 128 \times 16$.

Figura 12

U-Net 3D para la reconstrucción de disparos.




4.3. Modelo de reconstrucción de datos sísmicos usando DL basado en DIP

La metodología propuesta SRDIP (de las siglas *Seismic reconstruction DIP-based*) para el problema de reconstrucción de disparos, ilustrada en la Figura 13, fue inspirada en el modelo para la reconstrucción de trazas (Liu, 2021) para poder reconstruir disparos, partiendo del objetivo de obtener una reconstrucción únicamente de los datos observados o datos adquiridos en campo $\mathbf{Y}$.

Figura 13

Esquema del modelo de reconstrucción de disparos con SRDIP.



El objetivo es obtener una reconstrucción solamente a partir de los disparos adquiridos $\mathbf{Y}$. Dentro del modelo se tienen como entrada los datos observados, a los cuales se les aplica un reacondicionamiento en donde se agrega un ruido aleatorio $\mathbf{Z} \in \mathbb{R}^{M \times N \times L}$ con una distribución predeterminada a los datos observados, teniendo así $\mathbf{Y}_\Delta + \mathbf{Z} \in \mathbb{R}^{M \times N \times L}$ como entrada al modelo, estos datos se expanden a la dimensión L del cubo a reconstruir (dicha operación está descrita en la sección 4.2.1). Posteriormente ésta es la entrada a un operador de correlación $\mathcal{T}$, el cual realiza un movimiento vertical a cada disparo adquirido (dicho operador está definido en la sección 4.2.2), la salida de este operador es:

$$\mathbf{Y}_\Delta + \mathbf{Z}_{\text{corr}} = \mathcal{T}(\mathbf{Y}_\Delta + \mathbf{Z}), \quad (12)$$

luego la salida pasa por la CNN f_θ , transformándose como:

$$\hat{\mathbf{X}}_{\text{corr}} = f_\theta(\mathbf{Y}_\Delta + \mathbf{Z}), \quad (13)$$

donde $\hat{\mathbf{X}}_{\text{corr}}$ tiene las mismas dimensiones de los datos de entrada $\mathbf{Y}_\Delta + \mathbf{Z}$ como se muestra en la Figura 13. En el esquema mostrado en la Figura 13, se puede observar que el operador de correlación actúa antes de la CNN, y posteriormente se aplica el operador inverso con el fin de colocar los disparos en las posiciones originales de la siguiente forma:

$$\hat{\mathbf{X}} = \mathcal{T}^{-1}(\hat{\mathbf{X}}_{\text{corr}}). \quad (14)$$

Posteriormente, el operador de muestreo $\mathcal{H}$ selecciona solamente los disparos en las posiciones adquiridas como se muestra en la ecuación (15):


$$\hat{\mathbf{Y}} = \mathcal{H}(\hat{\mathbf{X}}). \quad (15)$$

Una vez se obtiene $\hat{\mathbf{Y}}$, se calcula la función de pérdida con la ecuación (9)) de la sección 4.2 y se realiza la actualización de los pesos de la red usando el optimizador ADAM (Lui, 2021).

Una vez finaliza la fase de entrenamiento, solo se requiere ingresar $\mathbf{Y}_\Delta + \mathbf{Z}$ al operador de correlación y a la red entrenada con los pesos óptimos, y como salida se obtienen los datos reconstruidos, es decir, los disparos faltantes como se muestra en la Figura 14.

Figura 14

Esquema del modelo entrenado para estimar disparos.



Por lo tanto, para estimar $\mathbf{X}$ a partir de las medidas $\mathbf{Y}$, se utilizan los pesos óptimos θ^* de la forma:

$$\hat{\mathbf{X}} = \mathcal{T}^{-1}(f_{\theta^*}(\mathcal{T}(\mathbf{Y}_\Delta + \mathbf{Z}))). \quad (16)$$

4.4. Implementación del modelo de reconstrucción de datos sísmicos

Para la implementación del modelo de reconstrucción de datos sísmicos se inicia tomando en consideración el problema de optimización planteado en la sección 4.2, de tal manera que se debe encontrar los pesos óptimos para la reconstrucción de disparos sísmicos. Para ello se realizó un pseudocódigo del algoritmo con el desarrollo paso a paso de la metodología SRDIP.

4.4.1. Pseudocódigo del algoritmo

En esta sección se muestra el pseudocódigo del algoritmo propuesto para la reconstrucción de disparos descrito en la sección 4.3, de donde se tomó como referencia el esquema mostrado en la Figura 13.

Algoritmo 3: Algoritmo de reconstrucción de disparos sísmicos**Entrada:** $\mathbf{Y}$, ref , $step$, l_d **Salida:** $\hat{\mathbf{X}}$

```

1  Se genera  $\mathbf{Z}$ 
2  Se calcula  $\mathbf{Y}_\Delta + \mathbf{Z}$ 
3   $n_e \leftarrow 3000$ 
4  Se inicializan de forma aleatoria los pesos  $\theta$ 
5  mientras  $i < epochs$  hacer
    |
    | // Función operador de correlación  $\mathcal{T}$  que retorna  $\mathbf{Y}_\Delta + \mathbf{Z}_{corr}$  y  $\omega^*$ 
6  | Se aplica el operador  $\mathcal{T}(\mathbf{Y}_\Delta + \mathbf{Z}, L, ref, step, l_d)$ 
    |
    | // Función de la CNN
7  | Se genera la salida  $f_\theta(\mathbf{Y}_\Delta + \mathbf{Z}_{corr})$ 
    |
    | // Función operador correlación inverso  $\mathcal{T}^{-1}$ 
8  | Se aplica el operador  $\mathcal{T}^{-1}(f_\theta(\mathbf{Y}_\Delta + \mathbf{Z}_{corr}))$ 
    |
    | // Función del operador de muestreo  $\mathcal{H}$ 
9  | Se aplica el operador  $\mathcal{H}(\mathcal{T}^{-1}(f_\theta(\mathbf{Y}_\Delta + \mathbf{Z}_{corr})))$ 
    |
10 | Se calcula la función de pérdida  $\mathcal{L}(\mathbf{Y}, \mathcal{H}(\mathcal{T}^{-1}(f_\theta(\mathbf{Y}_\Delta + \mathbf{Z}_{corr}))))$ 
    |
11 | Actualización de los pesos  $\theta$  con el optimizador Adam
12 fin
13 Se genera la predicción  $\hat{\mathbf{X}}$ 

```

4.4.2. Implementación computacional del algoritmo de reconstrucción de disparos

El algoritmo propuesto en la sección 4.4.1 emplea una de las técnicas más usadas en el aprendizaje profundo, el cual son las CNN. En esta metodología se propuso una U-Net 3D que se adaptada a la estructura de los datos sísmicos en el dominio *cross-spread*. El pseudocódigo se implementó en el lenguaje de programación *Python*, donde se aprovechó la capacidad de la librería *Tensorflow* para la creación del modelo CNN.

Las simulaciones se ejecutaron en *Colaboratory* como se muestra en la Figura 15, un servicio proporcionado por *Google* que permite ejecutar código en lenguaje *Python*. Se eligió este entorno ya que de forma gratuita ofrece los recursos de una GPU Nvidia T4 Tensor Core, lo cual facilita el entrenamiento de las redes convolucionales.

Figura 15

Captura implementación en Colaboratory.

```

1 def model_unet(pretrained_weights=None, input_size=(n2,n2,11,1), FLAGS=None):
2     inputs=Input(input_size)
3
4     n = 4
5     kernel= 3
6
7     fun_act = "sigmoid"
8     kernel_i = "random_uniform"
9
10    conv1 = Conv3D(n, kernel_size = kernel, padding="same", kernel_initializer=kernel_i)(inputs)
11    bn1 = BatchNormalization()(conv1)
12    relu1 = Activation(fun_act)(bn1)
13    conv1 = Conv3D(n, kernel_size = kernel, padding="same", kernel_initializer=kernel_i)(relu1)
14    bn1 = BatchNormalization()(conv1)
15    relu1_sc = Activation(fun_act)(bn1)
16    conv1 = Conv3D(n, kernel, strides=(2, 2, 2), padding="same", kernel_initializer=kernel_i)(relu1_sc)
17    bn1 = BatchNormalization()(conv1)
18    relu1 = Activation(fun_act)(bn1)
19
20    conv2 = Conv3D(n*2, kernel_size = kernel, padding="same", kernel_initializer=kernel_i)(relu1)
21    bn2 = BatchNormalization()(conv2)
22    relu2 = Activation(fun_act)(bn2)
23    conv2 = Conv3D(n*2, kernel_size = kernel, padding="same", kernel_initializer=kernel_i)(relu2)
24    bn2 = BatchNormalization()(conv2)
25    relu2_sc = Activation(fun_act)(bn2)
26    conv2 = Conv3D(n*2, kernel_size = kernel, strides=(2, 2, 2), padding="same", kernel_initializer=kernel_i)(relu2_sc)
27    bn2 = BatchNormalization()(conv2)
28    relu2 = Activation(fun_act)(bn2)
29
30    conv3 = Conv3D(n*4, kernel_size = kernel, padding="same", kernel_initializer=kernel_i)(relu2)
31    bn3 = BatchNormalization()(conv3)
32    relu3 = Activation(fun_act)(bn3)
33    conv3 = Conv3D(n*4, kernel_size = kernel, padding="same", kernel_initializer=kernel_i)(relu3)
34    bn3 = BatchNormalization()(conv3)
35    relu3_sc = Activation(fun_act)(bn3)
36    conv3 = Conv3D(n*4, kernel_size = kernel, strides=(2, 2, 2), padding="same", kernel_initializer=kernel_i)(relu3_sc)
37    bn3 = BatchNormalization()(conv3)
38    relu3 = Activation(fun_act)(bn3)
39
40    conv4 = Conv3D(n*8, kernel_size = kernel, padding="same", kernel_initializer=kernel_i)(relu3)
41    bn4 = BatchNormalization()(conv4)
42    relu4 = Activation(fun_act)(bn4)
43    conv4 = Conv3D(n*6, kernel_size = kernel, padding="same", kernel_initializer=kernel_i)(relu4)

```

5. Configuración experimental

En esta sección se describe la configuración experimental utilizada para las simulaciones de reconstrucción de disparos con el propósito de evaluar la calidad de estas con el algoritmo propuesto en la sección 4.3. La configuración experimental incluye la selección de métricas para evaluar la calidad de las reconstrucciones, la variación de parámetros para cada experimento y los conjuntos de datos sísmicos usados.

5.1. Métricas

Con el fin de evaluar la calidad del método propuesto en la reconstrucción de disparos se dispuso a seleccionar métricas para cuantificar la eficacia del método, para ello se propusieron las siguientes métricas.

5.1.1. Proporción máxima de señal a ruido (PSNR)

La proporción máxima de señal a ruido (PSNR) es una métrica que es utilizada para cuantificar la relación entre la máxima potencia que tiene una señal, y el ruido que corrompe dicha señal, ésta es representada en escala logarítmica la cual se mide en decibelios (dB) y se calcula de la siguiente forma:

$$PSNR_i = 10 \log \left(\frac{\max(\mathbf{X}_i)^2}{MSE(\mathbf{X}_i, \hat{\mathbf{X}}_i)} \right), \quad (17)$$

donde el disparo original $\mathbf{X}_i$ se compara con el reconstruido $\hat{\mathbf{X}}_i$, teniendo así un valor de PSNR, denotado por $PSNR_i$, siendo $i = 1, 2 \dots S$.

5.1.2. Medida del índice de similitud estructural (SSIM)

El índice de similitud estructural es una métrica utilizada con la finalidad de estimar la similitud entre dos señales o imágenes identificando fenómenos ópticos como la luminancia y el contraste. Se eligió la métrica SSIM ya que los disparos se pueden representar como imágenes; matemáticamente se calcula de la siguiente forma:

$$SSIM = \left(\frac{2\mu_{\mathbf{X}_i}\mu_{\hat{\mathbf{X}}_i} + c_1}{\mu_{\mathbf{X}_i}^2 + \mu_{\hat{\mathbf{X}}_i}^2 + c_1} \right) \left(\frac{2\sigma_{\mathbf{X}_i}\sigma_{\hat{\mathbf{X}}_i} + c_2}{\sigma_{\mathbf{X}_i}^2 + \sigma_{\hat{\mathbf{X}}_i}^2 + c_2} \right) \left(\frac{\sigma_{\mathbf{X}_i, \hat{\mathbf{X}}_i} + c_3}{\sigma_{\mathbf{X}_i}\sigma_{\hat{\mathbf{X}}_i} + c_3} \right), \quad (18)$$

donde $\mu_{\mathbf{X}_i}$ y $\sigma_{\mathbf{X}_i}$ es la media y la desviación estándar del disparo original $\mathbf{X}_i$, $\sigma_{\mathbf{X}_i, \hat{\mathbf{X}}_i}$ es la covarianza entre el disparo original $\mathbf{X}_i$ y el disparo reconstruido $\hat{\mathbf{X}}_i$; y c_1 , c_2 y c_3 son variables que evitan las divisiones por cero.

5.2. Conjuntos de datos sísmicos

En esta sección se muestran los conjuntos de datos sísmicos 3D utilizados para realizar las simulaciones, pertenecientes a una unidad de geometría *cross-spread*. Fue seleccionado un *cross-spread* sintético y otro correspondiente a una adquisición real, cada uno fue condicionado a las mismas dimensiones definidas en el método propuesto, lo cual requirió de hacer un redimensionamiento a los datos.


5.2.1. Datos sísmicos sintéticos

Los datos sísmicos sintéticos que se utilizaron para realizar las simulaciones son un conjunto de datos *cross-spread* compuesto por 16 disparos, cada disparo se conforma por $M = 128$ muestras de tiempo y $N = 128$ trazas como se muestra en la Figura 16, donde se evidencia el

esquema de adquisición correspondiente a una unidad de geometría *cross-spread* y una ilustración del cubo de datos.

Figura 16

Datos sintéticos utilizados para las simulaciones y experimentos.




5.2.2. Datos sísmicos reales

Los datos sísmicos reales son un *cross-spread* de una adquisición real, se utilizaron para demostrar la eficacia del algoritmo con datos que presentan una mayor complejidad, a dichos datos se les aplicó un redimensionamiento a cada uno de los disparos para la implementación del algoritmo propuesto, el cual requiere 16 disparos con 128 muestras en el tiempo y 128 trazas o receptores como se observa en la Figura 17, donde se evidencia el esquema de adquisición de dicho redimensionamiento correspondiente a una unidad de geometría *cross-spread* y una ilustración del cubo de datos.

Figura 17

Datos reales utilizados para las simulaciones y experimentos.




5.3. Diseño de experimentos

Para encontrar la configuración de parámetros óptima se propuso realizar una variación de parámetros donde se realizaron 10 experimentos para cada variación con el fin de identificar la incertidumbre del algoritmo y poder sacar mejores conclusiones a partir de cada una de las métricas propuestas para evaluar los resultados, estas fueron el PSNR y SSIM. En cada experimento fueron eliminados intencionalmente 5 disparos como se muestra en la Figura 18, el experimento consiste en la fase de procesamiento, entrenamiento y reconstrucción de los datos.

Figura 18

Esquema de adquisición cross-spread con las 5 fuentes eliminadas.




Para el entrenamiento de cada uno de los experimentos se fijó el algoritmo con 3000 épocas, utilizando el optimizador Adam y una tasa de aprendizaje de 0.001.

5.3.1. Configuración del modelo base

Inicialmente se diseñó un modelo base, el esquema de dicho modelo se muestra en la Figura 19, donde se implementó el modelo para la reconstrucción de trazas basado en el modelo propuesto por Liu (2021), adaptado a la reconstrucción de disparos sísmicos. La U-Net 3D propuesta es la encontrada en la sección 4.2.3, como función de pérdida se usó la MSE descrita en la ecuación (10).

Figura 19

Esquema del modelo base de reconstrucción de disparos.



A partir de dicho modelo se realizó una variación de los siguientes parámetros para poder concluir y verificar la configuración óptima.

- **Distribución del ruido de entrada $\mathbf{Z}$:** Se propuso estimar cual es la mejor distribución para el ruido de entrada, para ello se tomó la distribución uniforme, normal, de Bernoulli y una distribución a partir de los datos observados.
- **Conexión de salto:** Se contemplaron dos funciones para realizar esta operación las cuales fueron la función *Add* y la función *Concat*.
- **Profundidad CNN:** Se determinó analizar que la profundidad de la CNN propuesta en la sección 4.2.3 es la óptima, para ello se realizó una reducción de un nivel a la profundidad para comparar.

- **Número de filtros:** Se propuso determinar la configuración del número de filtros por nivel en la CNN, teniendo un aumento exponencial por cada nivel de la forma 2^{nivel} , se comparó con un aumento lineal de la forma $2 * nivel$ con $2 \leq nivel \leq 5$.
- **Downsampling:** Teniendo en cuenta la operación de *downsampling* con el argumento *stride* en la capa convolucional, se propuso compararla con la función *Maxpooling*.

5.3.2. Configuración modelo SRDIP

Posteriormente, se planteó mostrar la funcionalidad del método propuesto SRDIP, con la finalidad de determinar si cada propuesta realizada para el modelo en comparación con el modelo base daba como resultado reconstrucciones con una mayor calidad. Por lo tanto, se realizó una variación de los siguientes parámetros para poder concluir y verificar la configuración óptima.

- **Datos de entrada:** Se compararon los resultados teniendo como dato de entrada únicamente ruido aleatorio $\mathbf{Z}$ y el propuesto $\mathbf{Y}_\Delta + \mathbf{Z}$ en la sección 4.2.1.
- **Función de perdida:** Se propuso la función de perdida personalizada en la sección 4.2 con el fin de determinar si se logra tener mejores resultados.
- **Operador de correlación:** Para aprovechar la correlación del *cross-spread* se formuló un algoritmo para aumentar la correlación del conjunto de datos adquiridos y así demostrar que dicho operador brinda una mayor calidad en las reconstrucciones.

6. Análisis de resultados

En esta sección se presentan los resultados que se obtuvieron de las simulaciones para la reconstrucción de disparos sísmicos con la finalidad de evaluar cuantitativamente el desempeño del método propuesto, para ello se analizaron los parámetros para hallar la configuración óptima con los datos sintéticos.

6.1. Evaluación del algoritmo

En la Tabla 1 se presenta una evaluación del algoritmo a partir del diseño de experimentos descrito en la sección 5.3, donde se muestran la media de cada 10 experimentos usando los datos sintéticos mostrados en la sección 5.2, donde en la geometría diseñada se tienen $L = 16$, y los disparos adquiridos fueron $l = 11$, teniendo como cantidad de disparos faltantes $S = 5$. Se puede observar que para cada parámetro se cuantificó la calidad de las reconstrucciones teniendo en cuentas las métricas propuestas en la sección 5.1 y el valor más alto se marca en negrilla, determinando así que esa es la configuración óptima para ese parámetro en consideración.

Mediante los resultados obtenidos se puede afirmar que la arquitectura U-Net 3D propuesta en la sección 4.2.3 y el modelo SRDIP obtienen los mejores resultados en la reconstrucción de los disparos del conjunto de datos sintéticos, obteniendo los valores más altos en las métricas PSNR y SSIM para cada variación en el diseño de experimentos a partir de la configuración de experimentos descrita en la sección 5.3.1. El tiempo estimado para cada experimento el cual consiste en procesamiento, entrenamiento y predicción fue de 7 minutos aproximadamente con 3000 épocas.

Tabla 1


Métricas PSNR y SSIM para cada variación de parámetros.

Parámetro		Variación	PSNR (dB)	SSIM
Modelo base	Distribución ruido de entrada	Uniforme	40.62058	0.9912
		Normal	37.34345	0.98753
		Bernoulli	36.10284	0.98503
		Datos observados	35.08199	0.9837
	Conexión de salto	<i>Add</i>	40.62058	0.9912
		<i>Concat</i>	38.4272	0.98446
	Profundidad CNN	Propuesta	40.62058	0.9912
		Reducción	38.35676	0.98449
	Numero de filtros	Aumento lineal	40.62058	0.9912
		Aumento exponencial	37.44061	0.97922
	<i>Downsampling</i>	<i>Stride</i>	40.62058	0.9912
		<i>Maxpooling</i>	36.7268	0.98048
Modelo SRDIP	Datos de entrada	Z	40.62058	0.9912
		$Y_{\Delta} + Z$	40.66743	0.99267
	Función de pérdida	MSE	40.66743	0.99267
		Propuesta	41.67784	0.99362
	Operador de correlación	No	41.67784	0.99362
		Si	42.08075	0.9941

En la Figura 20 se muestran los resultados usando el método SRDIP, donde se realiza una comparativa entre dos disparos, el disparo original y el reconstruido con el algoritmo propuesto en el dominio TX y FK.

Figura 20

Comparativa visual de los resultados obtenidos en la reconstrucción de disparos correspondiente a los datos sintéticos en el dominio TX y FK.



En la Tabla 2 se presentan las métricas PSNR y SSIM para los dos disparos comparados en la Figura 20, donde se evaluó la calidad de la reconstrucción en el dominio TX y FK para la métrica PSNR.

Tabla 2

Métricas PSNR y SSIM de los disparos con índice 7 y 12 correspondiente a los datos sintéticos en el dominio TX y FK.


		Índice 7	Índice 12
PSNR	TX	43.5933	45.33193
	FX	40.0323	40.06639
SSIM		0.99693	0.99684

6.2. Comparación con algoritmos de estado del arte

Una vez se ha demostrado la eficacia de la reconstrucción de disparos usando datos sísmicos sintéticos, se prosiguió a realizar una comparativa con algoritmos del estado del arte, para ello se realizó la comparación con el método propuesto por Goyes (2022) Consensus Equilibrium (CE) y el método de interpolación propuesto por Villarreal (2019) (SBI) basado en un regularizador de escasez que resuelve la ecuación (2) con el algoritmo ADMM. Los resultados de la reconstrucción del método propuesto SRDIP en comparación con los métodos a del estado del arte en el dominio TX y FK se muestran en la Figura 21.

Figura 21


Comparativa visual de los resultados obtenidos en la reconstrucción de disparos con el método propuesto SRDIP, SBI y CE en el dominio TX y FK.



Posteriormente, en la Figura 22 se realiza una comparativa entre el método propuesto SRDIP y los métodos del estado del arte en la reconstrucción del mismo disparo mostrado en la Figura 21 seleccionando la traza con índice 60.

Figura 22

Comparativa visual de los resultados obtenidos en la reconstrucción de la traza 60 con el método propuesto SRDIP, SBI y CE en el dominio TX.



La Tabla 3 resume la evaluación del desempeño de los diferentes métodos de reconstrucción en términos de precisión de reconstrucción y tiempo de ejecución. Se puede observar que el método propuesto supera a los otros métodos en términos de PSNR donde se presentan la media más alta de las reconstrucciones, dicha superioridad confirma que el método propuesto SRDIP da una mejor solución a la reconstrucción de disparos.

Tabla 3

Evaluación de desempeño entre el método propuesto SRDIP, SBI y CE, con las métricas PSNR, SSIM, PSNR en dominio TX y FK y tiempo de ejecución.


Método	PSNR		SSIM	Tiempo (s)
	TX	FK		
SRDIP	41.54	38.73	0.993	385
SBI	9.025	19.89	0.477	118
CE	39.99	33.86	0.998	338

6.3. Resultados datos sísmicos reales

Una vez se ha demostrado la eficacia de la reconstrucción de disparos usando datos sísmicos sintéticos, se prosiguió a usar datos reales en el dominio *cross-spread* mencionados en la sección 5.2.2. El tiempo para entrenar y predecir los 5 disparos fue alrededor de 7 minutos con 3000 épocas. En la Figura 23 se muestran los resultados usando el método SRDIP, donde se realiza una comparativa entre dos disparos, el disparo original y el reconstruido con el algoritmo propuesto en el dominio TX y FK.

Figura 23

Comparativa visual de los resultados obtenidos en la reconstrucción de disparos correspondiente a los datos reales en el dominio TX y FK.



En la Tabla 4 se presentan las métricas PSNR y SSIM para los dos disparos comparados en la Figura 23, donde se evaluó la calidad de la reconstrucción en el dominio TX y FK para la métrica PSNR.

Tabla 4

Métricas PSNR y SSIM de los disparos con índice 7 y 12 correspondiente a los datos reales en el dominio TX y FK.

		Índice 7	Índice 12
PSNR	TX	19.32541	19.70451
	FX	21.89312	20.88288
SSIM		0.73476	0.74598


Como se puede observar, hubo una caída en la calidad de las reconstrucciones, debido a que la complejidad de los datos sísmicos reales es mayor a los datos sísmicos sintéticos y esto impacta en el nivel de aprendizaje que puede llegar a capturar el algoritmo propuesto en la etapa de entrenamiento.

6.3.1. Extensión del método propuesto a datos marinos

A continuación se decidió realizar la reconstrucción de disparos a una adquisición sísmica marina, en donde se tiene un esquema de adquisición diferente al *cross-spread*, en este caso solo se tiene una fuente y para cada disparo tanto la posición de la fuente como toda la línea de receptores se va trasladando por medio de un barco, a dichos datos se les aplicó el mismo redimensionamiento a cada uno de los disparos para la implementación del algoritmo y se aplicó el mismo muestreo de 5 disparos como se venía trabajando anteriormente como se muestra en la Figura 24.

Figura 24


Comparativa visual de los resultados obtenidos en la reconstrucción de disparos de los datos marinos.



El tiempo para entrenar y predecir los 5 disparos fue alrededor de 7 minutos con 3000 épocas utilizando los parámetros óptimos definidos en los análisis realizados en la sección 6.1. En la Figura 25 se muestran los resultados usando el método SRDIP, donde se realiza una comparativa entre dos disparos, el disparo original y el reconstruido con el algoritmo propuesto en el dominio TX y FK.

Figura 25

Comparativa visual de los resultados obtenidos en la reconstrucción de disparos correspondientes a los datos marinos en el dominio TX y FK.



En la Tabla 5 se presentan las métricas PSNR y SSIM para los dos disparos comparados en la Figura 25, donde se evaluó la calidad de la reconstrucción en el dominio TX y FK para la métrica PSNR.

Tabla 5

Métricas PSNR y SSIM de los disparos con índice 7 y 12 correspondiente a los datos marinos en el dominio TX y FK.

		Índice 7	Índice 12
PSNR	TX	35.66413	34.41231
	FX	27.06912	26.64197
SSIM		0.97753	0.97304

En este caso se observa una calidad de las reconstrucciones superiores a los datos reales en el dominio *cross-spread*, esto se debe a que los datos marinos tienen poca variedad de información a lo largo de cada disparo, maximizando el valor de la correlación en todo el cubo de datos permitiendo así al algoritmo poder capturar de forma óptima las características que definen los disparos sísmicos en la etapa de entrenamiento.

7. Conclusiones

Se implementó una metodología basada en los datos observados para la reconstrucción de datos sísmicos incompletos. Es una ventaja ya que reduce costos computacionales y de procesamiento de datos. Esto es de suma importancia para la adquisición y procesamiento de datos sísmicos debido a la dificultad de generar bases de datos extensas para entrenar métodos basados en aprendizaje profundo debido a la confidencialidad de los datos o la variedad limitada de características para la reconstrucción.

Primeramente, se formuló matemáticamente el modelo de adquisición sísmica en el dominio *cross-spread*, incorporando un operador de muestreo, el cual simula el proceso de pérdida de información sísmica en escenarios donde no es posible adquirir un disparo. Este operador remueve los disparos en unas posiciones o índices específicos, de modo que se tiene una señal densa como una matriz tridimensional de $M \times N \times L$ y el operador reduce las dimensiones de la matriz a $M \times N \times l$ siendo $l < L$. Con esta formulación se dio por cumplido el objetivo 1.

Posteriormente, se planteó el problema matemático de reconstrucción de disparos sísmicos usando un enfoque de aprendizaje profundo el cual únicamente requiere los datos observados en la fase de entrenamiento y reconstrucción (SRDIP). Para solucionar el problema de reconstrucción planteado, se propuso una función de pérdida que contempla la información en el dominio temporal y espectral, junto con un reacondicionamiento de los datos de entrada de la red. También se añadió un operador para maximizar la correlación de los disparos desfasados en el tiempo, con

el fin de aprender de forma óptima las características necesarias para la reconstrucción de los disparos. Con este planteamiento se dio por cumplido el objetivo 2.

Seguidamente, se implementó un algoritmo para resolver el problema de reconstrucción planteado anteriormente, en donde se cumplió con la meta de solo usar los datos observados. Para ello se desarrolló un pseudocódigo de la metodología propuesta en el objetivo 2 y posteriormente se implementó en *Python* usando la librería *Tensorflow* en la herramienta *Colaboratory*. Con esta implementación se dio por cumplido el objetivo 3.

Finalmente, se evaluó el algoritmo realizando un análisis de parámetros para determinar la configuración óptima del modelo y de la red neuronal convolucional tipo U-Net 3D para obtener los resultados con la mejor calidad posible usando datos sintéticos. Posteriormente, se comparó el método propuesto con los del estado del arte CE y SBI, evidenciado la competitividad en la métrica SSIM con el método CE el cual logró extraer de manera óptima ciertas estructuras del dato sísmico. El método SRDIP mostró superioridad en métricas como el PSNR, superando en promedio por 17.03 dB, demostrando la eficacia del método propuesto en cuestión de la amplitud y su impacto en el problema de reconstrucción de disparos sísmicos. Adicionalmente, se evaluó el algoritmo con datos reales en el dominio *cross-spread* y se evaluó el rendimiento con otro tipo de adquisiciones como son las marinas (*offshore*), lo cual permitió determinar la calidad de las reconstrucciones en diferentes esquemas de adquisición. Con esta evaluación se dio por cumplido el objetivo 4.

8. Trabajo futuro

Como trabajo futuro, se podría realizar una investigación profunda a la correlación de los datos sísmicos con el fin de determinar matemáticamente cómo impacta este procesamiento en el aprendizaje de la CNN y poder implementar este operador en otro tipo de señales, ya que se pudo evidenciar que maximizar dicho valor da como resultado mejores interpolaciones. Por otra parte, el método SRDIP tiene una limitante correspondiente a las dimensiones del dato sísmico, donde se ajustó la CNN a datos con dimensiones de $128 \times 128 \times 16$, por lo tanto, con la finalidad de soportar datos sísmicos que presenten diferentes dimensiones, se podría implementar un algoritmo que realice una partición por bloques de $128 \times 128 \times 16$.

Referencias Bibliográficas

- ANH, A. (2010). Manual para la adquisición y procesamiento de sismica terrestre y su aplicación en Colombia. Bogotá Universidad Nacional de Colombia.
- Chai, X., Tang, G., Wang, S., Lin, K., & Peng, R. (2020). Deep learning for irregularly and regularly missing 3-D data reconstruction. *IEEE Transactions on Geoscience and Remote Sensing*, 59(7), 6244-6265.
- Chaouch, A., & Mari, J. L. (2006). 3-D land seismic surveys: definition of geophysical parameter. *Oil & Gas Science and Technology-Revue de l'IFP*, 61(5), 611-630.
- Galvis, L., Ramírez, J. M., Vargas, E., Villarreal, O., Agudelo, W., & Arguello, H. (2020). Reconstruction of 2D seismic wavefields from nonuniformly sampled sources. *Electronic Imaging*, 2020(14), 307-1.
- Glossary, S. O. (2022). Oilfield glossary.
- Goyes-Peñafiel, P., Vargas, E., Correa, C. V., Agudelo, W., Wohlberg, B., & Arguello, H. (2021). A Consensus Equilibrium Approach for 3-D Land Seismic Shots Recovery. *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5.
- Hatton, L., Worthington, M. H., & Makin, J. (1986). *Seismic data processing: theory and practice*. Merlin Profiles Ltd.
- Ibtehaz, N., & Rahman, M. S. (2020). MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural networks*, 121, 74-87.
- Kazemi, N., Bongajum, E., & Sacchi, M. D. (2016). Surface-consistent sparse multichannel blind deconvolution of seismic signals. *IEEE Transactions on geoscience and remote sensing*, 54(6), 3200-3207.

- Kelleher, J. D. (2019). Deep Learning (MIT Press Essential Knowledge Series). vol. i.
- Kong, F., Picetti, F., Lipari, V., Bestagini, P., Tang, X., & Tubaro, S. (2020). Deep prior-based unsupervised reconstruction of irregularly sampled seismic data. *IEEE Geoscience and Remote Sensing Letters*.
- Kuijpers, D., Vasconcelos, I., & Putzky, P. (2021). Reconstructing missing seismic data using Deep Learning. arXiv preprint arXiv:2101.09554.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Liner, C. L. (2016). *Elements of 3D seismology*. Society of Exploration Geophysicists.
- Liu, Q., Fu, L., & Zhang, M. (2021). Deep-seismic-prior-based reconstruction of seismic data using convolutional neural networks. *Geophysics*, 86(2), V131-V142.
- Liu, W., Cao, S., Li, G., & He, Y. (2015). Reconstruction of seismic data with missing traces based on local random sampling and curvelet transform. *Journal of Applied Geophysics*, 115, 129-139.
- López, K. L., Ramírez, J. M., Agudelo, W., & Fuentes, H. A. (2019, April). Regular multi-shot subsampling and reconstruction on 3d orthogonal symmetric seismic grids via compressive sensing. In *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)* (pp. 1-5). IEEE.
- Mandelli, S., Borra, F., Lipari, V., Bestagini, P., Sarti, A., & Tubaro, S. (2018). Seismic data interpolation through convolutional autoencoder. In *SEG Technical Program Expanded Abstracts 2018* (pp. 4101-4105). Society of Exploration Geophysicists.
- Mandelli, S., Lipari, V., Bestagini, P., & Tubaro, S. (2019). Interpolation and denoising of seismic data using convolutional neural networks. arXiv preprint arXiv:1901.07927.

- Ochoa Pongutá, H. C. (2018). Métodos de reconstrucción de registros sísmicos. Departamento de Geociencias.
- Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.
- Ulyanov, D., Vedaldi, A., & Lempitsky, V. (2018). Deep image prior. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 9446-9454).
- Villarreal, O., León-López, K., Espinosa, D., Agudelo, W., & Arguello, H. (2019). Seismic source reconstruction in an orthogonal geometry based on local and non-local information in the time slice domain. *Journal of Applied Geophysics*, 170, 103846.
- Yang, P., Gao, J., & Chen, W. (2012). Curvelet-based POCS interpolation of nonuniformly sampled seismic records. *Journal of Applied Geophysics*, 79, 90-99.