

Detección automática de fracturas y fallas geológicas a partir de la segmentación de imágenes con redes convolucionales profundas aplicadas a cubos sísmicos

Bryan Daniel Álvarez Castillo

Trabajo de Grado para Optar al Título de Ingeniero de Sistemas

Director

Yesid Paul Goyes Peñafiel

Geólogo, Magister en Geofísica

Codirector

Henry Arguello Fuentes

Doctor en Ingeniería Eléctrica y Computación

Universidad Industrial de Santander

Facultad de Ingeniería Físico-mecánicas

Escuela de Ingeniería de Sistemas e Informática

Bucaramanga

2021

Dedicatoria

A mi madre Yarley Castillo, que con su apoyo culminé mi carrera.

A mi padre Wilson Álvarez, que gracias a su paciencia y apoyo pude recibir la formación
académica

A mi hermana Alejandra Álvarez, por siempre aportarme y darme la motivación de seguir
adelante.

A mis amigos en la Pastoral de la Universidad, los Pentecostales en la Universidad, por
ayudarme en los problemas y por los grandes recuerdos que tuve en mi vida universitaria

Agradecimientos

A PhD (c) Geol. Yesid Paul Goyes Peñafiel, director del proyecto de grado, por sus valiosos consejos, aportes y paciencia, para la culminación del trabajo.

A María Alejandra Hernández Rojas, por su tiempo, apoyo y recomendaciones cruciales para el desarrollo del proyecto.

A Juan Martínez, por su tiempo y por sus consejos para la redacción del documento.

Al grupo de investigación HDSP por brindarme su apoyo en la resolución del proyecto.

Finalmente, a la Universidad Industrial de Santander por la formación académica recibida

Tabla de Contenido

Introducción	12
1. Objetivos	14
1.1 Objetivo General	14
1.2 Objetivos Específicos.....	14
2. Marco teórico	15
2.1. Volumen sísmico	15
2.2. Atributos sísmicos.	17
2.3. Análisis de Componentes Principales.....	19
2.4. Visión por computador	20
2.5. Redes neuronales convolucionales	20
2.5.1. Redes neuronales convolucionales en sísmica	22
2.5.2. Redes autoencoders.	23
2.5.3. Red neuronal convolucional U-Net.....	24
2.6. Métricas de evaluación.	26
2.6.1. Índice de similitud estructural	27
2.6.2. Pixel accuracy	28
2.6.3. Intersection-Over-Union	28
3. Metodología	29
3.1 Etapa 1: Seleccionar los atributos sísmicos más relevantes para la detección de fallas y fracturas geológicas de cubos sísmicos.....	29
3.1.1. Contraste de amplitud.....	29

3.1.2. Ant Tracking	30
3.1.3. Varianza (método de bordes)	32
3.1.4. Impedancia acústica relativa	33
3.1.5. Magnitud del gradiente.....	33
3.1.6. Atributo Likelihood.....	34
3.1.7. Skeletonization	35
3.2 Etapa 2: Diseñar un algoritmo para mejorar la detección automática de las fallas geológicas a partir de la segmentación de imágenes y atributos sísmicos con redes convolucionales profundas.....	36
3.2.1. Método propuesto.	37
3.2.2. Red neuronal convolucional	40
3.3 Etapa 3: Validar la red entrenada para la detección automática de fallas en diferentes conjuntos de datos sísmicos induciendo diferentes niveles de ruido para estimar la precisión y rendimiento de la red.	43
4. Base de datos.....	45
4.1 Cubos sísmicos sintéticos.	45
4.2 Cubo sísmico real F3 Países bajos	48
5. Resultados	50
5.1 Análisis y selección de atributos sísmicos	50
5.2. Resultados de los entrenamientos de las redes neuronales convolucionales	53
5.2.1. Entrenamiento con la red neuronal convolucional autoencoder	54
5.2.2. Entrenamiento con la red U-net	57

5.3 Implementación del método en datos sísmicos reales	60
6. Conclusiones	62
7. Referencias.....	64

Lista de tablas

Tabla 1. Características de las CNN	26
Tabla 2. Descripción de los atributos implementados	52
Tabla 3. Resultados de la red Autoencoder.....	56
Tabla 4. Resultados de la red Unet.	59

Lista de Figuras

Figura 1. Propagación de una onda en el subsuelo.....	16
Figura 2. Esquema de una red neuronal convolucional.....	21
Figura 3. Red CNN para la clasificación de fallas.....	23
Figura 4. Implementación de la InversionNet	24
Figura 5. Red U-Net.....	25
Figura 6. Implementación del atributo contraste de amplitud	30
Figura 7. Resultado de aplicar el atributo Ant Tracking.....	31
Figura 8. Atributo de varianza	32
Figura 9. Atributo de impedancia acústica relativa	33
Figura 10. Atributo de magnitud del gradiente.....	34
Figura 11. Atributo Likelihood.....	35
Figura 12. Atributo Skeletonization.....	36
Figura 13. Varianza explicada para los componentes principales del cubo multiatributo	38
Figura 14. Esquema de datos para el cálculo del PCA	39
Figura 15. Implementación de la U-net	41
Figura 16. Implementación de la CNN Autoencoder	42
Figura 17. Datos con el procesamiento de aumento de datos.....	44
Figura 18. Procedimiento para la creación de cubos sísmicos sintéticos	47
Figura 19. Segmentación de datos sintéticos.....	48
Figura 20. Representación del cubo F3	49

Figura 21. Segmentación manual de las imágenes obtenidas del cubo F3	50
Figura 22. Implementación de los atributos sísmicos en los datos obtenidos.	51
Figura 23. Evolución de la precisión durante el entrenamiento y test con CNN autoencoder	54
Figura 24. Evolución de la función de pérdida durante el entrenamiento con CNN autoencoder	55
Figura 25. Predicción de las fallas con CNN autoencoder	56
Figura 26. Evolución de la precisión durante el entrenamiento y test U-Net.....	57
Figura 27. Evolución de la función de pérdida durante el entrenamiento con U-Net	58
Figura 28. Predicción de las fallas con U-Net	59
Figura 29. Implementación con datos sísmicos reales.....	60
Figura 30. Imágenes tridimensionales de las fallas geológicas reales	61

Resumen

Título: Detección automática de fracturas y fallas geológicas a partir de la segmentación de imágenes con redes convolucionales profundas aplicadas a cubos sísmicos *

Autor: Bryan Daniel Álvarez Castillo **

Palabras Clave: Interpretación sísmica, segmentación de imágenes, fallas geológicas, atributos sísmicos, redes neuronales convolucionales profundas

Descripción:

Uno de los mayores retos en la interpretación sísmica es el uso de grandes volúmenes de datos generados durante la etapa de exploración para la definición de nuevos prospectos de hidrocarburos, lo cual ocasiona un aumento en el tiempo requerido para la interpretación manual de estructuras geológicas (fallas y fracturas). Debido a esto, la detección automática de fallas geológicas es un proceso relevante para la industria petrolera.

Desde la perspectiva de la visión por computador, la tarea de detección de fallas puede ser interpretada como un problema de segmentación, el cual ha sido ampliamente analizado usando redes neuronales convolucionales. No obstante, tradicionalmente se usa como dato de entrada la imagen sísmica en el dominio de la amplitud, por lo cual puede tener insuficiente información para cumplir con la tarea propuesta. En este trabajo, se propone el uso de multi-atributos sísmicos de tipo geométrico y de amplitud, sintetizando la información con el Análisis de Componentes Principales, como una forma de preprocesamiento de los datos sísmicos, para mejorar el desempeño en la tarea de segmentación de fallas geológicas con una red convolucional de tipo U-NET y autoencoder, la cual permite detectar de manera eficiente las discontinuidades en datos reales y sintéticos. La propuesta presentada en este trabajo obtuvo una ganancia de 0.45 SSIM con respecto a los métodos tradicionales sobre datos sintéticos y reales.

* Trabajo de Grado

** Facultad de Ingeniería Físico-mecánicas. Escuela de Ingeniería de Sistemas. Director: Yesid Paul Goyes Peñafiel. Candidato a Doctor en Ciencias de la Computación

Abstract

Title: Automatic detection of geological fractures and faults from image segmentation task using deep convolutional networks applied to seismic cubes*

Author: Bryan Daniel Alvarez Castillo**

Key Words: Seismic interpretation, image segmentation, geological faults, seismic attributes, deep convolutional neural networks

Description:

One of the greatest challenges in seismic interpretation is the use of large volumes of data generated during the exploration stage to define new hydrocarbon prospects, which causes an increase in the required time for manual interpretation of geological structures (faults and fractures). Therefore, automatic geological fault detection is an important process for the oil and gas industry.

From the perspective of computer vision, the fault detection task can be interpreted as a segmentation problem, which has been widely analyzed using convolutional neural networks. However, the input data used is the seismic image in the amplitude domain, so it may have no enough information to fulfill the proposed task. In this work, the integration of seismic multi-attributes of geometric and amplitude type is proposed, synthesizing information with Principal Component Analysis, as a way of pre-processing the seismic data looking forward to improving the performance in the task of segmentation of geological faults with a U-NET convolutional network and autoencoder. This implementation allows to efficiently to detect discontinuities in real and synthetic data. The proposal presented in this work improves the accuracy of 0.45 SSIM in comparison to the traditional methods on synthetic and real seismic data.

* Degree Work

** School of Physical-Mechanical Engineering. Departament of Systems Engineering and Informatics. Advisor, Yesid Paul Goyes Peñafiel. PhD Candidate in Computer Science.

Introducción

Las fallas geológicas son discontinuidades encontradas en las imágenes sísmicas, su detección y segmentación es importante para definir sistemas petrolíferos y posteriormente encontrar yacimientos de hidrocarburos. Sin embargo, realizar dicha tarea de forma manual consume tiempo y dinero, esto debido a la creciente cantidad de datos que se presentan en la sísmica.

Para solucionar el problema planteado se han implementado numerosos métodos para su detección automática, tales como el uso de atributos sísmicos, los cuales ayudan a remarcar las características de interés en los datos, resaltando las fallas de manera automática, facilitando su detección y segmentación. Sin embargo, la detección de fallas con los atributos no es tan precisa, esto puede ser debido al ajuste de los parámetros para calcularlos, ya que no es fácil adaptar los diferentes parámetros para que encuentren las discontinuidades (Xiong et al., 2018) o porque las imágenes contienen demasiado ruido, impidiendo la correcta interpretación por parte del algoritmo.

Otro enfoque que se le ha dado para solucionar esta labor ha sido la implementación de Redes Neuronales Convolucionales Profundas o *Convolutional Neural Network* (CNN) para facilitar la detección automática. Este tipo de redes ya han sido implementadas anteriormente para la identificación de objetos, rostros, letras, entre otros, demostrando ser eficaz para la tarea de clasificación (Ronneberger et al., 2015; Acuña Uribe et al., 2021). En geofísica también han sido implementadas las CNN para la segmentación de fallas geológicas, utilizando diversos tipos de redes ajustados para la interpretación sísmica, la más empleada es la CNN U-Net (Ronneberger et al., 2015).

Las CNN utilizadas para la segmentación de imágenes implementan un sistema binario de clasificación detallando pixel a pixel. Si existe la falla, el algoritmo mostrará el valor de 1 y en caso contrario mostrará el valor de 0, este tipo de clasificación permite a las CNN comprender las características de forma global en la imagen utilizada para el entrenamiento (Guo et al., 2018).

Un típico flujo de trabajo empleado para el entrenamiento de las redes en sísmica es usar solamente imágenes en escalas de amplitud, la cual muestra los cambios en la amplitud que marcan las diferentes capas del subsuelo (Henry, 2004). Sin embargo, este flujo de trabajo puede llegar a ser insuficiente para la precisión de la segmentación sísmica, esto debido a la pérdida de datos al descartar los atributos que se utilizan para facilitar el resalte de las fallas geológicas, ya que pueden ser una valiosa herramienta para mejorar la detección y la segmentación.

En este trabajo se entrenará una CNN con los datos de los atributos sísmicos relacionados con el realce de discontinuidades y zonas de fallas geológicas, esto con el fin de mejorar la precisión de la red al momento de la segmentación, utilizando la técnica del Análisis de Componentes Principales o *Principal Component Analysis* (PCA), la cual es un método estadístico que permite disminuir la cantidad de espacios muestrales n-dimensionales, conservando la información presentada (Rodrigo, 2017).

1. Objetivos

1.1 Objetivo General

Detectar automáticamente fallas y fracturas geológicas a partir de la técnica de segmentación de imágenes usando redes convolucionales profundas, aplicadas a cubos sísmicos sintéticos y reales aplicando diferentes niveles de ruido.

1.2 Objetivos Específicos

1. Seleccionar los atributos sísmicos más relevantes para la detección de fallas y fracturas geológicas de cubos sísmicos.
2. Diseñar un algoritmo para mejorar la detección automática de las fallas geológicas a partir de la segmentación de imágenes y atributos sísmicos con redes convolucionales profundas.
3. Evaluar la red entrenada para la detección automática de fallas en diferentes conjuntos de datos sísmicos induciendo diferentes niveles de ruido a diferentes cubos obtenidos y diferentes transformaciones como técnica de aumento de datos, para estimar la precisión y rendimiento de la red.

2. Marco teórico

En este capítulo se presentan los antecedentes teóricos relacionados con las fallas geológicas, atributos sísmicos y redes neuronales convolucionales (CNN) utilizadas para su segmentación. Primeramente, se introducirán los conceptos de cubos sísmicos y los datos empleados para el entrenamiento de la red, además, se ampliarán los conceptos y se explicará sobre los atributos sísmicos relacionados con las fallas geológicas. Por último, se presentará la CNN utilizada para la segmentación de fallas geológicas, su estructura y descripción.

2.1. Volumen sísmico

Los volúmenes sísmicos son un conjunto de imágenes bidimensionales de diferentes partes de la sísmica posicionados en una matriz tridimensional, representados por los ejes x, y, z. Este conjunto de datos es mayormente estudiado por medio de una computadora, debido a la gran cantidad de información que poseen.


Las imágenes son obtenidas luego de interpretar los datos obtenidos en los diferentes pozos donde se ha realizado el estudio, mostrando las diferentes capas, forma de las estructuras geológicas y sus profundidades sin haber tenido la necesidad de perforar en la zona, esto es posible utilizando una fuente generadora de energía (explosivos, camiones vibroseis, entre otras fuentes) y sensores (geófonos) distribuidos estratégicamente en la zona (Figura 1). Se estudian las diferentes propiedades de las ondas resultantes tales como su energía, su tiempo de viaje, y su propagación en el subsuelo (Estrada, 2008).

Los datos obtenidos se almacenan en formatos SEG-Y, desarrollado por la Sociedad de Exploración Geofísica (SEG). Estos formatos consisten en 3 partes: la primera parte son 3200 bytes codificados en EBCDIC (código estándar de 8 bits encargado de la representación de

caracteres alfanuméricos) de texto describiendo los datos, la segunda parte consiste en 400 byte de cabeceras que poseen información sobre el contenido del archivo y, por último, el archivo contiene los valores de la traza de la sísmica, pesando para cada una 240 byte de almacenamiento (Stockwell & Cohen, 2002). Los archivos fueron tratados con la librería segyio en el lenguaje de programación de Python, obteniendo los datos en forma de arreglos numéricos de 3 dimensiones.

Figura 1.

Propagación de una onda en el subsuelo.



Nota: Imagen tomada de (lorenzor, s.f.) muestra como la fuente (un camión), hace propagar una onda, y dada la propiedad de reflexión se refleja en los diferentes niveles del suelo llegando finalmente a los receptores, tras la recepción de los datos se garantiza una uniformidad independientemente de los receptores utilizados para el procedimiento.

La correcta interpretación de los datos geológicos cumple un rol importante al momento de mapear la estructura sísmica, para el descubrimiento de yacimientos de hidrocarburos y para la planeación de la perforación de los pozos (Acuña Uribe et al., 2021).

2.2. Atributos sísmicos.

El objetivo principal de la interpretación sísmica es el correcto mapeo del subsuelo y la descomposición de las diferentes características, en donde es posible encontrar diferentes reservorios de hidrocarburos tales como el petróleo o el gas, asegurando la ubicación de sus yacimientos y facilitando la planeación para su perforación. Los atributos sísmicos fueron introducidos como herramientas para la interpretación sísmica.

Los atributos sísmicos son medidas cuantitativas que se ejercen sobre datos sísmicos, los cuales son utilizados para remarcar una característica de interés (Chopra & Marfurt, 2005). Desde su introducción cerca del año 1970, los atributos sísmicos han sido mejorados y modificados apoyándose con el avance de la tecnología para mejorar su precisión, actualmente es una de las herramientas más utilizadas para la detección de características en la sísmica.

Con el avance y mejora de la tecnología se han podido evaluar mayores cantidades de datos, pudiendo examinar desde datos sísmicos 2D a datos sísmicos 3D, cambiando el cómo se calculan los atributos y permitiendo, a partir de los años de 1990, desarrollar el concepto de atributos 3D. Uno de los primeros estudios fue realizado por Dalley et al. (1989), en el cual introdujeron dos conceptos importantes para el estado del arte de los atributos: los mapas de buzamiento, azimuth y la extracción de amplitudes (Chopra & Marfurt, 2005).

Durante las últimas décadas más de 600 autores han publicado artículos aplicando los atributos sísmicos en el estudio de la geología (Ahmed, 2001), tales como la inclusión del atributo de coherencia a mediados de los años de 1990, el cual fue desarrollado para capturar algunas discontinuidades en los datos. A finales de esos años se introdujo la descomposición espectral, la cual ha cambiado las técnicas de interpretación sísmica, proponiendo nuevas herramientas para su

cálculo (Dat, 2008), con la capacidad de retornar tres volúmenes sísmicos con un solo dato de entrada donde cada uno de los tres resultados representa una diferente banda de frecuencias permitiendo el análisis de diferentes tipos de estructuras (Dat, 2008). Debido al creciente aumento de atributos publicados por diferentes autores, en 1994 se propuso dividir los atributos en dos categorías globales: Atributos geométricos y atributos físicos.

- **Atributos físicos:** son atributos relacionado con las mediciones del frente de onda de propagación, la litología, características de las ondículas, los espectros de amplitud y otras características físicas, utilizados para resaltar características estratigráficas e identificar la presencia de hidrocarburos.
- **Atributos geométricos:** son atributos que definen las relaciones espacio temporales de los atributos, además miden la configuración y la continuidad de las capas, utilizados para la detección de fracturas geométricas.

Sin embargo, varios autores también han dado sus diferentes clasificaciones (Ahmed, 2001), dependiendo del tipo de atributo y las características que se utilizan para su cálculo, como por ejemplo en Tarner (1999) el cual propone que los atributos sísmicos pueden estar divididos en función de la velocidad, la amplitud, los tiempos reflexión entre otras características.

A pesar de ser útiles para la interpretación sísmica, el empleo de solamente los atributos sísmicos puede llegar a ser insuficiente, mostrando una gran cantidad de ruido sin la capacidad de mostrar las discontinuidades (fallas y fracturas) de manera correcta.

2.3. Análisis de Componentes Principales

El Análisis de Componentes Principales (PCA), es un método estadístico que busca sintetizar la información suministrada, disminuyendo la cantidad de variables perdiendo la menor cantidad de información posible.

El PCA es aplicable cuando se tienen una gran cantidad de correlaciones entre los datos, indicando que existe redundancia y es posible eliminar datos sin que el resultado general cambie (de la Fuente Fernzadez, 2001).

En el PCA se dispone de una serie de variables de tamaño p ($x_1, x_2, \dots, x_p$), sobre un conjunto de individuos. Se requiere hallar un nuevo conjunto de variables de tamaño $k \leq p$ ($y_1, y_2, \dots, y_k$) que no estén correlacionadas entre sí, y que además las varianzas disminuyan progresivamente. Obteniendo la ecuación.

$$Y_{1k} = x_{1p}u_{1p} + x_{2p}u_{2p} + \dots + x_{ip}u_{ip} \quad (1)$$

Con Y_{1k} como el valor de la componente, x_{1p} el valor de las variables del primer elemento y u_{1p} valores constantes.

La ecuación puede mostrarse matricialmente como

$$\begin{bmatrix} Y_{11} \\ Y_{12} \\ \vdots \\ Y_{1n} \end{bmatrix} = \begin{bmatrix} X_{11} & \dots & X_{p1} \\ X_{12} & \dots & X_{p2} \\ \vdots & \ddots & \vdots \\ X_{1n} & \dots & X_{pn} \end{bmatrix} \begin{bmatrix} u_{11} \\ u_{12} \\ \vdots \\ u_{1p} \end{bmatrix} \quad (2)$$

O en una notación abreviada

$$Y_1 = Xu_1 \quad (3)$$

Tomando Y_1 como el valor del vector de componentes, X la matriz de variables y u_1 un vector de constantes (de la Fuente Fernzadez, 2001).

2.4. Visión por computador

Como humanos somos capaces de percibir el mundo que nos rodea de forma tridimensional, capaces de detallar objetos cercanos o reconocer personas u objetos previamente vistos. En las imágenes digitales, sin embargo, se toma una captura de un ambiente tridimensional y se pasa a uno bidimensional, obteniendo una matriz de datos de señales bidimensionales que se presentan en una función $f(x, y)$.

$$f(x, y) = \begin{bmatrix} f(1,1) & \cdots & f(1,N) \\ \vdots & \ddots & \vdots \\ f(N,1) & \cdots & f(N,N) \end{bmatrix} \quad (4)$$

Cada uno de los puntos dentro de la matriz es un valor, que dependiendo de la cantidad de brillo de la señal se encuentra en un rango entre 0 y 255, los valores cercanos a 0 señalan negros y los cercanos a 255 señalan blancos. El resultado son imágenes en escalas de grises.

Con la inclusión de imágenes digitales se han implementado métodos para procesar y analizar imágenes para que puedan ser tratadas por un computador, realizando de manera automática diferentes tipos de tareas tales como la clasificación de objetos dentro de las imágenes, el ajuste o la restauración de las imágenes o la segmentación de una característica de interés dentro de la imagen (Petron & Petron , 2010).

2.5. Redes neuronales convolucionales


El uso de la inteligencia artificial ha aumentado en los últimos años, utilizadas para emular las diferentes percepciones que tiene el humano, tales como la clasificación de objetos específicos en imágenes, la recreación de medios, la identificación de patrones, ser capaz de imitar las conversaciones y lenguajes humanos, entre otras funcionalidades. Con la constante evolución de las redes también se han podido realizar avanzadas técnicas para el procesamiento de imágenes.

El tipo de red más utilizada para esta labor son las Redes Neuronales Convolucionales o *Convolutional Neural Network* (CNN). Un ejemplo de estas redes se presenta en Lawrence et al. (1997), donde se emplean las redes para la detección de rostros o en la medicina como en Ronneberger et al. (2015), donde se usan en la segmentación de imágenes médicas.

Una CNN es una red profunda capaz de tomar una imagen de entrada y capturar las dependencias espaciales de la imagen, diferenciando aspectos u objetos dentro del dato de entrada. Con la ayuda de diferentes filtros realiza una serie de convoluciones disminuyendo la dimensión de los datos y tomando solamente los más relevantes en la imagen, como se muestra en Figura 2.

Figura 2.

Esquema de una red neuronal convolucional



Nota: Tomado de (Gorodissky et al., 2018), CNN que disminuye sus dimensiones a lo largo de las capas.


Las CNN son utilizadas para tres tipos de tareas en el procesamiento de imágenes:

- Clasificación: conocer qué tipo de objetos se encuentra dentro de la imagen, capaz de entender patrones que se repiten dentro de una imagen. Eso se emplea en el reconocimiento de individuos o de rostros, por ejemplo.
- Regresión: capacidad de una red de predecir el valor de una variable según los datos de entrada. Se utiliza, por ejemplo, para mejorar la calidad de imágenes con mucho ruido.
- Segmentación: capacidad de aislar características de interés dentro de una imagen. Se suele usar en la medicina para la segmentación de órganos en imágenes médicas.

2.5.1. *Redes neuronales convolucionales en sísmica*

Dado que en la sísmica la segmentación de características es crucial para la detección de hidrocarburos, las CNN también han sido utilizadas para la segmentación automática de fallas geológicas.

Un ejemplo del empleo de CNN en la sísmica se realiza en Xiong et al. (2018), donde se emplean las redes CNN para la segmentación de fallas, realizando un proceso de clasificación, mostrando si se encuentra una falla en el pixel evaluado, mostrando el valor de 1 un caso de existir una falla y el valor de 0 en caso contrario, similar a la clasificación empleada para distinguir animales o rostros dentro de una imagen.

Figura 3.*Red CNN para la clasificación de fallas*


Nota: Imagen tomada de (Xiong et al., 2018)

Sin embargo, el procedimiento es demasiado costoso, computacionalmente hablando, debido a que se tiene que calcular la probabilidad de cada punto dentro de un cubo sísmico, lo cual aumenta cuantos más datos se tenga dentro de este.

2.5.2. Redes autoencoders.


Otro tipo de redes utilizadas para la segmentación de fallas geológicas son las redes *autoencoders*. La característica principal de este tipo de redes es que se dividen en dos partes, un codificador, el cual se encarga de aprender las características principales de la imagen, y comprimir la imagen realizando convoluciones, disminuyendo la dimensionalidad inicial. Y la segunda parte llamada decodificador, la cual es la encargada de descomprimir la imagen que pasa por el codificador realizando operaciones *upsampling*, retornando la imagen a las dimensiones originales.

Un tipo de red *autoencoder* es implementada en Wu et al. (2018) donde utilizan la red InvesionNet, una red que retorna los modelos de las velocidades de la onda, mostrando las capas y discontinuidades en los datos.

Figura 4.*Implementación de la InversionNet*

Como se muestra en la Figura 5 al haber realizado la convolución del dato de entrada procede a realizar el *upsampling* retornando el dato a sus dimensiones originales.

Red U-Net



A pesar de tener características de las redes *autoencoders*, este tipo de red cuenta con conexiones entre las diferentes capas, creando conexiones de omisión que permiten evitar los mínimos locales durante el entrenamiento, además es capaz de recuperar características durante la predicción.

Actualmente, esta red es utilizada para la segmentación de características en imágenes de diferentes temas, uno de ellos la segmentación automática de fallas geológicas, tales como en Wu et al. (2019), donde se implementó la red U-Net para dicha segmentación.

Tabla 1.

Características de las CNN

RED NEURONAL CONVOLUCIONAL	DESCRIPCIÓN	DESVENTAJAS
RED CNN	Red que se utilizó como un para la clasificación de fallas dentro de una imagen sísmica, resaltando las fallas con valores de 1 y las no fallas con valores de 0	Es una red con un coste computacional demasiado alto, debido a que debe predecir todos los píxeles para encontrar una falla
INVERSION-NET	Un tipo de red <i>autoencoder</i> , que utiliza codificador y decodificador para hallar las características deseadas dentro de las imágenes. En el caso de la InversionNet, se hallan los modelos de velocidades	Tiende a tomar mínimos locales durante el entrenamiento, además de la pérdida de características.
U-NET	Red implementada para la segmentación de imágenes, es similar a las redes <i>autoencoders</i> . Sin embargo, posee conexiones entre diferentes capas.	Al poseer las conexiones entre las diferentes capas aumenta su coste computacional a comparación de las redes <i>autoencoders</i> .

2.6. Métricas de evaluación.

Para realizar una evaluación cuantitativa sobre el resultado en las predicciones de las redes neuronales convolucionales, es posible comparar el resultado obtenido al entrenar la red con el resultado esperado, con la finalidad de demostrar la eficacia de la red, existiendo diferentes

métricas para evaluar si la red realizó de forma correcta la segmentación. Algunas de las más utilizadas se explicarán a continuación.

2.6.1. Índice de similitud estructural

El índice de similitud estructural (SSIM), es una métrica que cuantifica la similitud de dos imágenes, una original, y otra expuesta a algún tipo de procesamiento previo, utilizada generalmente al evaluar imágenes tras la transmisión de datos. Utilizada en Brunet et al., 2012 como una mejora ante el error cuadrático medio (MSE).

Se tienen dos imágenes $x \in R_+^N$ y $y \in R_+^N$, el SSIM utiliza tres componentes para comparar los datos, un término de distorsión de luminancia (media), una distorsión de contraste (varianza) y un término de correlación, expuestos en las siguientes ecuaciones:

$$l(x, y) = \frac{2\bar{x}\bar{y} + c_1}{\bar{x}^2 + \bar{y}^2 + c_1} \quad (5)$$

$$c(x, y) = \frac{2S_x S_y + c_2}{S_x^2 + S_y^2 + c_2} \quad (6)$$

$$s(x, y) = \frac{S_{xy} + c_3}{S_x S_y + c_3} \quad (7)$$

Donde $\bar{x}$, $\bar{y}$, S_x^2 , S_y^2 y S_{xy} representan respectivamente la media local de x e y , la varianza local de x e y , la covarianza entre x e y . Las constantes c_1, c_2, c_3 son pequeñas constantes que caracterizan los efectos de saturación.

El SSIM puede ser escrito como:

$$\text{SSIM}(x, y) = S_1(x, y) S_2(x, y) \quad (8)$$

Donde:

$$S_1(x, y) = l(x, y) = \frac{2\bar{x}\bar{y} + c_1}{\bar{x}^2 + \bar{y}^2 + c_1} \quad (9)$$

$$S_2(x, y) = c(x, y)s(x, y) = \frac{2S_x S_y + c_2}{S_x^2 + S_y^2 + c_2} * \frac{S_{xy} + c_3}{S_x S_y + c_3} \quad (10)$$

En la cual los resultados varían entre 0 y 1, esta métrica cuantifica la pérdida de calidad de la imagen. El SSIM es utilizado también para precisar de manera porcentual las diferencias entre dos imágenes similares (Brunet et al., 2012). Los valores de SSIM cercanos a 1 y 0 indican alta y baja similitud estructural, respectivamente.

2.6.2. *Pixel accuracy*

Es una métrica cuyo objetivo es verificar la precisión de dos imágenes evaluando la similitud pixel a pixel dentro de la imagen, teniendo una imagen base frente a una imagen predicha. Evaluando una máscara binaria, obteniendo una precisión con la siguiente ecuación:

$$Precisión = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

Siendo TP los valores verdaderamente positivos, TN los valores realmente negativos, FP los valores falsamente positivos y FN los valores falsamente negativos.

2.6.3. *Intersection-Over-Union*

La *Intersection-Over-Union* (IoU), es una de las métricas más comúnmente utilizadas para evaluar la segmentación de imágenes (Tiu, 2018), en la cual se evalúan el número de píxeles en común (intersección) dividido entre el número de píxeles presentes en ambas imágenes (unión).

$$IoU = \frac{ImgReal \cap ImgPredicción}{ImgReal \cup ImgPredicción} \quad (12)$$

3. Metodología

3.1 Etapa 1: Seleccionar los atributos sísmicos más relevantes para la detección de fallas y fracturas geológicas de cubos sísmicos

Corresponde a la investigación de información bibliográfica referente a los atributos sísmicos más utilizados para la tarea de segmentación de fallas y fracturas sísmicas. Además de obtener y visualizar los atributos de diferentes fallas con software especializados para la tarea, tales como OpendTect para el cálculo de las fallas y el lenguaje Python para su correspondiente visualización y estudio.

Para la realización de este proyecto se tuvieron en cuenta principalmente los atributos geométricos, debido a su mayor capacidad para el realce de discontinuidades en los datos sísmicos (Chopra & Marfurt, 2005). Utilizando un total de 7 atributos sísmicos detallados a continuación.


3.1.1. *Contraste de amplitud*

Atributo introducido por Adnan Aqrabi & Hellem Boe (2011), adaptando el método de detección de bordes Sobel, dando la normalización de la amplitud y la ponderación de las dimensiones. La normalización de la amplitud facilita la discriminación entre las amplitudes altas y las amplitudes bajas y la ponderación disminuye las intensidades de las discontinuidades horizontales y verticales.

Este atributo ayuda a revelar las discontinuidades en los datos sísmicos, las amplitudes más altas indican las fallas, como se muestra en la Figura 6b, este atributo remarca las discontinuidades de la falla.

Figura 6.

Implementación del atributo contraste de amplitud



Nota: a) Imagen de amplitud de la sísmica, b) implementación del atributo de contraste de amplitud. Las secciones vistas en blanco pertenecen a las amplitudes más altas.

Con las observaciones tomadas se muestra que el atributo es eficaz para la detección de bordes, sin embargo, al introducirse datos con demasiado ruido no siempre detecta las fallas de manera correcta, tomando erróneamente una gran cantidad de datos como fallas.


3.1.2. Ant Tracking

Atributo introducido por Pedersen et al. (2002), implementa la “inteligencia de enjambre”, método por el cual recibe su nombre. Un ejemplo análogo es la capacidad que tiene una hormiga de comunicar el camino con el uso de feromonas, influenciando una ruta de enjambre. Para el caso del atributo se implementaron varias “hormigas electrónicas” que se desplazan por los bordes de la sísmica. Se distribuyen por todo el volumen de datos y cada una toma un camino teniendo en cuenta el código preestablecido, al encontrar alguna irregularidad en el camino (una falla) sueltan “feromonas” que agrupan los demás individuos y realizan una trazabilidad del nuevo camino,

como se ilustra en la Figura 7b. Sin embargo, las hormigas se dispersan en áreas con mucho ruido, impidiendo que se encuentren las irregularidades.

Figura 7.

Resultado de aplicar el atributo Ant Tracking



Nota: a) Imagen de amplitud de la sísmica, b) implementación del atributo de *Ant Tracking*, las líneas negras son las irregularidades en el camino encontrado por las “hormigas electrónicas”, Imagen tomada de (Pedersen et al., 2002)

Con el paso del tiempo la capacidad de segmentación de este atributo ha sido mejorado, tal es el caso del mostrado en Acuña Uribe et al. (2021), el cual se propuso la integración de varios atributos sísmicos, con el fin de mejorar la inteligencia de enjambre, disminuyendo el ruido y resaltando de mejor manera las discontinuidades.

3.1.3. Varianza (método de bordes)


El atributo de varianza es un método utilizado para aislar bordes o discontinuidades de un conjunto de datos, el método calcula la varianza de la población normalizada, utilizando la ecuación

$$\sigma_t^2 = \frac{\sum_{j=t-L/2}^{j=t+L/2} w_{j-1} \sum_{i=1}^i (x_{ij} + \tilde{x}_j)^2}{\sum_{j=t-L/2}^{j=t+L/2} w_{j-1} \sum_{i=1}^i (x_{ij})^2} \quad (13)$$

Donde x_{ij} es el valor del dato, en la posición horizontal i , y la posición vertical j . Dando como resultado lo mostrado en la Figura 8b.

Figura 8.

Atributo de varianza



Nota: a) Imagen de amplitud de la sísmica, b) implementación del atributo de la varianza, mostrando los bordes las secciones más blancas vistas en la imagen.


Con los datos visualizados el atributo de varianza no es preciso con datos demasiado ruidosos, no mostrando las fallas segmentadas de manera correcta.

3.1.4. Impedancia acústica relativa

La impedancia acústica es un atributo físico que se utiliza principalmente en la litología, teniendo en cuenta el ancho de banda de la onda, ya que muestra el contraste acústico indicando una secuencia de límites. Dependiendo de los valores suministrados aclara y realza las discontinuidades, también puede indicar la porosidad o contenido el fluido en el yacimiento (Taner, 1992).

Figura 9.

Atributo de impedancia acústica relativa




Nota: a) Imagen de amplitud de la sísmica, b) implementación del atributo de impedancia acústica relativa realzando los límites del dato de la amplitud, como se mostrado dentro del cuadro rojo en la imagen.

3.1.5. Magnitud del gradiente

Atributo sísmico principalmente desarrollado para el realce de curvaturas en los datos sísmicos, utilizado para la caracterización del subsuelo. Sin embargo, en Gao (2013), proponen la implementación de este atributo para que, por medio de las discontinuidades de las curvaturas, sea posible la extracción de fallas en los datos. Como se muestra en la Figura 10b, aunque las líneas resaltadas pertenecen a la curvatura del dato, se pueden apreciar las discontinuidades en los trazos.

Figura 10.

Atributo de magnitud del gradiente



Nota: a) Imagen de amplitud de la sísmica, b) implementación del atributo de magnitud del gradiente, las secciones mostradas dentro de los cuadros rojos son las representaciones de las fallas.

Un problema encontrado con este atributo es que facilita la segmentación manual de las fallas, sin embargo, no las segmenta de manera apropiada, llegando a ser confuso el segmentar las fallas con datos varios datos, o con datos muy ruidosos.


3.1.6. Atributo Likelihood

Se utiliza el método del máximo *Likelihood*, usado para la estimación de una distribución estadística en los datos (Normal, Gaussian, entre otros). En general las fallas son frecuentemente caracterizadas en términos de longitud de la traza, intensidad, densidad u apertura, dichas características son bien descritas por distribuciones estadísticas (Rizzo et al., 2017). Una vez hallado el tipo de distribución estadístico, es posible resaltar las fallas a partir de este. Así, sin importar las variaciones de ángulos o la longitud de la falla es posible segmentarla (Rizzo et al.,

2017). Sin embargo, es uno de los métodos más costosos en términos de computación, debido a que tiene que evaluar los todos los datos y al ser muy sensible con las variaciones entre ellos, no siempre resalta solamente las fallas.

Figura 11.

Atributo Likelihood



Nota: a) Imagen de amplitud de la sísmica, b) implementación del atributo de *Likelihood* con datos resaltados al obtener la distribución estadística del dato de amplitud.

En las pruebas realizadas es el atributo con mejores resultados obtenidos, pero también es uno de los más costosos computacionalmente, debido a la gran cantidad de cálculos que debe hacer para segmentar las imágenes.


3.1.7. Skeletonization

Técnica de reconocimiento ampliamente utilizada en el análisis de la sísmica, también llamada “*Skeletonization* sísmica”. Es un método de reconocimiento de patrones que utiliza ciclos o las formas de onda como patrones primitivos. La cantidad de estos patrones puede variar dependiendo

del autor, pudiendo remarcar las fallas al evaluar los patrones del dato sísmico (Vasudevan, Cook, & Eaton, 2006).

Figura 12.

Atributo Skeletonization



Nota: a) Imagen de amplitud de la sísmica, b) implementación del atributo de Skeletonization con fallas encontradas en color blanco.

El atributo muestra una buena segmentación de fallas, sin embargo, depende demasiado de los datos de entrada para realizarlos de manera correcta.

3.2 Etapa 2: Diseñar un algoritmo para mejorar la detección automática de las fallas geológicas a partir de la segmentación de imágenes y atributos sísmicos con redes convolucionales profundas.

Una vez seleccionados y probados los atributos mostrados en la Etapa 1, se procedió a buscar una base de datos con cubos sísmicos con las fallas etiquetadas, o etiquetar manualmente

cubos sísmicos para obtener una mayor variedad de datos. Además, se busca información sobre las CNN que se implementan en el proyecto


3.2.1. Método propuesto.

La propuesta para mejorar la precisión en la tarea de segmentación de las fallas geológicas es el uso de los atributos sísmicos como herramienta para el pre-procesamiento de los datos sísmicos, esto debido a que son formas de segmentar fracturas y facilitarían a la red entrenada el entendimiento de las características de las fallas, obteniendo una mayor cantidad de información de entrada en los datos sísmicos con respecto al estado del arte (Wu et al., 2019; Xiong et al., 2018), en los cuales para el entrenamiento de las redes solamente se emplearon los datos de la amplitud sísmica.

No obstante, uno de los problemas al usar una gran cantidad de datos es que se deben tener en cuenta la correlación entre cada uno de ellos, atendiendo al hecho que si existen demasiadas variables correlacionadas afecta en el estudio de los resultados, creando una redundancia en los datos (Sanchez Sellero, 2008-2009) Para evitar este hecho, se utilizó el Análisis de Componentes Principales, el cual reduce la cantidad de variables sin perder la información de interés. Para esto, se debe tomar el componente con la mayor cantidad de información y que, al mismo tiempo, se relaciona con la varianza de los componentes principales. Como se muestra en la Figura 13, el dato con mayor varianza de información es el primer componente. Por ende, se decide tomar este como representante para la información


Figura 13.

Varianza explicada para los componentes principales del cubo multiatributo



Nota: Varianza contra la cantidad de componentes principales.

Para la ejecución del Análisis de Componentes Principales se realizó una matriz con una cantidad de filas equivalente a la multiplicación de las dimensiones de los cubos sísmicos (para los cubos de 128x128x128 el número de filas será equivalente a 2097152) y con una cantidad de columnas igual al número total de atributos evaluados (para el caso del proyecto se cuenta con un total de 8 atributos contando con los datos de la amplitud inicial). Al ejecutar el PCA, cuya operación matemática es mostrada en de la Fuente Fernzadez, (2001), con la librería de Python `sklearn.decomposition.PCA`. donde los datos de entrada corresponden a la matriz anteriormente descrita, se obtuvo como resultado un vector de datos con la misma cantidad de columnas que la matriz de entrada, pero con las variables indicadas por el PCA. Luego se retornan los datos obtenidos a las dimensiones iniciales, obteniendo nuevos cubos de datos, estos son los utilizados para entrenar la red. Ilustrando el procedimiento en la Figura 14.

Figura 14.*Esquema de datos para el cálculo del PCA*


Nota: La imagen representa el procedimiento efectuado para obtener datos utilizando diferentes atributos concatenados con PCA.

3.2.2. Red neuronal convolucional


En este proyecto se usó una red neuronal convolucional conocida como U-Net, es empleada en (Wu et al., 2019), donde se demuestra la eficacia de la red para la predicción de fallas geológicas. Y una red neuronal convolucional autoencoder, la cual es empleada en (Wu et al., 2018) mostrando su eficacia en la segmentación de capas basado en las velocidades.

Además, se contó con un total de 200 datos sísmicos diferentes, cada uno con dimensiones de 128x128x128 con sus respectivos datos de segmentaciones, tomando valores binarios de 1 si se encuentra una falla y 0 en caso contrario. Se utilizó el 20% de los datos para la etapa de validación de la red, como se muestra en la Figura 15 y Figura 16. Al final se obtuvo un conjunto de datos con dimensiones de 128x128x128 con las fallas segmentadas.

Las redes cuentan con 8 capas convolucionales, divididas en dos diferentes etapas, las 4 primeras capas funcionan como codificador (o compresión de datos), utilizando un *maxPooling 3D* para la reducción de dimensiones, y las últimas 4 capas funcionan como decodificador (función para descomprimir datos) utilizando un *upSampling 3D* para retornar los datos a las dimensiones originales. Además, la red U-Net contiene concatenaciones entre las capas número (4, 3), (5, 2) y (6, 1), haciéndola una red completamente conectada o *fully connected*.

Figura 15.*Implementación de la U-net*

Nota: Red U-net empleada para el entrenamiento de datos, obteniendo como resultado las fallas geológicas segmentadas

Figura 16.*Implementación de la CNN Autoencoder*

Nota: Red neuronal convolucional empleada para el entrenamiento de datos, obteniendo como resultado las fallas geológicas segmentadas

Para la ejecución de las redes se emplearon las especificaciones obtenidas de Wu et al. (2019) con los siguientes parámetros:

- Entrenamiento de la red con 50 épocas.
- Optimizador Adam (Kingma & Ba, 2014) para el entrenamiento.
- Tasa de aprendizaje: 1/10000.
- Función de pérdida: Entropía binaria cruzada, la cual es utilizada mayormente para la segmentación binaria aplicando al caso actual, además, es igualmente utilizada en Wu et al. (2019), definida con la función.

$$-\frac{1}{N} \sum_{i=1}^N y_i * \log(p(y_i)) + (1 - y_i) * \log(1 - p(y_i)) \quad (14)$$

donde y_i son las etiquetas y $p(y_i)$ es la probabilidad de predicción.

El conjunto total de datos empleados fue de 240 cubos sísmicos, contando los cubos utilizados en la etapa de entrenamiento y en la etapa de validación, se contó con una GPU Tesla P100-PCIE-16GB con una memoria RAM de 26.3 GB, ejecutado en el ambiente *Colaboratory* de Google con el lenguaje de programación de Python y la librería de Tensorflow 2.6.0.

3.3 Etapa 3: Validar la red entrenada para la detección automática de fallas en diferentes conjuntos de datos sísmicos induciendo diferentes niveles de ruido para estimar la precisión y rendimiento de la red.


En esta etapa se incluyen los diferentes preprocesamientos a las imágenes sísmicas obtenidas en la Etapa 2, induciéndoles diferentes niveles de ruido Gaussiano y calculando los correspondientes atributos detallados en la etapa 1, esto con el fin de poder mejorar la precisión del algoritmo con datos sísmicos reales. Se utilizó el siguiente flujo de trabajo.

- La variación de ruido Gaussiano, esto debido a que los datos sísmicos reales suelen tener una gran cantidad de ruido.
- La rotación de las imágenes, esto es posible de realizar ya que las fallas sísmicas pueden presentarse de diferentes ángulos y direcciones.

Obteniendo una mayor cantidad de cubos sísmicos a los obtenidos solamente con los datos sintéticos. Los datos obtenidos en esta etapa se entrenan en la red y se evalúan los resultados.

Figura 17.

Datos con el procesamiento de aumento de datos



Nota: Figura a) Dato sísmico sin modificación, b) dato sísmico con 10% de ruido, c) dato sísmico con 20% de ruido, d) dato sísmico con 50% de ruido, e) imagen rotada 90°, f) imagen rotada 180°, g) imagen rotada 270°.

Una vez realizadas las transformaciones a los cubos se obtuvo una gran cantidad de datos, sin embargo, dadas las limitaciones en los recursos de computo (mostrada en la sección 3.2) se optó por disminuir la cantidad de datos, esto debido que no fue posible entrenar la red con toda la información obtenida.

En este enfoque se añadió al conjunto de datos original de 100 cubos sísmicos, un nuevo conjunto de 100 cubos sísmicos nuevos, con dimensiones de 128x128x128. Teniendo 50 datos segmentados manualmente y otros 50 al aplicar técnicas para el aumento de datos, tales como añadir ruido gaussiano o rotar en diferentes ángulos los cubos originales (mostrado en la Figura 17). Así, se obtuvo un total de 200 datos y de la misma manera se cuenta con el 20% de datos para la validación (40 cubos sísmicos).

4. Base de datos

Uno de los mayores problemas que se encontraron para la culminación del trabajo, ha sido la escasa cantidad de datos sísmicos interpretados encontrados de manera abierta, debido a las diferentes restricciones que se tienen de estos datos. Es aún más difícil hallar conjuntos de datos reales que contengan las interpretaciones de fallas geológicas, por el gran esfuerzo (coste y tiempo) que se requiere para realizarlos e interpretarlos ya que cada interprete debe encontrar y resaltar las fallas en todas las secciones de los cubos sísmicos, teniendo que interpretar cientos de imágenes si se realizara de forma manual. Por lo tanto, en este trabajo se han optado por tomar dos diferentes conjuntos de datos. Primeramente, se escogieron datos de fallas geológicas con su respectiva interpretación, generados de manera sintética para aumentar la cantidad de información de entrada en el algoritmo de entrenamiento. También se tomaron un conjunto de datos reales los cuales fueron interpretados de forma manual.

4.1 Cubos sísmicos sintéticos.

La generación de datos de manera artificial ha sido implementada en la sísmica para simular la propagación de ondas en la tierra, y así tener un mejor cálculo en los datos obtenidos de los sensores, usando diferentes ecuaciones y técnicas para su creación. El método del modelo de reflectividad (Ma et al., 2004), es empleado en la generación de los datos utilizados en el trabajo con el fin de mitigar la poca información encontrada con fallas geológicas interpretadas y aumentar la cantidad de datos.

Los cubos sísmicos fueron creados por Wu et al. (2019), cada cubo de dimensiones 128x128x128 píxeles. En primer lugar, se creó un modelo de reflectividad horizontal de una dimensión realizado sobre un modelo $r(x, y, z)$ con una secuencia de números aleatorios de rango

[-1, 1] generando lo mostrado en la Figura 18a. Para la creación de las ondulaciones en las estructuras se utiliza la función:

$$S_1(x, y, z) = a_0 + \frac{1.5s}{s_{max}} \sum_{k=1}^{k=N} b_k e^{\frac{(x-c_k)^2 + (y-d_k)^2}{2a_k^2}} \quad (15)$$

Los valores de a_0 , b_k , c_k , d_k y σ_k variables espacialmente específicas para crear las curvaturas del modelo, las cuales al alterarse de manera aleatoria entre rangos predeterminados darán como resultado diferentes tipos de estructuras, obteniendo un modelo $r(x, y, z + S_1(x, y, z))$; Dichas ondulaciones se pueden ver en la Figura 18b. Para incrementar la complejidad del modelo creado, haciéndolo más real, se agregaron algunas rupturas en el modelo, definidas como:


$$S_2(x, y, z) = e_0 + f_x + g_y \quad (16)$$

Los parámetros e_0 , f , g , valores aleatorios escogidos dentro de un rango determinado, dando como resultado un modelo $r(x, y, z + S_1 + S_2)$, mostrado en la Figura 18c.

Una vez obtenido el modelo, se realizaron las fallas geológicas definidas como una función Gaussiana o una función lineal. En el caso de la distribución Gaussiana la falla incrementa en cualquier dirección desde el centro del modelo y en el caso de la distribución lineal, la falla incrementa o disminuye en cualquier parte del plano evitando la cercanía entre las fallas generadas como se muestra en la Figura 18d. Se realiza la convolución del modelo con la función *Ricker wavelet* (normalmente usada para el análisis de datos sísmicos, haciéndolos homogéneos (Wang, 2015)), mostrado en la Figura 18e. Finalmente se agregó ruido aleatorio al modelo para emular el ruido que se generan en los datos sísmicos reales.

Figura 18.

Procedimiento para la creación de cubos sísmicos sintéticos




Nota: a) Reflectivity Model horizontal de una dimensión realizado sobre un modelo con una secuencia de números aleatorios de rango $[-1, 1]$. b) Creación de curvaturas en el modelo. c) Creación de rupturas en el modelo. d) Obtención de fallas en el modelo. e) Se realiza la convolución del modelo con la función Ricker wavelet, f) Se le agrega ruido al modelo. Imagen tomada de (Wu et al., 2019)

Los datos obtenidos con el método anterior contaban con la amplitud de la sísmica y su correspondiente fractura geológica segmentada como se muestra en la Figura 19.

Figura 19.

Segmentación de datos sintéticos.



Nota: a) imagen de una sección del dato sintético, b) imagen de la segmentación de las fallas en el dato sintético.

4.2 Cubo sísmico real F3 Países bajos


Con el fin de entrenar la red con datos reales se utilizó un conjunto de datos del Bloque F3. Esto debido a que la implementación de solamente datos sintéticos puede hacer que la red no segmente de manera correcta datos sísmicos reales. Además, dicho conjunto de datos también ha sido implementado en otros trabajos de segmentación como en Negm et al. (2020) para la predicción de gases usando múltiples atributos.

El bloque F3 es un cubo sísmico marino con una profundidad de 1200ms, adquirido en Países Bajos, más específicamente en el mar al norte de Holanda con coordenadas N 54° 52' 0.86"/ E 4° 48' 47.07" en el año de 1987. Es una zona donde el principal propósito consiste en la exploración de yacimientos de aceite y gas. El cubo cuenta con dimensiones de 650x950x1200 pixeles, como se muestra en la Figura 20.

Este cubo es utilizado como un Demo con la autoría del programa OpendTect, el cual es un software de código abierto. Esta adquisición es mayormente utilizada en la academia y pesa un total de 7.2 GB en formato .segy (OpendTect, 2020).

Figura 20.

Representación del cubo F3



Nota: Representación de una sección frontal, sagital y coronal de la amplitud del bloque F3.


Dada la escasa información obtenida sobre los datos de las fracturas en el cubo F3, se optó por realizar la segmentación manual de cada una de las imágenes del cubo. Esto con el uso de software libre utilizado para la edición de imágenes llamado PaintTool Sai, demarcando las fracturas con líneas blancas y las no fracturas con el color negro como se aprecia en la Figura 21b,

se intentó tomar como base el atributo *likelihood* para una segmentación más precisa, sin embargo, debido a las limitaciones computacionales no fue posible realizar este atributo en todo el cubo, por el gran tamaño que tiene de 1.2 Gb, siendo el mismo caso para los demás atributos. Así que se optó por realizar la segmentación sin ninguna referencia.

Con las segmentaciones de las fallas geológicas, se procedió a tomar pequeños cubos de 128x128x128 donde se presentaban una gran cantidad de fracturas, dividiendo el cubo original. Así, se obtuvo un total de 50 cubos sísmicos con datos reales segmentados de manera manual.

Figura 21.

Segmentación manual de las imágenes obtenidas del cubo F3



Nota: En la imagen a) Sección 2D del cubo F3, y en la b) Imagen con las fallas resaltadas manualmente, las líneas blancas son las fallas.

5. Resultados


5.1 Análisis y selección de atributos sísmicos

Para la realización de este proyecto se tuvieron en cuenta principalmente los atributos geométricos, debido a su mayor capacidad para el realce de discontinuidades en los datos sísmicos (Chopra & Marfurt, 2005).

Con los datos de las amplitudes y sus respectivas segmentaciones de fracturas geológicas, se procedió a calcular los diferentes atributos sísmicos a cada uno de los cubos. Para una validación entre los diferentes atributos estos son comparados con los datos de la segmentación esperada utilizando la métrica SSIM mostrada en la sección 2.6.1, mostrando los resultados en la Figura 22. Además, tras su implementación se obtuvieron los resultados expuestos en la tabla 2.


Figura 22.

Implementación de los atributos sísmicos en los datos obtenidos.



Nota: a) Amplitud de la sísmica, con los atributos de b) contraste de amplitud, c) *Ant tracking*, d) *Skeletonization*, e) *Likelihood*, f) impedancia acústica relativa, g) magnitud del gradiente y h) varianza.

Tabla 2.*Descripción de los atributos implementados*

ATRIBUTO	DESCRIPCIÓN	DESVENTAJAS	REPRESENTACIÓN
Contraste de amplitud	Muestran las fallas apoyándose en las variaciones de las amplitudes, y la detección de bordes.	Es muy fácil que se tomen bordes que no son fallas, es más notoria esta desventaja con datos muy ruidosos, teniendo que se ajustado dependiendo del tipo de dato entrante	
Ant Traking	Sistema inteligente que se distribuye sobre el cubo sísmico, para la obtención de las fallas.	Depende de los ajustes iniciales y la eficiencia del algoritmo, ya que con los datos de entrada erróneos no obtiene una buena predicción	
Varianza	Algoritmo utilizado para la detección de bordes en la sísmica, se tomando los datos con mayor varianza como fallas.	El algoritmo puede llegar a ser impreciso con datos con demasiado ruido o con una gran cantidad de contraste entre ellos, prediciendo puntos donde no se encuentran fallas	
Impedancia acústica relativa	Atributo utilizado para realzar discontinuidades en los datos sísmicos, apoyándose en el contraste acústico.	El algoritmo depende de los datos de entrada para llegar a resaltar las discontinuidades de forma correcta, en caso contrario no resaltaría las características de interés.	

Magnitud del gradiente	Resalta las curvaturas de la sísmica permitiendo observar con mayor facilidad las discontinuidades entre estas.	El atributo es menos eficiente cuanto mayor ruido exista, además no resalta las fallas, solamente permite resaltarlas teniendo en cuenta las discontinuidades vistas por las curvaturas	
Likelihood	Atributo que evalúa las características geométricas de la sísmica, y por medio de una distribución estadística permite segmentar las discontinuidades dentro de esta.	El algoritmo puede llegar a ser bastante pesado para la ejecución, además, es el atributo seleccionado con el mayor tiempo de compilación, además su eficiencia es menor cuanto mayor sea el ruido en los datos de entrada	
Skeletonization	Permite el reconocimiento de patrones dentro de los datos sísmicos, evalúa y discrimina las discontinuidades con los patrones obtenidos.	Depende de los datos de entrada y la cantidad de patrones para una correcta segmentación, teniendo que ser modificado cada vez que se ejecuta el algoritmo.	

5.2. Resultados de los entrenamientos de las redes neuronales convolucionales

Para realizar una validación sobre la eficacia del método propuesto, este fue comparado con la fuente bibliográfica dada por Wu et al. (2019), realizando el entrenamiento de la red convolucional U-Net y una red convolucional autoencoder.

Además, para la evaluación visual se obtuvieron los resultados usando cubos del conjunto de prueba, es decir, que no se usaron durante el entrenamiento, validándola con los atributos que mejor precisión mostraron.

Para evaluar las predicciones de forma cuantitativa se utilizan las diferentes métricas mencionadas en la sección 2.6, además, se realizan un total de 5 entrenamientos en cada una de las redes, variando los datos implementados en el entrenamiento y la validación.


Para el entrenamiento se utilizaron los 200 cubos sísmicos, con dimensiones de 128x128x128 cada uno, y con el 20% de datos para realizar la validación en el entrenamiento se emplearon 40 cubos sísmicos.

5.2.1. Entrenamiento con la red neuronal convolucional autoencoder

Al completar el entrenamiento se obtienen los datos de precisión evidenciados en la Figura 23 y los datos de las pérdidas evidenciados en la Figura 24.

Figura 23.


Evolución de la precisión durante el entrenamiento y test con CNN autoencoder




Como se muestra en la Figura 23 el método propuesto obtiene una mayor precisión en una menor cantidad de épocas, comenzando a aumentar la precisión a partir de la época 5, en contraste con el método tradicional que toma una mayor cantidad de épocas aumentar la precisión, tomando un total de 10 épocas para iniciar a mejorar la precisión.

Figura 24.

Evolución de la función de pérdida durante el entrenamiento con CNN autoencoder



A continuación, en la Figura 25 y la Tabla 3 se muestran los resultados, tomando como datos las predicciones realizadas en los entrenamientos anteriormente mencionados y los atributos con mejor predicción de fallas.

Figura 25.*Predicción de las fallas con CNN autoencoder*

Nota: a) Sección sísmica de amplitud original, b) sección con las fallas segmentadas, c) predicción usando el método propuesto con PCA, d) predicción utilizando el método tradicional sin PCA, e) predicción de fallas utilizando el atributo sísmico *Likelihood*, f) predicción de fallas utilizando el atributo sísmico *Skeletonization*.

Tabla 3.*Resultados de la red Autoencoder*


	Valor métrica SSIM	Desviación SSIM	Valor métrica Píxel	Desviación Píxel	Valor métrica IoU	Desviación IoU
Predicción con PCA	0.8714	0.0276	0.9631	0.8619	0.6724	5.3491
Predicción sin PCA	0.7725	0.0466	0.9290	1.8073	0.4963	8.4041
Atributo Likelihood	0.2539	-	0.8018	-	0.1774	-
Atributo Skeletonization	0.1151	-	0.0071	-	0.0868	-

5.2.2. Entrenamiento con la red U-net

Al completar el entrenamiento se obtienen los datos de precisión evidenciados en la Figura 26 y los datos de las pérdidas evidenciados en la Figura 27.

Figura 26.


Evolución de la precisión durante el entrenamiento y test U-Net




Como se muestra en la Figura 26 el método propuesto obtiene una mayor precisión en una menor cantidad de épocas, comenzando a estabilizar la precisión a partir de la época 10, en contraste con el método tradicional que toma una mayor cantidad de épocas estabilizar la precisión, tomando un total de 35 épocas para tener una predicción similar al método propuesto.

Figura 27.

Evolución de la función de pérdida durante el entrenamiento con U-Net



A continuación, en la Figura 28 y en la Tabla 4, se muestran los resultados y comparación en la segmentación de falla, tomando como datos las predicciones realizadas en los entrenamientos anteriormente mencionados y los atributos con mejor predicción de fallas.

Figura 28.*Predicción de las fallas con U-Net*

Nota: a) Sección sísmica de amplitud original, b) sección con las fallas segmentadas, c) predicción usando el método propuesto con PCA, d) predicción utilizando el método tradicional sin PCA, e) predicción de fallas utilizando el atributo sísmico *Likelihood*, f) predicción de fallas utilizando el atributo sísmico *Skeletonization*.

Tabla 4.*Resultados de la red Unet.*

	Valor métrica SSIM	Desviación SSIM	Valor métrica Píxel	Desviación Píxel	Valor métrica IoU	Desviación IoU
Predicción con PCA	0.8625	0.0120	0.9613	0.4438	0.6668	2.5248
Predicción sin PCA	0.7215	0.0873	0.9237	2.2847	0.4581	20.0437
Atributo Likelihood	0.2539	-	0.8018	-	0.1774	-
Atributo Skeletonization	0.1151	-	0.0071	-	0.0868	-


El método propuesto demuestra tener mejor predicción de datos a comparación del estado del arte y la ejecución de los atributos solamente, como se evidencia en las tablas 3 y 4, a pesar de que gráficamente al final de las épocas tuvieron una precisión similar. Esto se debe a que los datos utilizados con el método propuesto presentan una mayor cantidad de información, sintetizando las características de los diferentes atributos tardando menos tiempo en comprender las características de las fallas y en estabilizar la predicción a comparación del método tradicional.

5.3 Implementación del método en datos sísmicos reales

Para validar los datos se obtuvieron los resultados con datos sísmicos reales presentados en la Figura 29, mostrando las diferentes fallas segmentadas sobre los datos sísmicos. Además, en la Figura 30 se muestra la representación tridimensional de las fallas, detallando cómo las fallas geológicas mantienen su forma a lo largo de las predicciones, tal como sucede en la Figura 30c, resaltándose la falla principal del dato sísmico.

Figura 29.

Implementación con datos sísmicos reales




Nota: Los datos resaltados en color rojo son puntos donde es más probable que exista una falla.

a) Segmentación de fallas vistas frontalmente, b) Segmentación de fallas vistas sagitalmente, c)

Segmentación de fallas vistas frontalmente.

Figura 30.

Imágenes tridimensionales de las fallas geológicas reales



Nota: a) Imagen de las fallas tridimensionales desde la perspectiva frontal del cubo sísmico, b) Imagen de las secciones individuales del cubo sísmico desde la perspectiva frontal, c) Imagen de las fallas tridimensionales desde la perspectiva lateral del cubo sísmico, d) Imagen de las secciones individuales del cubo sísmico desde la perspectiva lateral.

6. Conclusiones

1. Los atributos sísmicos enfocados para la segmentación de fallas de acuerdo a sus características de resaltar las discontinuidades son Contraste de amplitud, Varianza, Impedancia acústica relativa, Contraste del gradiente, *Ant Traking*, *Likelihood*, *Skeletonization*. Sin embargo, implementar únicamente estas características no es suficiente para la representación de las fallas geológicas debido a que son muy susceptibles a ruido y requieren de un conocimiento previo de los parámetros para el cálculo de cada atributo.
2. En este trabajo de investigación se desarrolló un nuevo enfoque para el tratamiento de datos con la implementación de diferentes atributos que permitan detectar automáticamente fallas geológicas. Con la implementación del PCA se reducen los atributos obteniendo una nueva forma de datos en un nuevo cubo sísmico que conserva la varianza y estructura de la información.
3. El método propuesto demuestra ser superior con respecto al tiempo de ejecución, llegando a una mayor estabilidad en el entrenamiento de las redes U-Net y CNN autoencoders en una menor cantidad de épocas con respecto al método tradicional. Y en los resultados obtenidos durante la evolución de las curvas de convergencia de la red neuronal convolucional autoencoder y la U-Net. Obteniendo para el caso de la res autoencoder una ganancia del 0.0989 SSIM, una ganancia de 0.0391 respecto a la métrica de Pixel Accuracy, y una ganancia de 0.1761 de IoU. Para la red Unet una ganancia de 0.141 SSIM,

una ganancia de 0.0376 respecto a la métrica de Pixel Accuracy, y una ganancia de 0.2087 de IoU.

4. En cada uno de los entrenamientos realizados el método propuesto obtiene una menor desviación estándar con respecto al método tradicional, teniendo una diferencia menor para el caso de la red autoencoder de 0.019 en la métrica de SSIM, de 0.9454 en la métrica de Pixel Accuracy, de 3.055 en la métrica de IoU. De igual forma ocurre con la red Unet, teniendo una menor cantidad de desviación estándar, siendo una diferencia de 0.0753 en la métrica de SSIM, de 1.8409 en la métrica de Pixel Accuracy, y de 17.5189 en el caso de la métrica IoU.
5. Al completar los entrenamientos de las redes U-Net y CNN autoencoder, es posible remarcar la poca diferencia que se obtuvo con las redes CNN comparándose con la U-Net en los resultados del método propuesto, ya que la diferencia en la métrica SSIM es de 0.0089, en la métrica Pixel Accuracy es de 0.0018, en la métrica de IoU es de 0.0056. Siendo la red autoencoder un poco superior respecto a la red Unet.

7. Referencias

- Acuña Uribe, M., Pico Forero, M. C., Goyes Peñafiel, P., & Mateus, D. (2021). Enhanced ant tracking: Using a multispectral seismic attribute workflow to improve 3D fault detection. *The Leading Edge* 40: 502–512. <https://doi.org/10.1190/tle40070502.1>
- Adnan Aqrawi, A., & Hellem Boe, T. (2011). Improved fault segmentation using a dip guided and modified 3D Sobel filter. *SEG Technical Program Expanded Abstracts*: 999-1003.
- Ahmed, S. (2001). Seismic attributes. *CSEG Recorder*.
- Brunet, D., Vrscay, E. R., & Wang, Z. (2012). On the Mathematical Properties of the Structural Similarity Index. *IEEE Transactions on Image Processing*, vol. 21, no. 4, pp. 1488-1499.
- Chopra, S., & Marfurt, K. (2005). Seismic attributes - A historical perspective. *Canada: Geophysics* vol 70.
- Dalley, R., Gevers, E., Stampfli, G., Davies, D., Gastaldil, C., Ruijtenberg, P., & Vermeer, G. (1989). Dip and azimuth displays for 3D seismic interpretation. *First Break*.
- Dat, P. (2008). Seismic Attributes - A review.^{7a} *International Conference & Exposition on Petroleum Geophysics*.
- de la Fuente Fernzadez, S. (2001). Componentes principales. Madrid, España: Universidad Autonoma.
- Estrada, L. A. (2008). Prospección sísmica para geólogos. Universidad Nacional de Tucuman.
- Gao, D. (2013). Integrating 3D seismic curvature and curvature gradient attributes for fracture characterization: Methodologies and interpretational implications. *GEOPHYSICS* 78: O21-O31.

- Gorodissky, H., Harari, D., & Ullman, S. (2018). Large Field and High Resolution: Detecting Needle in Haystack. ArXiv, abs/1804.03576.
- Guo, B., Liu, L., & Lou, Y. (2018). A new method for automatic seismic fault detection using convolutional neural network. SEG Technical Program Expanded Abstracts : 1951-1955.
- Henry, S. (2004). Understanding Seismic Amplitudes. Geophysical Corner.
- Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. ArXiv, abs/1412.6980.
- Lawrence, S., Giles, C., Chung Tsoi, A., & Back, A. (1997). Face recognition: a convolutional neural-network approach. IEEE Transactions on Neural Networks vol 8.
- lorenzor. (s.f.). steemKR. Obtenido de <https://steemkr.com/stem-espanol/@lorenzor/analisis-estratigrafico-del-subsuelo-a-partir-de-la-impedancia-acustica-y-coeficientes-de-reflexion>
- Ma, Y., Loures, L., & Margrave, G. (2004). Seismic modelling with the reflectivity method. CREWES Research Report.
- Negm, S. A., Khalil, M. H., & Bakr, A. (2020). Gas prediction through the LMR method using post-stack inversion and multi-attributes, F3 cube, North Sea, Netherlands. Arab J Geosci 13, 674. <https://doi.org/10.1007/s12517-020-05497-2>
- Nuwara, Y. (05 de 03 de 2021). Seismic Amplitude Extraction on Horizon in Gullfaks Field. Obtenido de The Earth Curiosity: <https://yohanesnuwara.com/2021/03/05/seismic-amplitude-extraction-on-horizon-in-gullfaks-field/>
- OpendTect. (2020). terranubis. Obtenido de Project F3 Demo 2020: <https://terranubis.com/datainfo/F3-Demo-2020>

- Pedersen, S. I., Randen, T., Sønneland, L., Research, S. S., & Steen, Ø. (2002). Automatic Fault Extraction using Artificial Ants. SEG Technical Program Expanded Abstracts : 512-515.
<https://doi.org/10.1190/1.1817297>
- Petron, M., & Petron, C. (2010). Image Processing: The Fundamentals. Reino Unido: Wiley.
- Rizzo, R. E., Healy, D., & De Siena, L. (2017). Benefits of maximum likelihood estimators for fracture attribute analysis: Implications for permeability and up-scaling.
<https://doi.org/10.1016/j.jsg.2016.12.005>.
- Rodrigo, J. A. (06 de 2017). Análisis de Componentes Principales (Principal Component Analysis, PCA) y t-SNE. Obtenido de Análisis de Componentes Principales (Principal Component Analysis, PCA) y t-SNE:
https://www.cienciadedatos.net/documentos/35_principal_component_analysis
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. <https://arxiv.org/abs/1505.04597v1>.
- Saha, S. (15 de 12 de 2018). A comprehensive Guide to Convolutional Neural Networks. Obtenido de towardsdatascience: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- Sanchez Sellero, C. (2008-2009). Análisis Multivariante. Obtenido de uc3m.
- Stockwell, J. W., & Cohen, J. K. (2002). The New SU User's Manual. Colorado.
- Taner, M. (1992). Attributes revisited, Rock Solid Images.
- Vasudevan, K., Cook, F. A., & Eaton, D. W. (2006). Seismic Skeletonization: A Useful Tool for Geophysical Data Analysis. Recorder.

- Wang , Y. (2015). The Ricker wavelet and the Lambert W function. En *Geophysical Journal International* (pág. 111). London.
- Wu, X., Liang, L., Shi, Y., & Fomel, S. (2019). FaultSeg3D: Using Synthetic data sets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *GEOPHYSICS* 84: IM35-IM45. <https://doi.org/10.1190/geo2018-0646.1>.
- Wu, Y., Lin, Y., & Zhou, Z. (2018). InversionNet: Accurate and Efficient Seismic Waveform Inversion with Convolutional Neural Networks. SEG International Exposition.
- Xiong, W., Ji, X., Ma, Y., Wang, Y., AlBonHassan, N., Ali, M., & Luo, Y. (2018). Seismic fault detection with convolutional network. *GEOPHYSICS* 83: O97-O103. <https://doi.org/10.1190/geo2017-0666.1>.
- Turner, M. T. (1999). Seismic attributes, their classification and project utilization. Houston, Texas: Rock Solid Images.
- Spolti, A., Guizilini, V., Caio C, M., Croce, M., de Geus, A., Oliveira, E., Backes, A., & Souza, J. (2020). Application of U-Net and Auto-Encoder to the Road/Non-Road Classification of Aerial Imagery un Urban Environments. <https://www.scitepress.org/Papers/2020/93373/93373.pdf>.
- Tiu Elkin. (2019) Towars Data Science. Obtenido de <https://towardsdatascience.com/metrics-to-evaluate-your-semantic-segmentation-model-6bcb99639aa2>