

Estudio de la respuesta a la variación de parámetros en la técnica redes neuronales probabilísticas para clasificación supervisada de facies sísmicas.

Diana Katerine Salazar Flórez

Trabajo de grado en modalidad pasantía de investigación, para optar el título de Geóloga

Directora

Heather Bedle

PhD. en Ciencias de la Tierra y Planetarias

Co-Director

Javier Téllez Rodríguez

M.Sc en Geología y candidato PhD.

Universidad Industrial de Santander

Facultad de Ingenierías Físicoquímicas

Escuela de Geología

Bucaramanga

2021

Dedicatoria

A mi familia, por apoyarme siempre en todas mis decisiones y por su esfuerzo para que yo cumpliera mis metas. Sin ellos no sería la persona que soy, ni habría alcanzado todos los logros que hasta hoy me he trazado.

Agradecimientos

Mi profunda gratitud para mi directora Dr. Heather Bedle, por darme la oportunidad de trabajar con ella en la Universidad de Oklahoma. A Karelia La Marca, por sus recomendaciones y por orientarme en esa grandiosa aventura llamada “investigación científica”. A todos los miembros del grupo de investigación SDA, especialmente a Javier Téllez, Julian Chenin y David Lubo; y por supuesto, al Dr. Marfurt por sus siempre motivadoras palabras y enriquecedores comentarios.

Gracias a Nicolás Gutiérrez y Camilo Olimpo, geólogos de Repsol Colombia, por ser quienes me introdujeron en el mundo de los atributos sísmicos y la geofísica. A todos los ingenieros de Repsol Colombia, gracias por todo lo que aprendí de ustedes, especialmente Aivones Rivas, Carolina Acosta, y Yamile Nur.

Mil gracias a mi familia, por su apoyo incondicional y todos los esfuerzos puestos en mi formación personal y profesional. A mis amigos, Nicolás Córdoba, Carlos Santos, y Andrés Rojas, gracias por su motivación y apoyo. A todas mis compañeras de carrera, no podría estar más orgullosa de formar parte, junto con todas ustedes, de la siguiente generación de geólogas.

Finalmente, mil agradecimientos a mi alma mater, la Universidad Industrial de Santander, por la educación de alta calidad y los recursos invertidos en mi formación profesional. A la Universidad de Oklahoma por patrocinar este proyecto de investigación. Igualmente, gracias a los patrocinadores del consorcio AASPI, a Schlumberger por proveer la licencia del software Petrel, y al Servicio Geológico de los Estados Unidos (USGS) y la Oficina de Manejo de Energías del Océano (BOEM) por proveer el volumen sísmico.

Contenido

Introducción.....	11
1. Objetivos	13
1.1. Objetivo general.....	13
1.2. Objetivos específicos.....	13
2. Localización.....	14
3. Marco geológico regional.....	15
4. Marco geológico local.....	18
5. Facies sísmicas identificadas	20
6. Atributos sísmicos aplicados	22
7. Técnicas de aprendizaje automatizado.....	25
7.1. Métodos no supervisados.....	25
7.2. Métodos supervisados	26
8. Redes neuronales probabilísticas	29
8.2. Método de Parzen	30
8.3. Algoritmo exhaustivo.....	31
9. Flujo de trabajo	32
9.1. Parámetros modificados	34
9.1.1. <i>Atributos sísmicos seleccionados</i>	34

9.1.2. Datos de entrenamiento y validación	35
9.1.3. Facies sísmicas incluidas.....	35
9.1.4. Tamaño del volumen sísmico	36
9.1.5. Ventana de análisis.....	36
9.2. Pruebas realizadas	36
9.2.1. Prueba 1: Resultados iniciales.....	40
9.2.2. Prueba 2: Adición de más datos de entrenamiento.....	40
9.2.3. Prueba 3: Ventana de análisis del filtro Kuwahara.....	41
9.2.4. Prueba 4: Volumen cortado	41
9.2.5. Prueba 5: Curvatura con longitud de onda corta vs. No curvatura	41
9.2.6. Prueba 6: Zonas geológicamente complejas	42
9.2.7. Prueba 7: Último análisis en las zonas con errores de clasificación	42
10. Resultados.....	43
10.1. Prueba 1: Resultados iniciales.....	44
10.2. Prueba 2: Adición de más datos de entrenamiento	47
10.3. Prueba 3: Ventana de análisis del filtro Kuwahara	50
10.4. Prueba 4: Volumen cortado	52
10.5. Prueba 5: Curvatura con longitud de onda corta vs. no curvatura	55
10.6. Prueba 6: Zonas geológicamente complejas	57
10.7. Prueba 7: Último análisis en las zonas con clasificaciones incorrectas	60

11. Discusión	63
12. Conclusiones.....	73
Referencias Bibliográficas.....	76

Lista de Figuras

Figura 1. Localización del área de estudio	14
Figura 2. Marco geológico regional.....	17
Figura 3. Línea 1013 indicando la columna estratigráfica generalizada en el área de estudio	18
Figura 4. Localización de los domos salinos que rodean la minicuenca Diana	19
Figura 5. Facies sísmicas identificadas	21
Figura 6. Atributos sísmicos usados en el presente estudio	24
Figura 7. Cálculo de la función de probabilidad de densidad como la suma escalada de las funciones de peso individuales	31
Figura 8. Flujo de trabajo generalizado seguido en el presente estudio	33
Figura 9. Pruebas y casos corridos en este estudio, y las conexiones entre ellos.....	38
Figura 10. Volúmenes de predicción de facies obtenidas de la Prueba 1	46
Figura 11. Volúmenes de predicción de facies obtenidos de la Prueba 2.....	49
Figura 12. Volúmenes de predicción de facies obtenidos de la Prueba 3	51
Figura 13. Volúmenes de predicción de facies obtenidos de la Prueba 4.....	54
Figura 14. Volúmenes de predicción de facies obtenidos de la Prueba 5.....	56
Figura 15. Volúmenes de predicción de facies obtenidos de la Prueba 6.....	59
Figura 16. Volúmenes de predicción de facies obtenidos de la Prueba 7.....	62
Figura 17. Evolución de las clasificaciones de facies del Modelo 3	71
Figura 18. Propuesta de flujo de trabajo final	72

Lista de Tablas

Tabla 1. Parámetros específicos aplicadas en cada prueba y caso.....	39
Tabla 2. Compilación de las mejores combinaciones de atributos sísmicos y valores σ obtenidos en cada prueba y caso.....	44
Tabla 3. Impacto cualitativo de cada parámetro modificado en los volúmenes de predicción de facies obtenidos en cada caso.	70

Resumen

Título: Estudio de la respuesta a la variación de parámetros en la técnica redes neuronales probabilísticas para clasificación supervisada de facies sísmicas *

Autora: Diana Katherine Salazar Flórez **

Palabras Clave: aprendizaje automatizado, redes neuronales probabilísticas, facies sísmicas, atributos sísmicos, Golfo de México

Descripción:

Hoy en día, hay muchas técnicas de aprendizaje automatizado supervisado y no supervisado disponibles para realizar clasificación de facies sísmicas. Sin embargo, dichos métodos no solo demandan altos tiempos de cómputo, sino que también pueden no proveer una medida de confianza adecuada. Las redes neuronales probabilísticas (PNNs) superan dichas limitaciones y han demostrado su superioridad en comparación con otros algoritmos. Las PNNs han sido ampliamente aplicadas para las algunas tareas de predicción con registros de pozo, pero no han sido bien estudiadas para la predicción de facies usando volúmenes de atributos sísmicos. Aquí se explora la capacidad del algoritmo PNN para la clasificación de facies sísmicas de gran y pequeña escala y, adicionalmente, se evalúa el impacto de los parámetros definidos por un usuario en los volúmenes de clasificación. Se realizaron siete pruebas con las cuales se pudo demostrar que el procesamiento puede tener un impacto significativo en los volúmenes de clasificación, y que las zonas geológicamente más complejas son las más difíciles para el algoritmo. Además, se demostró que a pesar de que la técnica PNN está realizando y produciendo resultados considerablemente correctos, es posible superar las limitaciones anteriormente mencionadas, y mejorar significativamente los volúmenes de clasificación finales mediante la inclusión del criterio y conocimiento del geocientífico. Se concluyó con un nuevo flujo de trabajo que podrá guiar a futuros interpretes interesados en aplicar PNN para obtener mejores volúmenes de clasificación de facies sísmicas mediante la consideración de algunos pasos y sugerencias iniciales.

* Trabajo de Grado

** Facultad de Ingenierías Físicoquímicas. Escuela de Geología. Director: Heather Bedle. PhD. en Ciencias de la Tierra y Planetarias. Codirector: Javier Téllez Rodríguez, M.Sc. en Geología y candidato PhD.

Abstract

Title: Study on the parameterization response of probabilistic neural networks for seismic facies classification*

Author: Diana Katherine Salazar Florez**

Keywords: machine learning, probabilistic neural networks, seismic facies, seismic attributes, Gulf of Mexico

Description:

Nowadays, there are many unsupervised and supervised machine learning techniques available for performing seismic facies classification. However, those classification methods either demand high computational costs or do not provide an accurate measure of confidence. Probabilistic neural networks (PNNs) overcome these limitations and have demonstrated their superiority among other algorithms. PNNs have been extensively applied for some prediction tasks, but not well studied regarding the prediction of seismic facies volumes using seismic attributes. We explore the capability of the PNN algorithm when classifying large- and small-scale seismic facies. Additionally, we evaluate the impact of user-chosen parameters on the final classification volumes. After performing seven tests, each with a parameter variation, we assess the impact of the parameter change on the resultant classification volumes. We show that the processing task can have a significant impact on the classification volumes, but also how the most geologically complex areas are the most challenging for the algorithm. Moreover, we demonstrate that even if the PNN technique is performing and producing considerably accurate results, it is possible to overcome those limitations and significantly improve the final classification volumes by including the geological insight provided by the geoscientist. We conclude by proposing a new workflow that can guide future geoscientists interested in applying PNNs, to obtain better seismic facies classification volumes by considering some initial steps and advice.

* Undergraduate Research Thesis

** Faculty of Physical-Chemical Engineerings. School of Geology. Advisor: Heather Bedle. PhD. Earth and Planetary Sciences. Co-advisor: Javier Téllez Rodríguez, M.Sc. Geology and PhD candidate.

Introducción

La técnica Redes Neuronales Probabilísticas (*Probabilistic Neural Networks- PNN*) si bien ha sido ampliamente usada para la predicción de propiedades de reservorio mediante datos de pozo, su aplicación para predicción de facies sísmicas a partir de atributos sísmicos ha sido restringida. Esto hace necesario que se realicen proyectos de este tipo que permitan evaluar la capacidad de la técnica, sus fortalezas y limitaciones, así como también las maneras para obtener mejores resultados.

Este proyecto de investigación tiene como objetivo hacer un análisis exploratorio del impacto de la variación de parámetros iniciales en las clasificaciones de facies sísmicas realizadas utilizando Redes Neuronales Probabilísticas. Entre los parámetros a variar se encuentran: la cantidad de datos de entrenamiento, el tamaño de la ventana de análisis del filtro de suavizado, la definición de los polígonos de facies, la cantidad y tipos de facies sísmicas, entre otros. Todos estos parámetros son controlados por el intérprete, y, por ende, se espera que después de incluir el criterio geocientífico para la definición del parámetro a variar, se obtengan mejores clasificaciones.

La variación de parámetros se hará mediante diferentes pruebas, donde en cada una de ellas se variará un parámetro y se evaluará su impacto en el volumen de predicción de facies resultantes. Para este proyecto se eligió el volumen East Breaks y Alaminos Canyon ubicado en aguas profundas en el Occidente del Golfo de México. Este volumen se consideró adecuado puesto que se encontraron elementos arquitecturales de gran y pequeña escala, tales como turbiditas, depósitos de transporte en masa, sedimentos hemipelágicos y domos salinos.

Este proyecto se realizará bajo la modalidad de pasantía de investigación con la Universidad de Oklahoma, y como resultado final se deberá entregar un manuscrito en idioma inglés. Todo esto, además, con el objetivo adicional de fortalecer las relaciones conjuntas y capacidades investigativas entre las dos universidades.

1. Objetivos

1.1. Objetivo general

Hacer un análisis exploratorio del impacto de la variación de parámetros iniciales en las clasificaciones de facies sísmicas realizadas utilizando la técnica Redes Neuronales Probabilísticas.

1.2. Objetivos específicos

Aplicar la técnica Redes Neuronales Probabilísticas para clasificación de facies sísmicas, variando parámetros como: la cantidad y tipo de facies sísmicas, la cantidad de datos de entrenamiento, el tamaño de la ventana de análisis del filtro de suavizado, la longitud de onda para el cálculo de los atributos de curvatura y la definición de los polígonos de facies.

Analizar el impacto de cada parámetro en los volúmenes resultantes de predicción de facies, teniendo en cuenta el criterio geocientífico.

Identificar las limitaciones de la técnica Redes Neuronales Probabilísticas a través del análisis de las zonas con errores de clasificación y las posibles causas de estos.

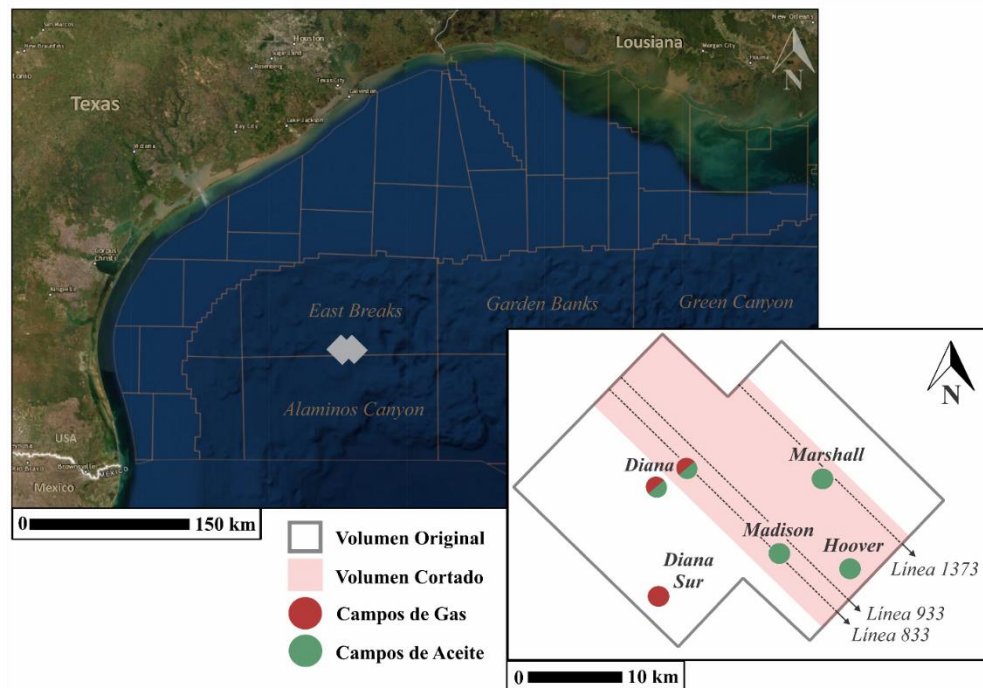
Generar un flujo de trabajo replicable, que pueda ayudar a futuros interpretes a mejorar y optimizar las clasificaciones realizadas con la técnica Redes Neuronales Probabilísticas.

2. Localización

El volumen sísmico usado en este estudio se encuentra ubicada costa afuera en el talud del Occidente del Golfo de México, entre los bloques East Breaks y Alaminos Canyon; más específicamente, en la minicuenca Diana (Figura 1). En esta minicuenca se encuentran importantes campos de petróleo y gas como lo son el campo Diana y el campo Hoover, entre otros. Para este estudio, y debido a la necesidad de disminuir los altos tiempos de cómputo, el volumen sísmico fue cortado a 325 líneas (*lines*), 2481 líneas de corte (*crosslines*), con un área final aproximada de 380 km², y una longitud de registro de 4.1 segundos. El volumen sísmico tiene polaridad positiva, de acuerdo con los estándares de la Sociedad de Geofísicos de Exploración (*SEG-Society of Exploration Geophysics*), y un tamaño de celda (*bin size*) de 41,01 ft² × 131,237 ft² × 0,004s.

Figura 1.

Localización del área de estudio.



Nota. Imagen modificada del USGS.

3. Marco geológico regional

El Golfo de México es una cuenca oceánica pequeña, formada después de la separación del supercontinente Pangea entre el Triásico tardío y el Jurásico temprano (Nixon et al., 2014). Su depocentro contiene una sucesión de estratos sedimentarios depositados desde el Jurásico al Holoceno, con un espesor de hasta 20 km, de los cuales >15 km son estratos sedimentarios del Cenozoico (Galloway, 2008; Weimer et al., 2017). El evento de separación de Pangea permitió el desarrollo de cuencas tipo graben; así como también, familias de fallas de crecimiento alineadas con el rumbo (Nixon et al., 2014; Galloway, 2008).

Durante el Jurásico medio, el inicio de la invasión de mares epicontinentales someros permitió el desarrollo de ambientes restringidos y la consecuente depositación de gruesas capas de sedimentos evaporíticos, conocidos como la sal autóctona de Louann, (Galloway, 2008; Nixon et al., 2014; USGS, 1984). La transgresión continua del mar en el Jurásico tardío dió inicio al episodio de depositación dominada por carbonatos (Galloway, 2008). Durante el Cretácico, se desarrollaron gruesos complejos de arrecifes, y para el Cretácico medio, el crecimiento continuo de carbonatos en las plataformas de Florida y Yucatán dieron lugar al aislamiento de Golfo de México del mar Caribe y del océano Atlántico (Nixon et al., 2014; USGS, 1984).

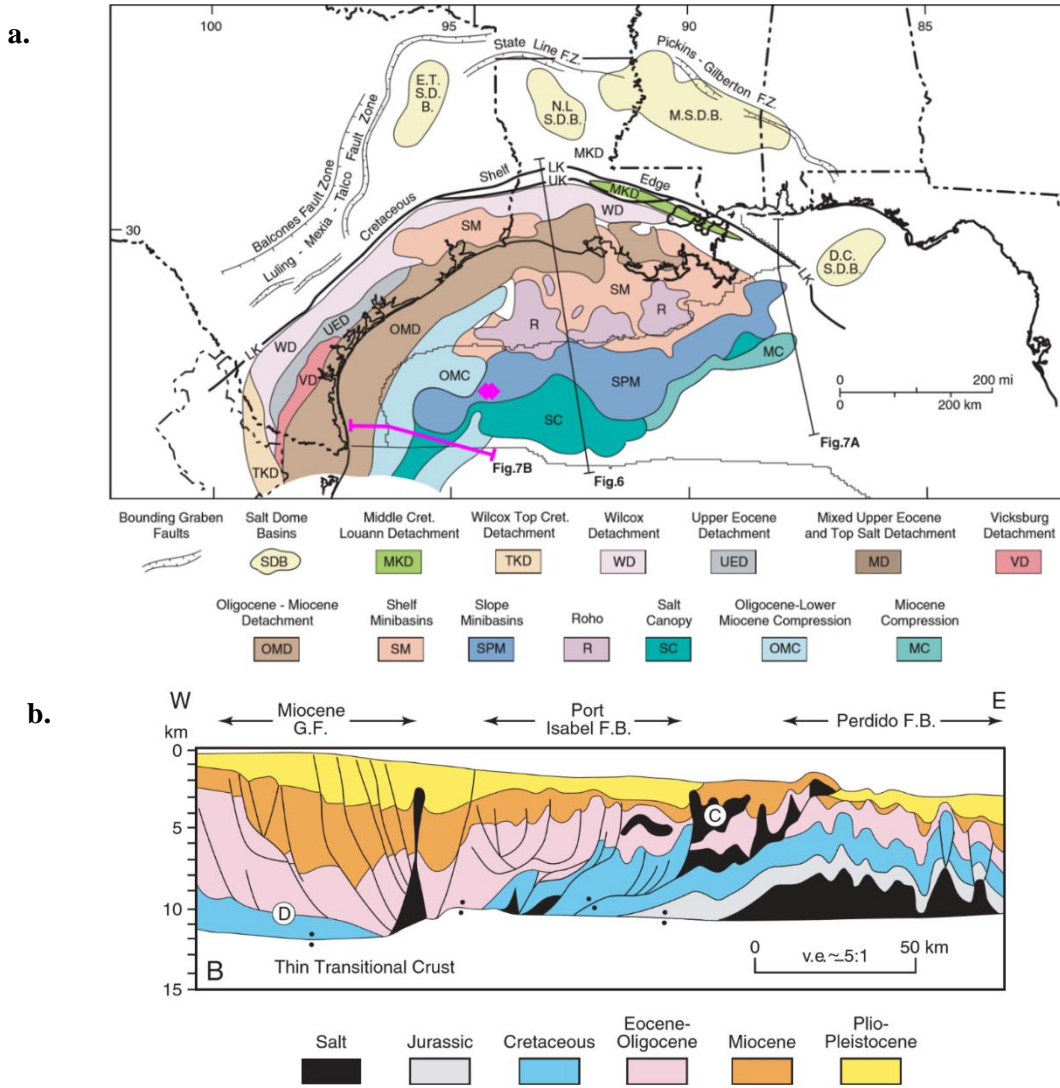
Para el final del Cretácico, la carga de sedimentos generó la expulsión de la mayor parte de la sal autóctona de Louann en dirección hacia la cuenca, mientras que la sal remanente sirvió como zona de despegue para los procesos de dispersión por gravedad (Galloway, 2008). En el Cretácico tardío y el Cenozoico temprano, la formación tectónica de las Montañas Rocosas, debido a la Orogenia Laramide, produjo cantidades voluminosas de sedimentos siliciclásticos que fueron

transportados al norte, occidente, y suroccidente del Golfo de México por los ríos Mississippi y otros sistemas fluviales antiguos (Nixon et al., 2014; USGS, 1984).

A finales del Oligoceno, la carga sedimentaria del Paleógeno desencadenó la formación de complejos de canopes salinos debajo del talud continental y la inflación de la lámina salina abisal (Galloway, 2008). La depositación de sedimentos durante el Mioceno-Plioceno generó una carga litostática importante que presionó dichos canopes, dando lugar a diapirismo pasivo y dispersión por gravedad, creando *stocks* salinos y minicuevas en la plataforma y en el talud; siendo las primeras completamente llenadas por la carga sedimentaria del Pleistoceno, mientras que las segundas permanecen incompletas (Galloway, 2008). La Figura 2a. muestra el mapa de dominios estructurales y la localización del volumen sísmico utilizado en el presente estudio, la Figura 2b. indica la configuración actual de los estratos sedimentarios presentes en el occidente del Golfo de México.

Figura 2.

Marco geológico regional.




Nota. a. Mapa de dominios estructurales indicando la localización del volumen sísmico utilizado en este estudio. b. Sección de corte al Occidente del Golfo de México. Figuras tomadas de Galloway (2008).

4. Marco geológico local

Figura 3.

Línea 1013 indicando la columna estratigráfica generalizada en el área de estudio.



Nota. Columna estratigráfica interpretada siguiendo las descripciones de Miller et al. (2012). Note las zonas de fallas en el tope del domo de sal, así como también la falla normal al lado derecho de la sección.

La minicuenca Diana está ubicada en el talud del Occidente del Golfo de México y está rodeada por dos cuerpos salinos relativamente someros. Esta minicuenca está compuesta por paquetes continuos de arcillas y lodos hemipelágicos de nivel alto (*high-stand*) y por depósitos de transportes en masa (MTD) ricos en arcillas (Figura 3., Miller et al., 2012 and Donovan et al., 2003). Entre los depósitos de arcillas hemipelágicas y los MTD arcillosos también se encuentran delgados intervalos de MTD ricos en arena, que corresponden a los intervalos de rocas reservorio y que presentan elementos de turbiditas de agua profunda (Miller et al., 2012). Estos intervalos son considerados reservorio e incluyen sistemas de canales confinados, complejos de canales distributarios, y complejos de lóbulos distributarios (Frye et al., 2009). De acuerdo con Sullivan et


al. (2000) las turbiditas que conforman la roca reservorio en el campo Diana fueron depositadas en un abanico submarino de nivel bajo (*lowstand*) dentro del talud.

En general, de acuerdo con Sarkar et al. (2008) los MTD encontrados en las minicuenas de talud, como la del presente estudio, se desarrollan usualmente debido a rompimientos en el frente de delta o las paredes de los cañones submarinos durante eventos de nivel bajo (*low stands system tracts*), cuando el nivel del mar cae rápidamente.

La Figura 4. es una franja de tiempo del volumen de amplitud sísmica que muestra los dos cuerpos salinos presentes en la minicuenca; el primero localizado al noroeste y el segundo al noreste del volumen sísmico. En el área de estudio, es posible identificar una falla relacionada con los eventos de extensión regional; así como también, se pueden identificar zonas de fallas hacia el tope de los domos salinos y que están relacionadas con el emplazamiento de dichos cuerpos salinos alóctonos (Figura 3c. en Galloway, 2008).

Figura 4.

Localización de los domos salinos que rodean la minicuenca Diana.



Nota. Franja de tiempo a 2740 ms indicando la localización de los domos salinos que rodean la minicuenca Diana.

Área de estudio encerrada en el polígono color magenta.

5. Facies sísmicas identificadas

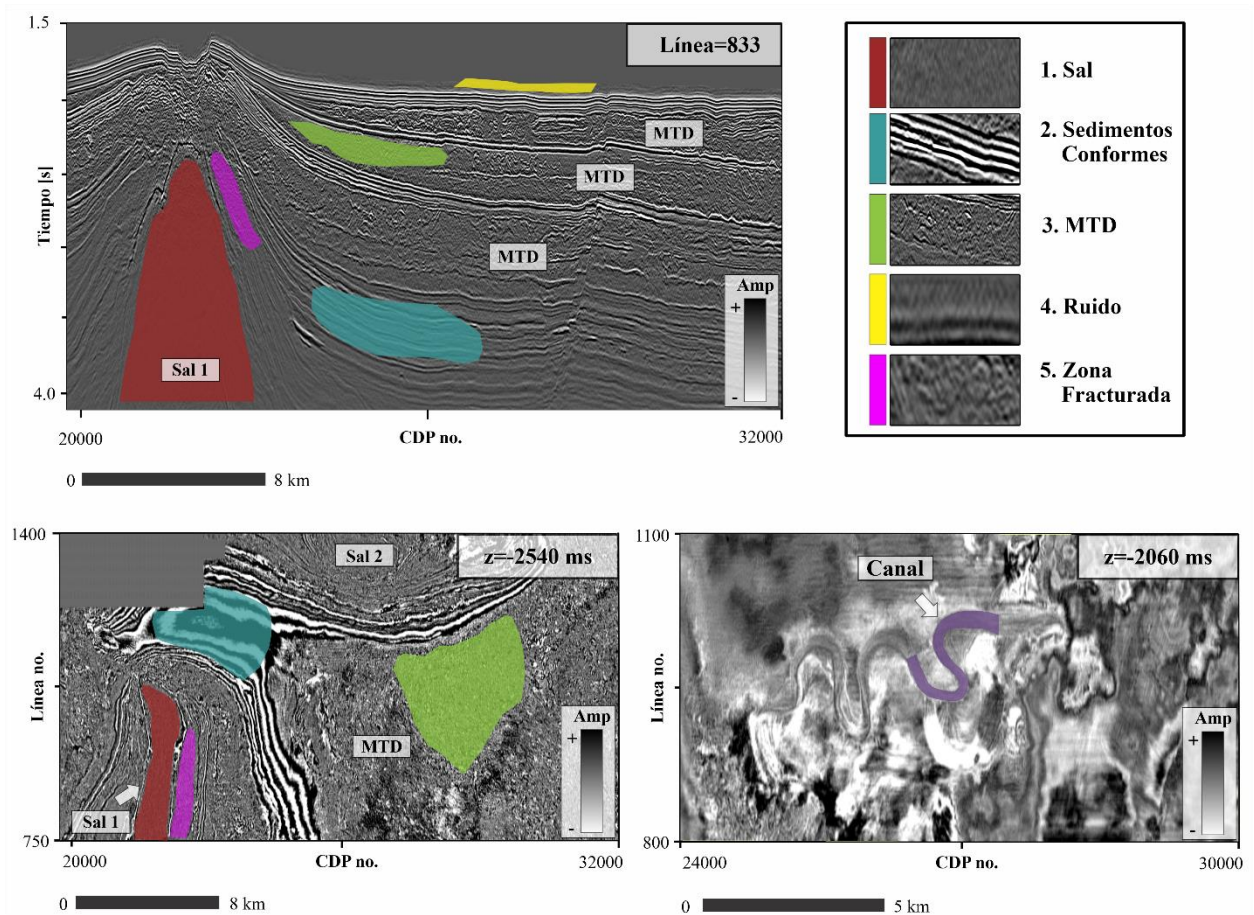
Roksandic (2006) define las facies sísmicas como unidades de roca que difieren de otras adyacentes, en sus características sísmicas tales como: amplitud de la reflexión, frecuencia dominante de reflexión, polaridad de la reflexión, continuidad de la reflexión, abundancia de reflectores, geometría, y la relación con otras unidades. Siguiendo este concepto, se definieron seis facies sísmicas indicadas en la Figura 5. 1) Facies de sal, cuyos reflectores son discontinuos, caóticos, y de baja amplitud, 2) Facies de sedimentos conformes, que están conformadas por reflectores continuos, subparalelos y de alta amplitud, 3) Facies de MTD, correspondientes a los reflectores discontinuos, caóticos y de alta amplitud, 4) Facies de ruido, que corresponden al ruido sobre el lecho marino y que están conformadas por reflectores continuos, paralelos y de baja amplitud, 5) Facies de zonas fracturadas, formadas por reflectores caóticos, semicontinuos y de baja amplitud.

En el volumen de amplitud, se infiere que las facies de zonas fracturadas corresponden a la continuación de los estratos de MTD y sedimentos conformes localizados alrededor de los domos salinos. Debido al emplazamiento de la sal, es posible que los estratos más cercanos hayan sido altamente fracturados, y, por ende, muestren respuestas sísmicas muy diferentes de aquellas estrictamente relacionadas con las facies de MTD y sedimentos conformes. Estas facies de zona fracturada fueron incluidas únicamente en una de las pruebas finales.

Finalmente, en los estratos sedimentarios someros se identificó un canal (Figura 5), el cual se incluyó como la sexta facie a clasificar. De esta manera, se buscaba también probar la capacidad de esta técnica para la clasificación de elementos más pequeños y sutiles.

Figura 5.

Facies sísmicas identificadas,



Nota. Observe los ejemplos de algunos de los polígonos de facies inicialmente usados para el entrenamiento del algoritmo.

6. Atributos sísmicos aplicados

En este estudio se incluyeron seis atributos sísmicos como candidatos iniciales para aplicar el algoritmo PNN de clasificación: 1) curvatura principal más positiva - $k1$, 2) curvatura principal más negativa - $k2$, 3) GLCM-contraste, 4) GLCM-desemejanza, 5) envolvente, y 6) coherencia. Otros atributos inicialmente considerados, pero posteriormente descartados, fueron los atributos de frecuencia instantánea, dulzura (*sweetness*) y caos. Los dos primeros fueron descartados puesto que resultan redundantes con el atributo de envolvente; por otra parte, el atributo de caos resulta redundante con los atributos texturales de GLCM (*gray level co-occurrence matrix*).

El atributo de coherencia se incluyó puesto que es bien conocido por su utilidad en la detección de bordes de canales y domos salinos (Chopra and Marfurt, 2007a). En cuanto a los atributos de curvatura, se incluyó la curvatura principal más positiva ya que ayuda a resaltar características de anticlinales o elevaciones, como aquellas relacionadas a domos salinos o bordes de canales (Chopra and Marfurt, 2007b). Por otro lado, la curvatura principal más negativa- $k2$ ayuda a resaltar características relacionadas con sinclinales o depresiones (Chopra and Marfurt, 2007b), como aquellas encontradas en ejes de canales o sinclinales formados durante la expulsión de sal en cuencas como la del presente estudio.

Juntos, los atributos de coherencia y curvatura son excelentes para delinear características estratigráficas relacionales tanto a canales como a MTD (Chopra and Marfurt, 2011). Finalmente, el atributo de envolvente fue incluido ya que está relacionado con la energía de la traza y ayuda a detectar cambios litológicos mayores o sutiles (Taner et al, 1979). En esta región, tenemos un contraste alto entre la sal y las litologías relacionadas a los demás sedimentos de la cuenca. Igualmente, existe un contraste alto entre los sedimentos conformes y los MTD.

Puesto que algunos elementos geológicos pueden exhibir curvaturas a diferentes longitudes de onda (Chopra and Marfurt, 2008), en este estudio se probaron dos maneras diferentes de calcular los atributos de curvatura, longitud de onda larga y longitud de onda corta. La curvatura calculada con longitud de onda corta incorpora información de buzamiento de 9–25 trazas, mientras que la curvatura calculada con longitud de onda larga utiliza información de buzamiento de 400 o más trazas (Chopra and Marfurt, 2007b). De acuerdo con Al-Dossary y Marfurt (2006), las estimaciones de curvatura con longitud de onda larga facilitan la detección de características que son difíciles de ver ya sea utilizando la curvatura de longitud de onda corta o con el atributo de coherencia. Por este motivo, se decidió iniciar las pruebas utilizando los atributos de curvatura calculados con longitud de onda larga y posteriormente se creó una prueba utilizando los atributos de curvatura calculado con longitud de onda corta.

Adicionalmente, los atributos texturales de GLCM fueron incluidos por varias razones. Primero, porque ayudan a resaltar texturas internas y a diferenciar mejor las variaciones de facies (Gao, 2003). Segundo, porque estos atributos ya han sido probados en previos estudios de clasificación de facies utilizando PNN. West et al. (2002) combinó exitosamente PNN con este tipo de atributos sísmicos texturales para automatizar los procesos de clasificación de facies sísmicas. De acuerdo con Deriche (2016), los atributos de GLCM pueden diferenciar entre texturas relacionadas o no con bordes de domos salinos. Los atributos de GLCM-desemejanza y GLCM-contraste usualmente muestran valores altos para las facies de sal (Deriche, 2016).

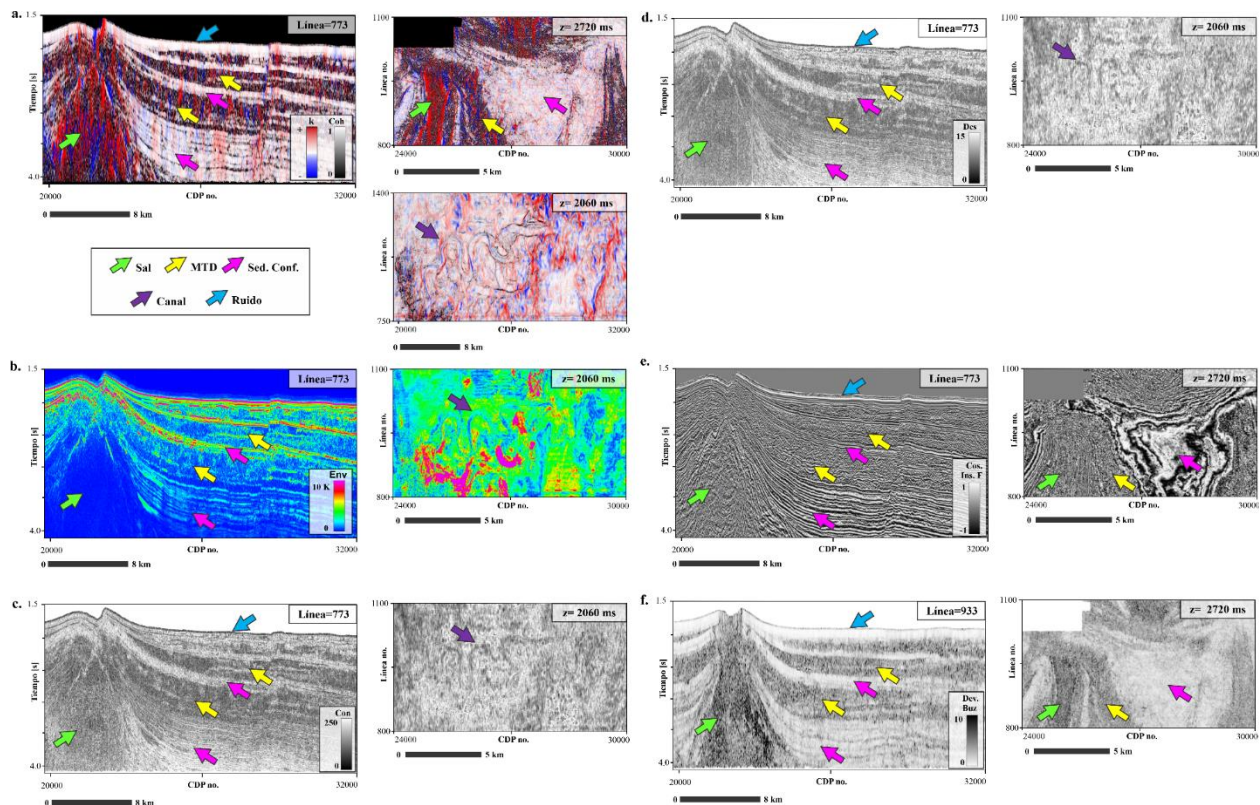
Adicionalmente, se utilizaron otros dos atributos sísmicos: coseno de fase instantánea y desviación del buzamiento (*dip deviation*). El atributo de coseno de fase instantánea fue útil para la definición de los polígonos de facies puesto que ayuda a resaltar características estratigráficas (Subrahmanyam y Rao, 2008). El atributo de desviación de buzamiento es uno de los tres atributos

de no-parallelismo presentados por Qi y Marfurt (2019) que ayuda a resaltar variaciones laterales de parallelismo de reflectores. Este atributo fue incluido como parte de una prueba final, con el objetivo de corregir algunas clasificaciones incorrectas dentro de las facies de sedimentos conformes en áreas altamente falladas debido al emplazamiento de los domos salinos.

Finalmente, como parte de una etapa de acondicionamiento y como lo sugiere Qi et al. (2015), se aplicó el filtro de suavizado Kuwahara 3D en cada uno de los atributos sísmicos utilizados en el algoritmo PNN. De acuerdo con Qi et al. (2015), este tipo de filtros ayuda a mejorar las clasificaciones de facies sísmicas ya que suaviza el interior de las estructuras y mejora el contraste entre estas. En estudio, se probó el impacto de usar diferentes tamaños de la ventana de análisis de dicho filtro de suavizado.

Figura 6.

Atributos sísmicos usados en el presente estudio.



Nota. a. Mezcla de los atributos de coherencia, k_1 , y k_2 , b. envolvente, c. GLCM-contraste, d. GLCM-desemejanza, e. Coseno de la fase instantánea, f. Desviación del buzamiento.

7. Técnicas de aprendizaje automatizado

Actualmente, hay muchas técnicas de aprendizaje automatizado para la clasificación de facies sísmicas, desde métodos no supervisados tales como K-medias (*K-means*), mapas auto-organizados (*self-organizing maps-SOMs*), y mapas topográficos generativos (*generative topographic mapping-GTM*), a métodos supervisados tales como redes neuronales convolucionales (*convolutional neural networks-CNNs*), apoyo a máquinas vectoriales (*support vector machines-SVMs*), y redes neuronales probabilísticas (*probabilistic neural networks-PNNs*). En diferentes estudios (Coléou et al., 2003; Roy et al., 2013; Zhao et al., 2015a Zhao et al., 2015b; Chopra and Marfurt, 2018), se ha comparado y contrastado cada una de estas técnicas, así como también las clasificaciones resultantes después de su aplicación.

7.1. Métodos no supervisados

De acuerdo con Zhao et al. (2015b), una de las desventajas del algoritmo de K-medias es la falta de organización, haciendo que datos de muestra que pueden estar relacionados a facies similares, aparezcan en facies diferentes. Además, esta técnica requiere la definición de una distancia, que puede ser Euclidiana, Mahalanobis, Manhattan, Canberra o Chebychev (Barnes and Laughlin, 2002; Chopra and Marfurt, 2018). La definición de este tipo de distancias puede tener un impacto considerable en la precisión del algoritmo o la velocidad de este (Barnes and Laughlin,

2002). La distancia euclidiana, por ejemplo, funciona bien cuando las facies tienen un patrón esférico en el espacio multidimensional, mientras que la distancia de Mahalanobis es más adecuada para formas elípticas (Chopra and Marfurt, 2018). Esto añade un grado significativo de complejidad a este método no supervisado. La definición de la distancia no es algo obvio o intuitivo para un intérprete sin experiencia y puede ser una decisión abrumadora, ya que tendrá un impacto directo en el rendimiento y los resultados de la clasificación.

En contraste con el método de K-medias, donde la agrupación de patrones se hace en un espacio N-dimensional (Coléou et al., 2003), SOMs y GTMs son considerados técnicas de proyección o técnicas para reducción de dimensionalidad, donde la agrupación se hace sobre una superficie 2D deformada o *manifold* (Zhao et al., 2015b). De acuerdo con Chopra and Marfurt (2018), SOMs tiene muchas limitaciones, siendo la más notable el hecho de que no proveen una medida de confiabilidad en los resultados finales de agrupación. Esto es sobrellevado por la técnica GTM, la cual indica la categoría a la cual es más probable que este asociado un dato de muestra, pero también indica la probabilidad de que dicho dato de muestra específico pertenezca a un clúster u otro (Zhao et al., 2015b).

7.2. Métodos supervisados

Mientras que los métodos no supervisados no requieren información asignada o clasificada dentro de una categoría u otra, si requieren de una interpretación posterior a las clasificaciones hechas por el algoritmo, y algunas veces, es más difícil asignar sentido geológico a una interpretación automática hecha por la máquina (Wrona et al., 2018; Liu et al., 2019). Por otro

lado, los métodos supervisados sí permiten hacer clasificaciones con significado geológico, puesto que están restringidas a un número y tipo de facies sísmicas previamente definidas por el geocientífico (West et al., 2002; Wrona et al., 2018). Otra ventaja de las redes neuronales usadas para clasificaciones supervisadas es que permiten el procesamiento de cantidades considerables de datos sin requerir cantidades excesivas de memoria (Coléou et al., 2003).

Aun así, es importante recalcar que esto no es siempre verdad para todos los métodos supervisados. CNN, a pesar de que parece ser una técnica prometedora dentro del llamado aprendizaje profundo (*deep learning*) puesto que solo requiere del volumen de amplitud como dato de entrada y elimina la necesidad del uso de atributos sísmicos, de hecho, esta técnica requiere grandes cantidades de datos de entrenamiento para evitar la sobreajuste o *overfitting*, y para clasificar aquellas zonas no usadas durante el entrenamiento (Waldeland et al, 2018; Di et al 2019; Liu et al., 2019). En el caso de SVM, puesto que esta técnica implica un aumento de la dimensionalidad de los datos, también implica un aumento significativo del costo computacional (Zhao et al. 2015b).

En comparación con los otros métodos supervisados, PNN no requiere una cantidad extensa de datos de entrenamiento y su base matemática también entrena datos más rápidamente que otras redes neuronales de multicapas de alimentación hacia adelante (*multi-layer feedforward neural networks*) (Masters, 1995; West et al., 2002). Adicionalmente, PNN no está basada únicamente en el cómputo de la distancia entre el vector de entrada y los vectores de entrenamiento, sino que también esta guiada por la cantidad de miembros de una categoría que está cerca (Masters, 1995; West et al., 2002). Por ende, PNN es capaz de proveer una medida de confiabilidad mediante el cálculo, a cada dato de muestra, de una probabilidad de 1 a 0 de pertenecer a una clase A, B, o C, y finalmente simplemente clasifica el punto de muestra en la

categoría con la probabilidad más alta (West et al., 2002). Todos estos aspectos hacen que PNN sea una técnica que puede asegurar sentido geológico, entrenamiento rápido, y clasificaciones acertadas con una medida de confiabilidad.

Debido a las características de las redes neuronales artificiales, como las PNNs, para encontrar relaciones no lineales entre los datos de registros de pozo y datos sísmicos, hay muchos artículos que han demostrado la exactitud de la PNNs para predecir propiedades del yacimiento (Hampson et al., 2001; Pramanik et al., 2004; Putri et al., 2018; Liu et al., 2019). Sin embargo, hay pocos artículos que aplican PNNs para clasificación de facies sísmicas (West et al., 2002; Lubo et al., 2019). West et al. (2002) presentó resultados exitosos después de aplicar únicamente atributos texturales, mientras que Lubo et al. (2019), a pesar de que usó diferentes tipos de atributos sísmicos, realizó la clasificación de facies sísmicas relacionadas a domos salinos y sedimentos conformes únicamente. Con el éxito de esas clasificaciones, es necesario seguir explorando las capacidades del algoritmo PNN probándolo en escenarios más complejos, usando más facies sísmicas, y diferentes tipos de atributos sísmicos.

En todas las aplicaciones anteriores de PNNs, la selección de los atributos sísmicos para las clasificaciones o predicciones se han realizado mediante regresión escalonada (Hampson, 2001; Putri et al., 2018), regresión multilineal (Mercado-Herrera et al., 2006), o mediante experiencia del geocientífico (West et al., 2002; Verma et al., 2012). Sin embargo, muchos autores han manifestado que la selección apropiada de atributos sísmicos es crucial, puesto que tienen un importante impacto en los resultados finales y puede ser más importante que el algoritmo en sí mismo (Barnes and Laughlin, 2002; Zhao et al., 2018; Kim et al., 2019; La Marca et al., 2019). En este sentido, una última ventaja del algoritmo PNN aplicado en este estudio es que está acoplado con un algoritmo de búsqueda exhaustiva. El objetivo de este algoritmo exhaustivo es encontrar

la mejor combinación de atributos sísmicos y el parámetro de escalado que permite obtener resultados más acertados. Esta técnica fue introducida por Lubo et al. (2019) bajo el nombre de PNN Exhaustivo.

8. Redes neuronales probabilísticas

En esta sección se discutirán las bases estadísticas detrás de la técnica PNN, como las propuso Spetch (1988, 1990) y Masters (1995). PNN es un método de clasificación de patrones basado en la estrategia de Bayes para toma de decisiones y el método de Parzen.

8.1. Estrategia de Bayes para toma de decisiones

En la estrategia de Bayes, la decisión $d(\mathbf{X})$ de clasificar un patrón \mathbf{X} como parte de una categoría A o B depende de un valor de probabilidad *a priori* h , una función de probabilidad $f(\mathbf{X})$, y una función de pérdida l asociada con el costo de hacer una clasificación incorrecta (Spetch, 1988). En este sentido, la regla de Bayes [1], favorecerá una categoría si esta categoría tiene una alta densidad de sus miembros cerca de la muestra desconocida \mathbf{X} , si el costo de la clasificación incorrecta de \mathbf{X} dentro de dicha categoría es alto, y si la probabilidad *a priori* es alta también. De otra manera, la regla favorecerá la otra categoría. Es importante recalcar que el patrón o muestra \mathbf{X} corresponde a un vector en el espacio N -dimensional formado por N atributos usados para la clasificación.

$$\begin{aligned}
 d(\mathbf{X}) &= A \text{ if } h_A l_A f_A(\mathbf{X}) > h_B l_B f_B(\mathbf{X}) \\
 d(\mathbf{X}) &= B \text{ if } h_A l_A f_A(\mathbf{X}) < h_B l_B f_B(\mathbf{X})
 \end{aligned}
 \tag{1}$$

Sin embargo, en la estrategia de Bayes, la función de probabilidad es desconocida y requiere de una técnica como la del método de Parzen para estimarla.

8.2. Método de Parzen

El método de Parzen calcula una función de peso para cada punto de muestra de entrenamiento y estima la función de densidad como una suma escalada de todas las funciones de peso individual (Figure 7). De acuerdo con Masters (1995), la mejor y más común función de peso, también llamada función potencial o kernel, es la distribución Gaussiana. Además de eso, en la aproximación de Parzen, también hay un importante parámetro de escalado, σ , que define el ancho de la curva con forma de campana que rodea cada punto de muestra y que tiene un importante efecto en el desempeño del PNN (Figure 7) (Masters, 1995).

Matemáticamente, Spetch (1988) describe la función de densidad de probabilidad de una muestra de entrenamiento \mathbf{X} en la categoría A como sigue:


$$f_A(\mathbf{X}) = \frac{1}{(2\pi)^{p/2} \sigma^p} \frac{1}{m} \sum_{i=1}^m e^{\left[-\frac{(\mathbf{X}-\mathbf{X}_{Ai})^t(\mathbf{X}-\mathbf{X}_{Ai})}{2\sigma^2} \right]}
 \tag{2}$$

donde, i es el número del patrón, m es el número total de patrones de entrenamiento, \mathbf{X}_{Ai} es el patrón de entrenamiento i^{th} de la categoría A , p es la dimensionalidad del espacio de medida, y σ es el parámetro de escalado o suavizado.

El valor σ es crucial puesto que puede tener un impacto considerable en el desempeño de la clasificación PNN. En la técnica usada en este estudio, y dentro del trabajo presentado por Lubo et al. (2019), PNN está acoplada con un algoritmo de búsqueda exhaustiva.

Figura 7.

Cálculo de la función de probabilidad de densidad como la suma escalada de las funciones de peso individuales.



Nota. El valor σ define el ancho de la curva con forma de campana que rodea cada uno de los datos de muestra. Imagen modificada de Masters (1995).

8.3. Algoritmo exhaustivo

Este algoritmo prueba todos los valores σ dentro de un intervalo definido por el usuario, pero también, todas las posibles combinaciones de atributos sísmicos preseleccionados como datos de entrenamiento para la clasificación. Con cada iteración, calcula un error que ayuda al intérprete a determinar la combinación de atributos sísmicos y valor σ más teóricamente correctos o óptimos de acuerdo con el algoritmo.

El cálculo del error E tiene en cuenta los datos de validación R . Como PNN es un método supervisado, el intérprete humano asigna, desde un principio, las categorías a las cuales pertenecen los datos de entrenamiento y validación. La red neuronal aprende en el proceso de entrenamiento

y después clasifica los datos de validación. El algoritmo compara las clasificaciones asignadas a los datos de validación por la máquina con las clasificaciones asignadas por el intérprete humano desde el principio. Finalmente, el algoritmo define el error E según la ecuación [3].

$$E = \frac{\sum_{r=1}^R e(r)}{R} \quad [3]$$

Si e es 0, significa que la muestra de validación clasificada por la máquina corresponde correctamente con la categoría asignada por el intérprete humano. Si e es 1, significa que la muestra de validación fue clasificada en otra categoría (Lubo et al., 2019).

9. Flujo de trabajo

La Figura 8. muestra el flujo generalizado seguido en este estudio. La primera parte del flujo de trabajo implica la preparación de los datos de entrenamiento y el preprocesamiento. Estos dos pasos iniciales requieren: el picado de los polígonos de facies, la selección de los atributos sísmicos, y la aplicación del filtro de suavizado Kuwahara 3D. Después, se aplica el algoritmo exhaustivo que indica la combinación de atributos sísmicos y valor σ que dan lugar al error E más pequeño. Finalmente, el algoritmo PNN se aplicó para generar tanto el volumen de predicción de facies como los volúmenes de probabilidad para cada una de las facies sísmicas.

En este flujo de trabajo se incluyó un paso adicional, la evaluación geocientífica. En este paso, se analiza cuidadosamente los volúmenes de predicción de facies y de probabilidad y se identifican las áreas mal clasificadas y las posibles razones que las hayan causado. Después, se evalúa la posibilidad de cambiar un parámetro inicial para mejorar los modelos de clasificación.

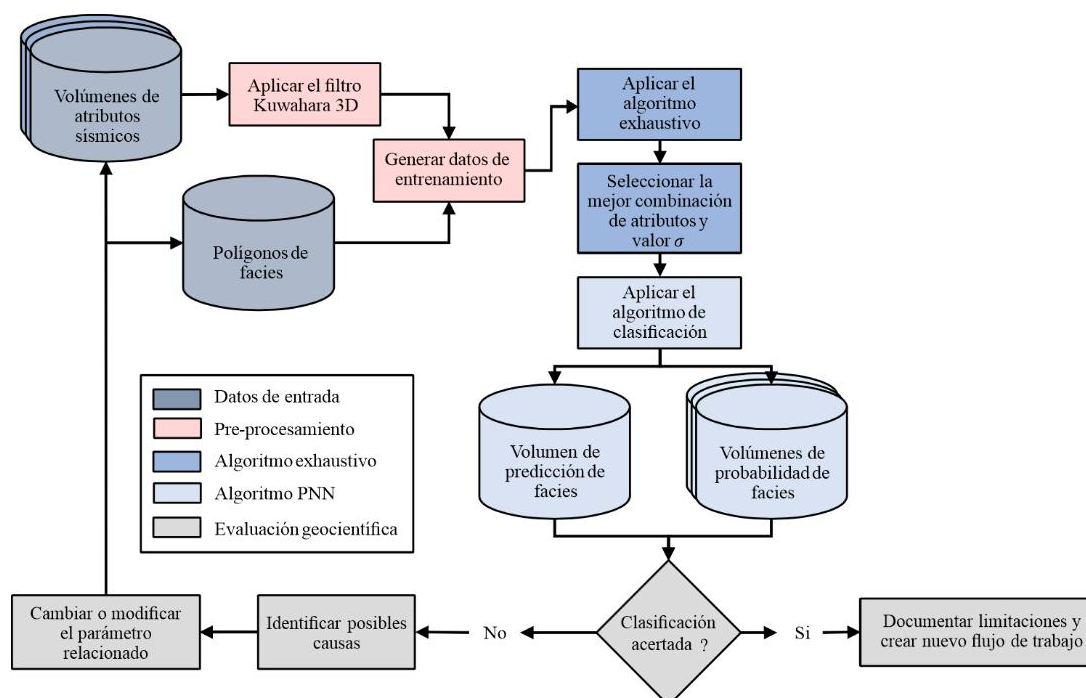
Siguiendo ese análisis, se aplican nuevamente los algoritmos y se comparan dichos resultados para entender el impacto del parámetro variado y las limitaciones del algoritmo PNN.

Para cumplir el objetivo de probar la capacidad de PNN para la clasificación de elementos arquitecturales relacionados con características geológicas de pequeña y gran escala, se definieron tres modelos iniciales. Modelo 1, incluyó las facies sísmicas de la sal, sedimentos conformes, MTD, canal, y ruido, el Modelo 2, incluyó las facies de sal, sedimentos conformes, MTD, y canal, y el Modelo 3, incluyó solamente las facies de sal, sedimentos conformes, y MTD.

Se realizaron varias iteraciones del flujo de trabajo, cambiando un parámetro específico en cada una de ellas, evaluando los diferentes resultados obtenidos para cada modelo. Al final se obtuvo un total de siete pruebas que serán explicadas más adelante en esta sección. Primero, se debe discutir los parámetros específicos que el geocientífico puede controlar.

Figura 8.

Flujo de trabajo generalizado seguido en el presente estudio.



Nota. Aquí se incluyó el criterio geocientífico como paso adicional para evaluar los resultados de las clasificaciones después de aplicar el algoritmo de PNN. Modificado de Lubo et al. (2019).

9.1. Parámetros modificados

El geocientífico puede controlar los siguientes parámetros:

9.1.1. Atributos sísmicos seleccionados

La cantidad y tipo de atributos sísmicos preseleccionados como candidatos para realizar las clasificaciones PNN dependerá de la revisión bibliográfica y de la experiencia del geocientífico. Puede haber diferentes tipos de atributos sísmicos en una misma categoría, por ejemplo, los atributos de envolvente y frecuencia instantánea corresponden a atributos instantáneos, los atributos de caos y GLCM, corresponden a atributos texturales. Esto debe ser revisado desde el principio, de tal manera que el intérprete elija los atributos que mejor diferenciaran las facies sísmicas a clasificar.

Incluso, hay maneras diferentes de calcular un mismo atributo sísmico, como los atributos geométricos. Los atributos de coherencia, por ejemplo, pueden ser calculados como el producto exterior de similitud (*outer product similarity*) o como similitud de filtro sobel (*sobel filter similarity*), mientras que el atributo de curvatura puede ser calculado como curvatura estructural de longitud de onda larga o de longitud de onda corta. El intérprete debe tener dichas opciones en mente.

9.1.2. Datos de entrenamiento y validación

Esto corresponde a la manera en cómo el geocientífico pica los polígonos de facies para después entrenar el algoritmo. El geocientífico puede decidir entre picar dichos polígonos en una, dos, o más líneas y cortes (*slices*), pero que puede también decidir entre picar en las zonas más sencillas o en las zonas más geológicamente complejas. Estas decisiones tendrán un impacto en el tiempo dedicado para la realización de las clasificaciones de facies. Picar más polígonos implica más tiempo, tanto del interprete como de la máquina. Además, picar en zonas más complejas implica un mayor nivel de dificultad y, por ende, más tiempo que el intérprete debe invertir.

Finalmente, este parámetro también implica la manera en cómo el intérprete decide cuáles polígonos serán usados para el entrenamiento y cuáles para validación. Esto, que pareciera no ser necesario de atención, realmente es un detalle importante. Los datos de entrenamiento son precisamente para enseñar el algoritmo, mientras que los de validación son para la verificación y estimación del error, es decir, el algoritmo no aprende de los polígonos usados para validación.

9.1.3. Facies sísmicas incluidas

En este parámetro el geocientífico debe observar detenidamente el volumen sísmico e identificar las facies sísmicas presentes. Estas facies pueden estar relacionadas a elementos de gran o pequeña escala. Si ambas están presentes, entonces se debe decidir si incluirlas todas en el modelo de clasificación o solamente considerar algunas de ellas.

9.1.4. Tamaño del volumen sísmico

Los volúmenes sísmicos pueden ser considerablemente grandes y, por ende, requerir altos tiempos de cómputo. El intérprete puede decidir entre usar el volumen sísmico completo, o si cortarlo en múltiples zonas como, por ejemplo, una zona somera y una zona profunda. Igualmente, se puede usar para delimitar zonas donde ciertos tipos de características geológicas son más probables que aparezcan.

9.1.5. Ventana de análisis

Este parámetro aplica generalmente para todos los atributos sísmicos, sin embargo, es especialmente importante para la aplicación del filtro de suavizado Kuwahara 3D. De acuerdo con, Qi et al. (2016), si la ventana de análisis de dicho filtro es grande, entonces la imagen estará suavizada, pero con un patrón de bloques, si la ventana de análisis es pequeña, entonces la imagen se verá menos suavizada y el patrón de bloques también se reducirá.

9.2. Pruebas realizadas

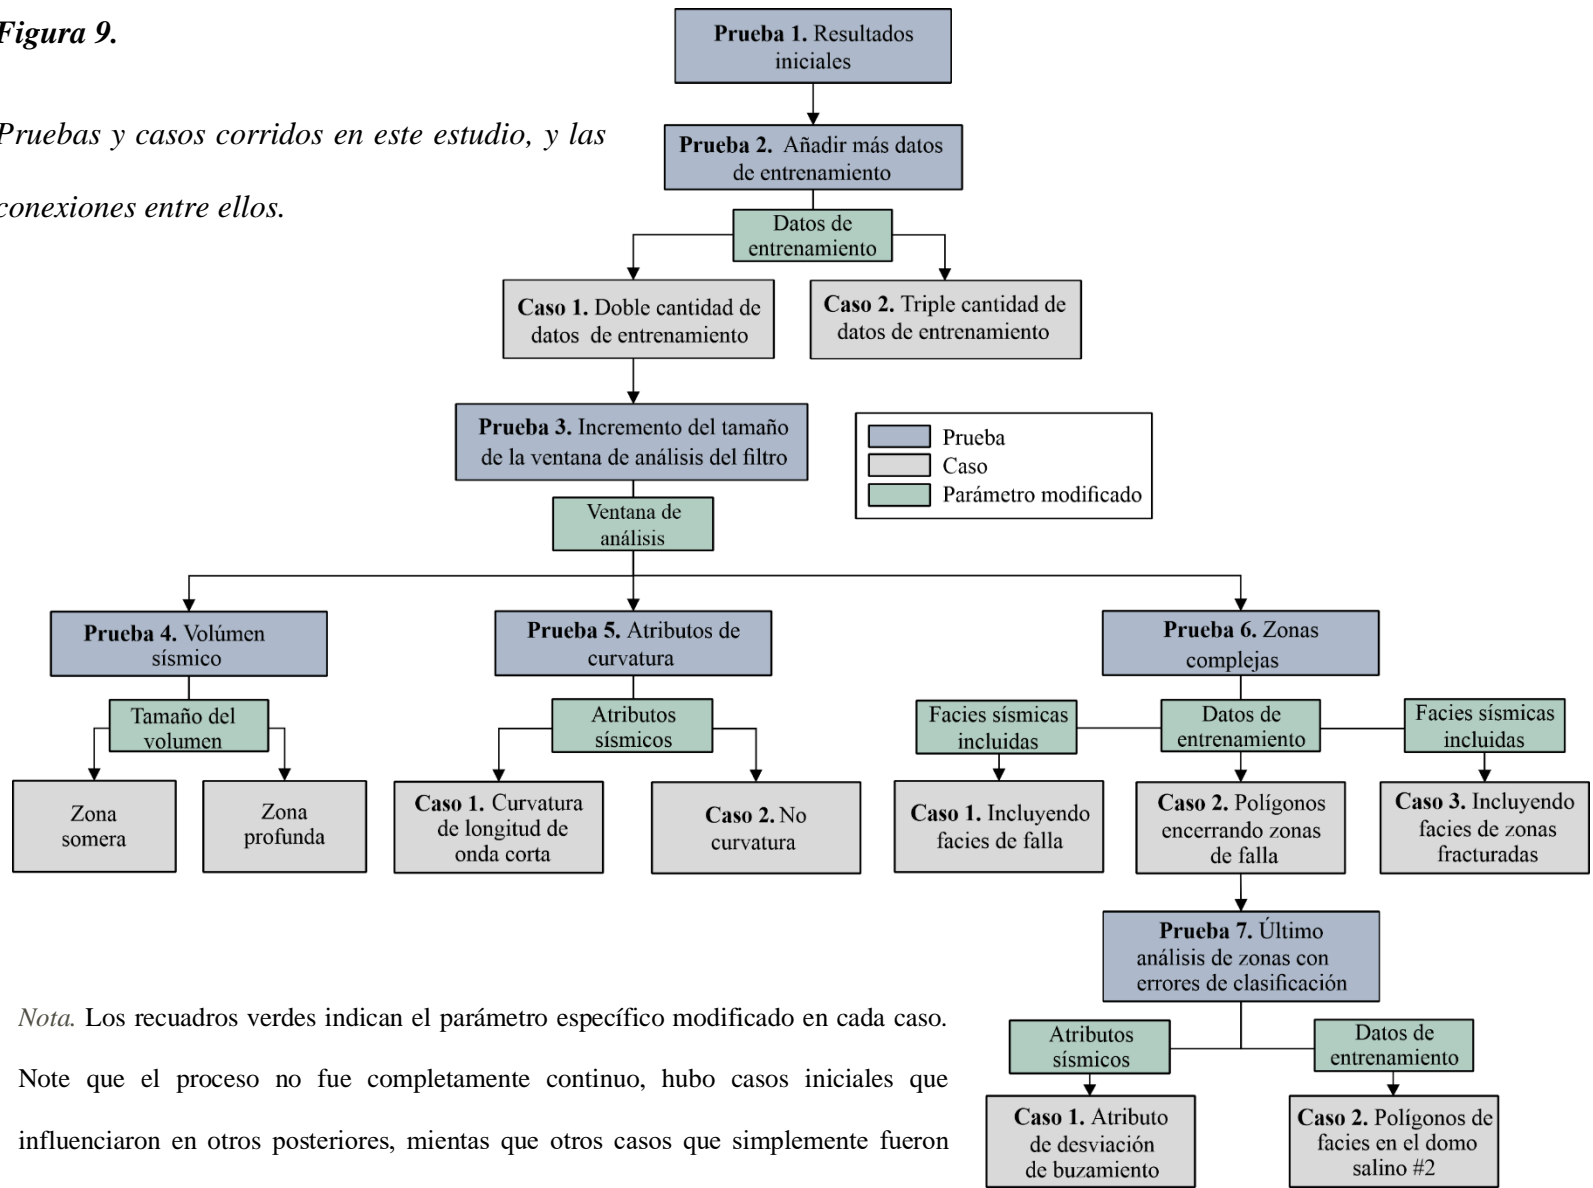
Ahora que los parámetros se han explicado, se procede a explicar las pruebas realizadas y el parámetro específico modificado en cada una de ellas.

- Prueba 1: corresponde a las primeras clasificaciones realizadas
- Prueba 2: explora el impacto de añadir más datos de entrenamiento
- Prueba 3: utiliza un tamaño más grande de la ventana de filtro Kuwahara 3D
- Prueba 4: utiliza dos volúmenes, uno que corresponde a la zona somera y otro a la zona profunda
- Prueba 5: explora el impacto de usar atributos de curvatura calculados con longitud de onda pequeña en vez de longitud de onda grande, y también el impacto de no usar atributos de curvatura
- Prueba 6: incluye más facies sísmicas y cambia la manera en cómo se pican los polígonos de facies
- Prueba 7: realiza las clasificaciones incluyendo otro atributo sísmico, el atributo de desviación de buzamiento, y explora la aplicación de polígonos de facies picados en el área más compleja cercana al segundo domo salino.

La Figura 9 muestra la manera sistemática como se realizaron las pruebas, y las conexiones lógicas entre ellas. Dichas conexiones entre pruebas indican como un impacto positivo de una prueba influyó en la siguiente, de esta manera, las clasificaciones se fueron mejorando progresivamente. Es importante tener en cuenta que algunas de las pruebas se llevaron a cabo de diferentes maneras y por eso puede tener dos o más casos. Los parámetros específicos aplicados en cada prueba se muestran detalladamente en la Tabla 1.

Figura 9.

Pruebas y casos corridos en este estudio, y las conexiones entre ellos.



Nota. Los recuadros verdes indican el parámetro específico modificado en cada caso. Note que el proceso no fue completamente continuo, hubo casos iniciales que influenciaron en otros posteriores, mientras que otros casos que simplemente fueron descartados.

Tabla 1.

Parámetros específicos aplicadas en cada prueba y caso.

Prueba	Parametro modificado	Objetivo	Caso	Parámetros específicos				
				Atributos sísmicos pre-seleccionados	Cantidad de datos de entrenamiento	Ventana de análisis del filtro	Facies sísmicas incluidas	Longitud del registro
Prueba 1.	-	Resultados iniciales	-	k1 y k2 (longitud de onda larga), GLCM-contraste, GLCM-desemejanza, envolvente, coherencia	1 línea, 1 corte en tiempo	$41 ft^2 \times 131 ft^2 \times 0.004 s$	Sal, MTD, Sedimentos Conf., Canal, Ruido	1.5 a 4.1 s
Prueba 2.	Datos de entrenamiento	Probar el impacto de usar más datos de entrenamiento	Caso 1		2 líneas, 2 cortes en tiempo	$41 ft^2 \times 131 ft^2 \times 0.004 s$	Sal, MTD, Sedimentos Conf., Canal, Ruido	1.5 a 4.1 s
			Caso 2		3 líneas, 3 cortes en tiempo			
Prueba 3.	Ventana de análisis	Probar el impacto de usar una ventana de análisis del filtro más grande	-		2 líneas, 2 cortes en tiempo	$123 ft^2 \times 393 ft^2 \times 0.012 s$	Sal, MTD, Sedimentos Conf., Canal, Ruido	1.5 a 4.1 s
Prueba 4.	Tamaño del volumen	Usar volúmenes más pequeños y verificar si se observa alguna mejora en las clasificaciones	Somero		2 líneas, 2 cortes en tiempo	$41 ft^2 \times 131 ft^2 \times 0.004 s$ $123 ft^2 \times 393 ft^2 \times 0.012 s$	Sal, MTD, Sedimentos Conf., Canal, Ruido	1.5 a 2.7 s
			Profundo		2 líneas, 2 cortes en tiempo	$123 ft^2 \times 393 ft^2 \times 0.012 s$		
Prueba 5.	Atributos seleccionados	Cambiar la forma de cálculo de los atributos de curvatura y verificar si se observa una disminución de los artefactos verticales	Caso 1		2 líneas, 2 cortes en tiempo	$123 ft^2 \times 393 ft^2 \times 0.012 s$	Sal, MTD, Sedimentos Conf.	1.5 a 4.1 s
			Caso 2					
Prueba 6.	Facies incluidas	Añadir una facie de falla para clasificar fallas y eliminar las clasificaciones incorrectas en aquellas áreas	Caso 1		2 líneas, 2 cortes en tiempo	$123 ft^2 \times 393 ft^2 \times 0.012 s$	Sal, MTD, Sedimentos Conf., Fallas	1.5 a 4.1 s
	Datos de entrenamiento	Probar el impacto de cambiar la manera de picar los polígonos de facies en la zonas de fallas	Caso 2		2 líneas, 2 cortes en tiempo	$123 ft^2 \times 393 ft^2 \times 0.012 s$	Sal, MTD, Sedimentos Conf.	1.5 a 4.1 s
	Facies incluidas	Añadir una facie de zonas fracturadas para clasificar los estratos altamente fracturados cercanos al tope de los domos salinos	Caso 3	2 líneas, 2 cortes en tiempo	$123 ft^2 \times 393 ft^2 \times 0.012 s$	Sal, MTD, Sedimentos Conf., Zona Fracturada	1.5 a 4.1 s	
Prueba 7.	Atributos seleccionados	Probar un atributo de noparalelismo para clasificar mejor las facies de sedimentos conformes, especialmente en zonas donde están altamente fracturados	Caso 1	k1 y k2 (longitud de onda larga), GLCM-contraste, GLCM-desemejanza, envolvente, desviación de buzamiento	2 líneas, 2 cortes en tiempo	$123 ft^2 \times 393 ft^2 \times 0.012 s$	Sal, MTD, Sedimentos Conf.	1.5 a 4.1 s
	Datos de entrenamiento	Probar el impacto de cambiar la manera de picar los polígonos de facies en zonas más geológicamente complejas	Caso 2	k1 y k2 (longitud de onda larga), GLCM-contraste, GLCM-desemejanza, envolvente, coherencia	2 líneas, 2 cortes en tiempo	$123 ft^2 \times 393 ft^2 \times 0.012 s$	Sal, MTD, Sedimentos Conf.	1.5 a 4.1 s

9.2.1. Prueba 1: Resultados iniciales

La primera prueba se realizó picando los polígonos de facies de entrenamiento en una línea y un corte en tiempo, y los polígonos de facies de validación en otra línea y otro corte en tiempo. En esta prueba se aplicó el filtro Kuwahara 3D con una ventana de análisis igual al tamaño de celda $41 \text{ ft}^2 \times 131 \text{ ft}^2 \times 0.004 \text{ s}$. También se utilizó el volumen sísmico inicialmente cortado; es decir, el de 380 km^2 y una longitud de registro de 4.1 s. Esta primera prueba servirá como punto de partida para detectar las zonas con clasificaciones iniciales incorrectas y empezar a realizar modificaciones a los parámetros iniciales.

9.2.2. Prueba 2: Adición de más datos de entrenamiento

En la Prueba 2, se quería explorar el impacto de añadir más datos de entrenamiento. Este parámetro puede ayudar a mejorar las clasificaciones de facies sísmicas, pero igualmente puede dar lugar a mayores tiempos de cómputo. Por ello, se crearon dos casos: Caso 1, usando doble cantidad de datos de entrenamiento; es decir, dos líneas y dos cortes en tiempo; y Caso 2, usando triple cantidad de datos de entrenamiento; es decir, tres líneas y tres cortes en tiempo. El resto de los parámetros permanecieron igual. Con esta prueba, se podrá determinar si efectivamente hay un impacto positivo después de aumentar la cantidad de datos de entrenamiento y, si es así, qué tan grande debe ser ese aumento. El primer caso se probó en los tres modelos, mientras que el segundo solo se aplicó en el Modelo 3. Todos los polígonos de facies adicionales se picaron en el área cercana al primer domo salino.

9.2.3. Prueba 3: Ventana de análisis del filtro Kuwahara

Para la Prueba 3, se exploró el impacto de usar una ventana de análisis más grande, de $123 \text{ ft}^2 \times 393 \text{ ft}^2 \times 0.012 \text{ s}$, en el cálculo del filtro Kuwahara 3D en los atributos sísmicos. Aunque Qi et al. (2015) indican que esto puede ayudar a definir mejor las facies sísmicas, en dichos estudios solo se clasificaron facies relacionadas a elementos de gran escala. En el presente estudio se clasifican elementos de gran y pequeña escala, haciendo necesario evaluar el impacto de este cambio en cada modelo.

9.2.4. Prueba 4: Volumen cortado

Siguiendo la suposición de que usar volúmenes más pequeños hace que la clasificación de facies sísmicas sea más fácil para el algoritmo, se decidió cortar el volumen sísmico en una parte somera y una parte profunda. La parte somera cubrió la región desde los 1.5 s a los 2.7 s, mientras que la parte profunda cubrió de los 2.6 s a los 4.1 s. La clasificación de la zona profunda se corrió únicamente con el Modelo 3, puesto que las únicas facies sísmicas encontradas en dicho intervalo son las de sal, MTD, y sedimentos conformes. La clasificación de la zona somera, por otro lado, se corrió en los tres modelos.

9.2.5. Prueba 5: Curvatura con longitud de onda corta vs. No curvatura

Cuando se corrieron las clasificaciones previas, se notaron unos artefactos verticales en todos los volúmenes de clasificación. Dichos artefactos se correlacionaron con los atributos de curvatura calculados con la longitud de onda larga. En el Caso 1, se decidió probar los atributos de curvatura calculados con longitud de onda corta, mientras que en el Caso 2, se decidió no usar ninguno de los atributos de curvatura. Estos casos se corrieron únicamente con el Modelo 3. En este sentido, la prueba 5 permitirá analizar el impacto de cambiar la manera en cómo se calculan atributos sísmicos como los de curvatura.

9.2.6. Prueba 6: Zonas geológicamente complejas

Para abordar las zonas más complejas, como aquellas altamente fracturadas o falladas, se exploraron tres casos en la Prueba 6. Caso 1, incluyó facies de falla; Caso 2, usó polígonos de facies picados de tal manera que encerraran las zonas de fallas; y el Caso 3, incluyó facies de zonas fracturadas. Todas las facies adicionales se picaron en la zona cercana al primer domo salino

9.2.7. Prueba 7: Último análisis en las zonas con errores de clasificación

Finalmente, en la Prueba 7, se quería corregir algunas áreas con clasificaciones incorrectas entre las facies de sedimentos conformes y MTD, especialmente en el área cercana al tope del segundo domo salino. Para ello, en el Caso 1, se decidió realizar las clasificaciones de facies sísmicas utilizando el atributo de desviación de buzamiento en vez del atributo de coherencia. En

el Caso 2, se cambió la manera de picar los polígonos de facies, y estos se generaron en el área cerca al segundo domo salino, donde los sedimentos conformes están altamente fallados y donde las intercalaciones entre los MTD y los sedimentos conformes son más difíciles de distinguir. Con este Caso 2, se busca adicionalmente determinar si las clasificaciones de facies sísmicas mejoran después de generar los polígonos de facies en áreas con mayor complejidad geológica.

10. Resultados

En esta sección se realizará un análisis detallado de los volúmenes de predicción de facies generados por el algoritmo PNN en cada una de las pruebas realizadas, al igual que los valores de error calculados por el algoritmo exhaustivo. Para este análisis se comparan los resultados obtenidos en una prueba específica, con los resultados de la prueba inmediatamente anterior.

En esta sección igualmente se mostrará como los resultados de las pruebas y casos iniciales influenciaron en la definición de parámetros de pruebas y casos posteriores. La Tabla 2 muestra la compilación de las mejores combinaciones de atributos sísmicos y valores σ obtenidos para cada prueba y caso. Note que los atributos de curvatura principal más positiva k_1 , envolvente, y coherencia, conforman la mejor combinación de atributos calculada por el algoritmo exhaustivo para casi todas las pruebas y casos, siendo la única excepción el segundo caso de la Prueba 7. Igualmente, note que casi todos los valores σ están dentro del intervalo entre 0.1 a 0.3.

Tabla 2.

Compilación de las mejores combinaciones de atributos sísmicos y valores σ obtenidos en cada prueba y caso.

Prueba	Caso	Modelo	Facies sísmicas	Mejor combinación de atributos sísmicos	Error	Sigma		
Prueba 1	N/A	1	Sal, MTD, Sedimentos Conf., Canal, Ruido	k1, GLCM-desemejanza, envolvente, y coherencia	0.274	0.1		
		2	Sal, MTD, Sedimentos Conf., Canal	k1, envolvente, y coherencia	0.233	0.1		
		3	Sal, MTD, Sedimentos Conf.	k1, envolvente, y coherencia	0.147	0.2		
Prueba 2	Caso 1	1	Sal, MTD, Sedimentos Conf., Canal, Ruido	k1, GLCM-contraste, envolvente, y coherencia	0.233	0.1		
		2	Sal, MTD, Sedimentos Conf., Canal	k1, envolvente, y coherencia	0.199	0.1		
		3	Sal, MTD, Sedimentos Conf.	k1, envolvente, y coherencia	0.148	0.1		
	Caso 2	3	Sal, MTD, Sedimentos Conf.	k1, envolvente, y coherencia	0.143	0.1		
		Prueba 3	N/A	1	Sal, MTD, Sedimentos Conf., Canal, Ruido	k1, k2, GLCM-contraste, envolvente, y coherencia	0.181	0.2
				2	Sal, MTD, Sedimentos Conf., Canal	k1, GLCM-contraste, envolvente, y coherencia	0.136	0.2
3	Sal, MTD, Sedimentos Conf.			k1, GLCM-contraste, envolvente, y coherencia	0.092	0.2		
Prueba 4	Somero	1	Sal, MTD, Sedimentos Conf., Canal, Ruido	k1, envolvente, y coherencia	0.302	0.1		
		2	Sal, MTD, Sedimentos Conf., Canal	k1, envolvente, y coherencia	0.277	0.1		
		3	Sal, MTD, Sedimentos Conf.	k1, envolvente, y coherencia	0.145	0.1		
	Profundo	3	Sal, MTD, Sedimentos Conf.	GLCM-desemejanza, envolvente, y coherencia	0.081	0.1		
Prueba 5	Caso 1	3	Sal, MTD, Sedimentos Conf.	k1 (longitud de onda corta), GLCM-contraste, envolvente, y coherencia	0.113	0.2		
	Caso 2	3	Sal, MTD, Sedimentos Conf.	GLCM-contraste, envolvente, y coherencia	0.11	0.2		
Prueba 6	Caso 1	-	Sal, MTD, Sedimentos Conf., Fallas	k1, k2, GLCM-desemejanza, envolvente, y coherencia	0.108	0.3		
	Caso 2	3	Sal, MTD, Sedimentos Conf.	k1, GLCM-contraste, envolvente, y coherencia	0.102	0.2		
	Caso 3	-	Sal, MTD, Sedimentos Conf., Zona Fracturada	k1, envolvente, y coherencia	0.239	0.1		
Prueba 7	Caso 1	3	Sal, MTD, Sedimentos Conf.	k1, GLCM-contraste, envolvente, y desviación de buzamiento	0.111	0.2		
	Caso 2	3	Sal, MTD, Sedimentos Conf.	k2, envolvente, y coherencia	0.103	0.2		

10.1. Prueba 1: Resultados iniciales

El Modelo 1 se realizó con la siguiente combinación de atributos sísmicos: k1, GLCM-desemejanza, envolvente, y coherencia, y un valor σ de 0.1. Esta combinación mostró un error

mínimo de 0.274. En los resultados obtenidos (Figura 10a), se pueden observar errores de clasificación entre las facies de sal, MTD, y ruido dentro de los sedimentos conformes de las zonas profundas del volumen. Igualmente, se observan zonas dentro de las facies de sedimentos conformes, que fueron incorrectamente clasificadas como facies de canal. El algoritmo, sin embargo, diferenció correctamente la capa de ruido al tope de la sección a pesar de las clasificaciones incorrectas en la base. Cuando se observa el corte en tiempo a 2060 ms (derecha de la Figura 10a), donde debería observarse claramente el canal, se puede evidenciar que este fue correctamente clasificado dentro de su respectiva facie y aislado de las facies de sedimentos conformes. Otras áreas en el mismo corte en tiempo fueron incorrectamente clasificadas como facies de canal y/o ruido.

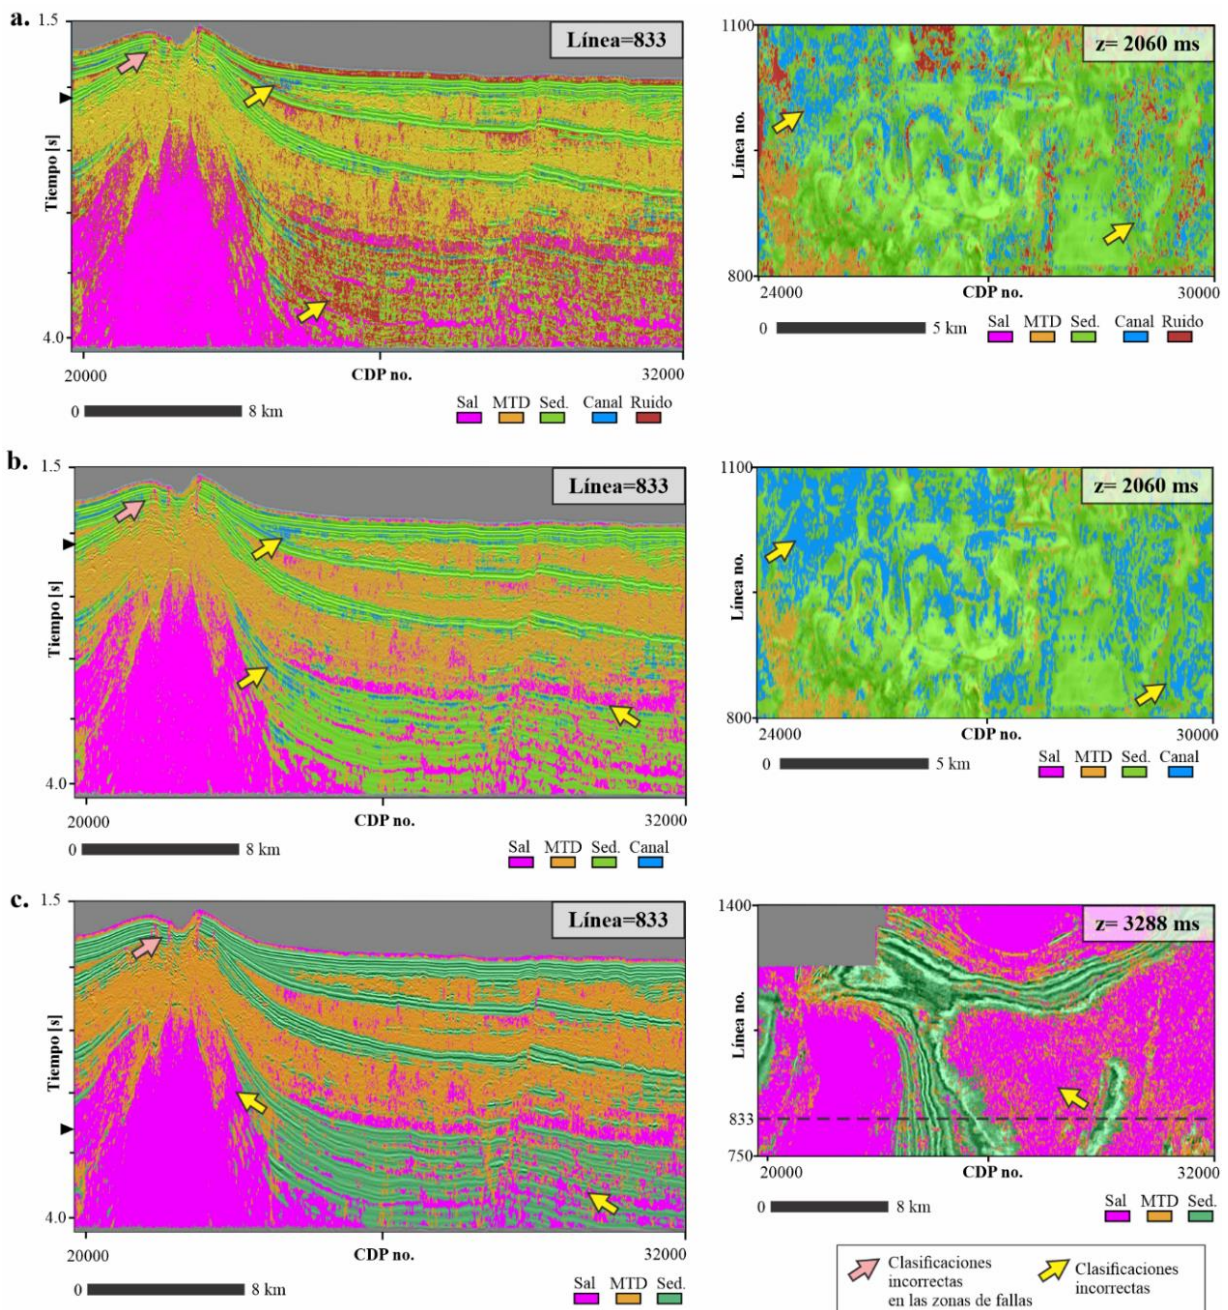
El Modelo 2, tuvo el mínimo error de 0.233 usando un valor σ de 0.1 y la combinación de atributos de k1, envolvente, y coherencia. Los resultados de este modelo son similares a los obtenidos en el Modelo 1, el algoritmo tuvo mayor inconveniente diferenciando las facies de sal de las facies de MTD en las zonas profundas del volumen sísmico, y en el tope de los domos salinos (Figura 10b). Adicionalmente, algunas áreas relacionadas a los sedimentos conformes fueron incorrectamente clasificadas como facies de canal. En el corte de tiempo a 2060 ms, el canal se ve mejor definido y aislado con respecto al Modelo 1. Sin embargo, note que otras áreas fueron mal clasificadas como facies de canal y tuvieron respuestas más fuertes. Esto indica que para las facies de canal tanto las clasificaciones correctas como las incorrectas en el Modelo 1, fueron más resaltadas en el Modelo 2.

Modelo 3, clasificando únicamente características de gran escala, como aquellas relacionadas a las facies de sal, MTD, y sedimentos conformes, tuvieron el mínimo error de 0.147 usando el valor σ de 0.2, y la combinación de los atributos k1, envolvente, y coherencia. En las

zonas profundas del volumen sísmico se puede notar que el algoritmo tuvo dificultades para distinguir entre las facies de sal y MTD, y entre las facies de sedimentos conformes y sal (Figura 10c).

Figura 10.

Volúmenes de predicción de facies obtenidos de la Prueba 1.



Nota. Resultados obtenidos después de entrenar el algoritmo con una línea y un corte en tiempo, y aplicar el filtro de Kuwahara 3D igual al tamaño de celda base de $41 \text{ ft}^2 \times 131 \text{ ft}^2 \times 0.004 \text{ s}$. a. Modelo 1, b. Modelo 2, c. Modelo 3. Note que en los tres modelos la facie profunda está siendo incorrectamente clasificada como facies de sal y ruido. En el Modelo 1, note que la capa de ruido fue correctamente clasificada y en el corte en tiempo a 2060 ms, el canal fue correctamente interpretado dentro de la facie correspondiente. En el Modelo 2, el canal está mejor resaltado. En el Modelo 3, el corte en tiempo a 3288 ms muestra un MTD siendo incorrectamente clasificado como sal. Todas estas imágenes corresponden a la mezcla entre el volumen de amplitud y los volúmenes de predicción de facies.

Note que, en los tres modelos, el área que se interpretó como zona altamente fracturada fue clasificada como facie de sal. Igualmente, note que la mayoría de las zonas con errores de clasificación presentaron un patrón de vertical. Después de estos resultados se decidió aumentar los datos de entrenamiento, buscando una mejoría de las clasificaciones de facies en dichas zonas más problemáticas.

10.2. Prueba 2: Adición de más datos de entrenamiento

En el primer caso, usando doble cantidad de datos de entrenamiento, el Modelo 1 tuvo el mínimo error de 0.233 con un valor σ de 0.1 y la combinación de atributos de k1, GLCM-contraste, envolvente, y coherencia. Note que los errores de clasificación disminuyeron considerablemente en las zonas profundas (Figura 11a), mientras que aquellas en la zona somera permanecieron igual. El canal observado en el corte en tiempo a 2060 ms fue sutilmente más resaltado y las facies de ruido incorrectamente clasificadas en la prueba anterior fueron menos obvias en esta prueba.

El Modelo 2 tuvo un mínimo error de 0.199 cuando se combinó el valor σ de 0.1 y los atributos de k1, envolvente, y coherencia. Aunque en esta prueba, el canal fue mejor resaltado y aislado en el corte en tiempo a 2060 ms, los errores de clasificación entre las facies de canal y los sedimentos conformes (Figura 11b) permanecieron casi iguales en comparación con los resultados de la Prueba 1.

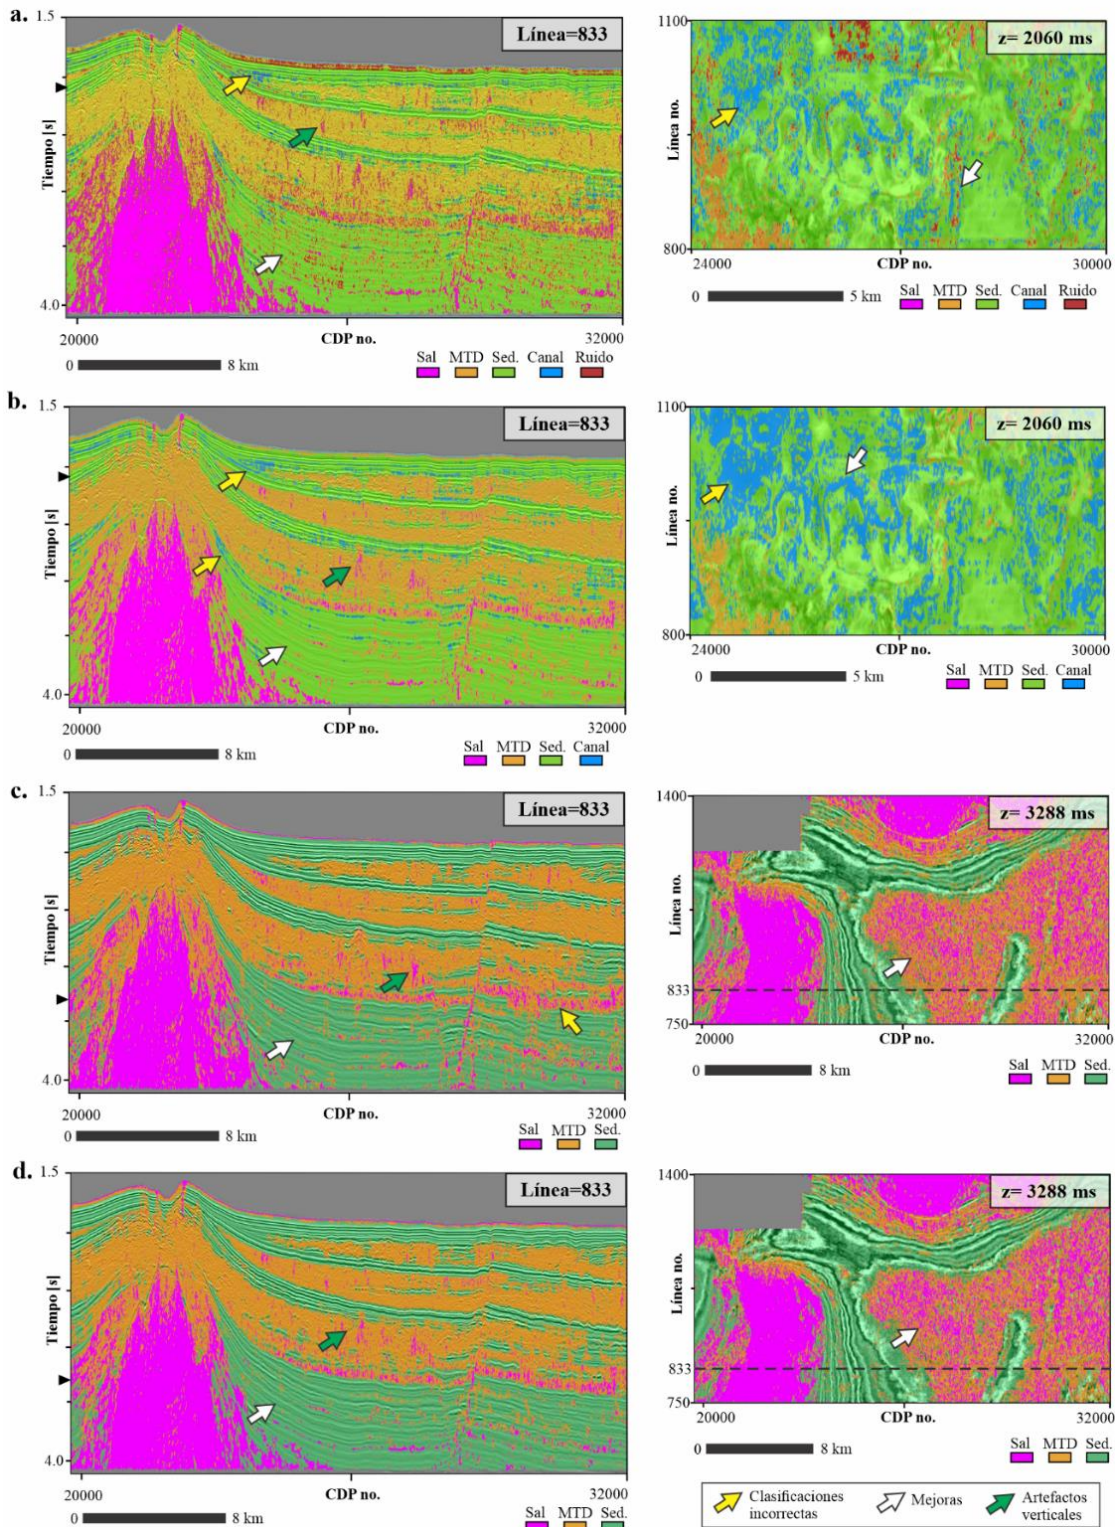
Para el primer caso, el Modelo 3 tuvo el mínimo y óptimo error de 0.148 cuando se combinaron los atributos de k1, envolvente, y coherencia, y el valor σ de 0.1. En la Figura 11c, se puede evidenciar una mejoría considerable en la clasificación de facies en las zonas profundas después de utilizar el doble de la cantidad de datos de entrenamiento. Por otro lado, en el segundo caso, el Modelo 3 no mostró ninguna diferencia notable después de usar el triple de la cantidad de datos de entrenamiento iniciales (Figura 11d).

Algunas observaciones similares en los tres modelos fueron: la disminución generalizada del valor de error calculado por el algoritmo, menos equivocaciones entre las clasificaciones de las facies de sal y de MTD en las zonas profundas y en las zonas fracturadas cerca al tope de los domos salinos. Igualmente, note que en los tres modelos las zonas de fallas permanecieron incorrectamente clasificadas y aun se pueden observar artefactos verticales.

En general, después de usar el doble de la cantidad de datos de entrenamiento los resultados mejoraron considerablemente. Aun así, cuando se utilizó el triple de la cantidad de datos de entrenamiento, las clasificaciones no mostraron ninguna mejoría significativa, mientras que dicho caso sí implicó mayor tiempo de cómputo.

Figura 11.

Volúmenes de predicción de facies obtenidos de la Prueba 2.



Nota. Resultados obtenidos después de aumentar los datos de entrenamiento. a, b, y c, corresponde a los Modelos 1, 2 y 3 respectivamente, usando el doble de los datos de entrenamiento iniciales. d. corresponde al Modelo 3 usando el triple de los datos de entrenamiento iniciales. Note la disminución significativa de los errores de clasificación en las zonas profundas de los volúmenes de predicción después de usar el doble de los datos de entrenamiento. Mientras que usando el triple de los datos de entrenamiento no muestra ninguna mejoría notoria.

10.3. Prueba 3: Ventana de análisis del filtro Kuwahara

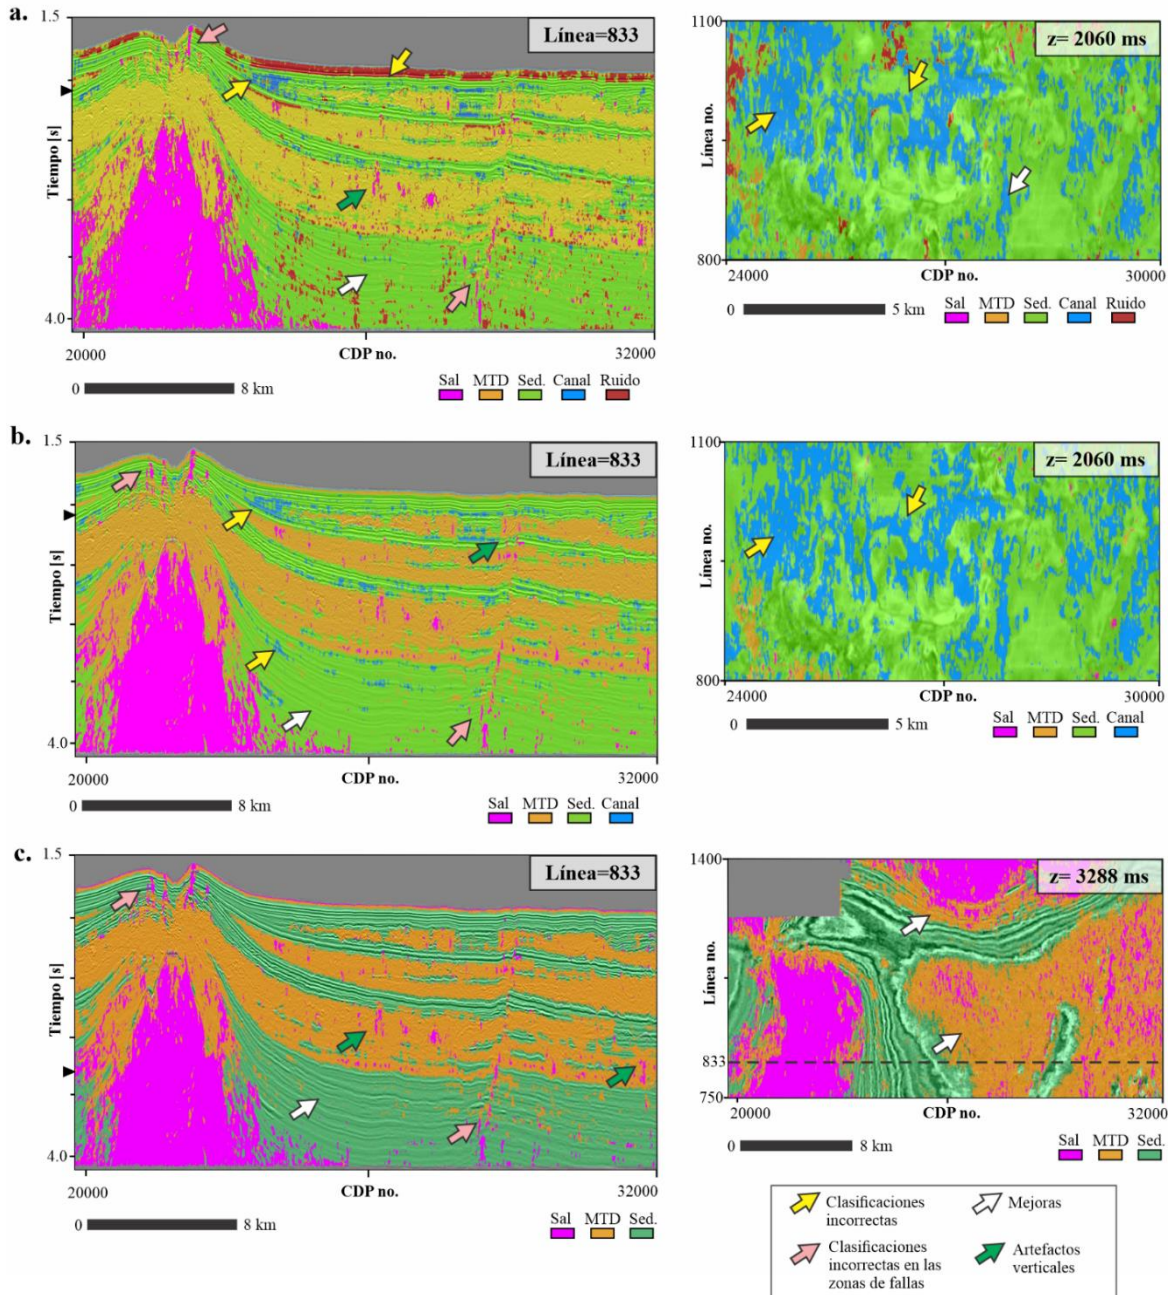
Para esta prueba, se decidió utilizar una ventana de análisis más grande de $123 \text{ ft}^2 \times 393 \text{ ft}^2 \times 0.012 \text{ s}$. Siguiendo los resultados obtenidos de la prueba anterior, también se decidió continuar usando el doble de la cantidad inicial de datos de entrenamiento. El resto de los parámetros iniciales permanecieron igual.

El Modelo 1 tuvo el error más óptimo de 0.181 cuando se combinó σ igual a 0.2 y los atributos de k1, k2, GLCM-contraste, envolvente, y coherencia. El Modelo 2, tuvo el error más óptimo de 0.136 con σ igual a 0.2 y los atributos de k1, GLCM-contraste, envolvente, y coherencia. Esta combinación de atributos y valores σ también fue la más óptima para el Modelo 3, el cual tuvo un error de 0.092.

Después de cambiar este parámetro, los resultados de los tres modelos mejoraron significativamente para las facies sísmicas relacionadas con elementos de gran escala. En la Figura 12, se puede observar los errores de clasificación entre las facies de sal y MTD, y dentro de los sedimentos conformes de las zonas profundas para todos los tres modelos. En esta prueba, el Modelo 3 (Figura 12c) resaltó notablemente en comparación con las clasificaciones previas de este mismo modelo, pues presentó la mejor clasificación observada hasta este punto.

Figura 12.

Volúmenes de predicción de facies obtenidos de la Prueba 3.



Nota. Resultados obtenidos después de usar el doble de la cantidad de datos de entrenamiento iniciales y una ventana de análisis del filtro más grande. a, Modelo 1, b, Modelo 2, y c, Modelo 3. Note que en los tres modelos la clasificación de características de gran escala mostró mejores resultados, mientras que la clasificación de características de pequeña escala desmejoró considerablemente.

En el corte en tiempo a 2060 ms de los Modelos 1 y 2, el canal apenas se puede ver (Figura 12 a, b). Aun así, la capa de ruido cerca al lecho marino en el Modelo 1, a pesar de estar mejor interpretada, dicha clasificación se extendió a las partes someras de las facies de sedimentos conformes, haciendo que el resultado de dicha clasificación se considere incorrecto (Figura 12a). Las zonas de falla incorrectamente clasificadas en las pruebas anteriores no mostraron ninguna mejoría en esta prueba para ninguno de los modelos.

Después de estos resultados, los cuales parecen favorecer únicamente el Modelo 3, se decidió correr las siguientes pruebas aumentando la ventana de análisis del filtro únicamente para dicho Modelo 3, y dejando una ventana de análisis pequeña para los otros modelos.

10.4. Prueba 4: Volumen cortado

En esta prueba se cortó el volumen sísmico en dos, una zona somera y una zona profunda. La zona somera se corrió en los tres modelos, mientras que la zona profunda se corrió solamente con el Modelo 3, puesto que en esta zona solamente se encuentran elementos arquitecturales relacionados con características geológicas de gran escala, haciendo que solo sea necesario el modelo que se enfoca en dichas facies.

La zona somera del Modelo 1 tuvo el mínimo error de 0.302 con un σ igual a 0.1 y usando la combinación de atributos de k1, envolvente, y coherencia. Este error fue mayor al obtenido para el Modelo 1 de la Prueba 2, la cual usó el volumen sísmico completo. Cuando se compararon las clasificaciones de la zona somera de la Prueba 2 (Figura 11a) con las de la Prueba 4 (Figura 13a), se observa que hay más errores de clasificación después de cortar el volumen sísmico. Estos errores

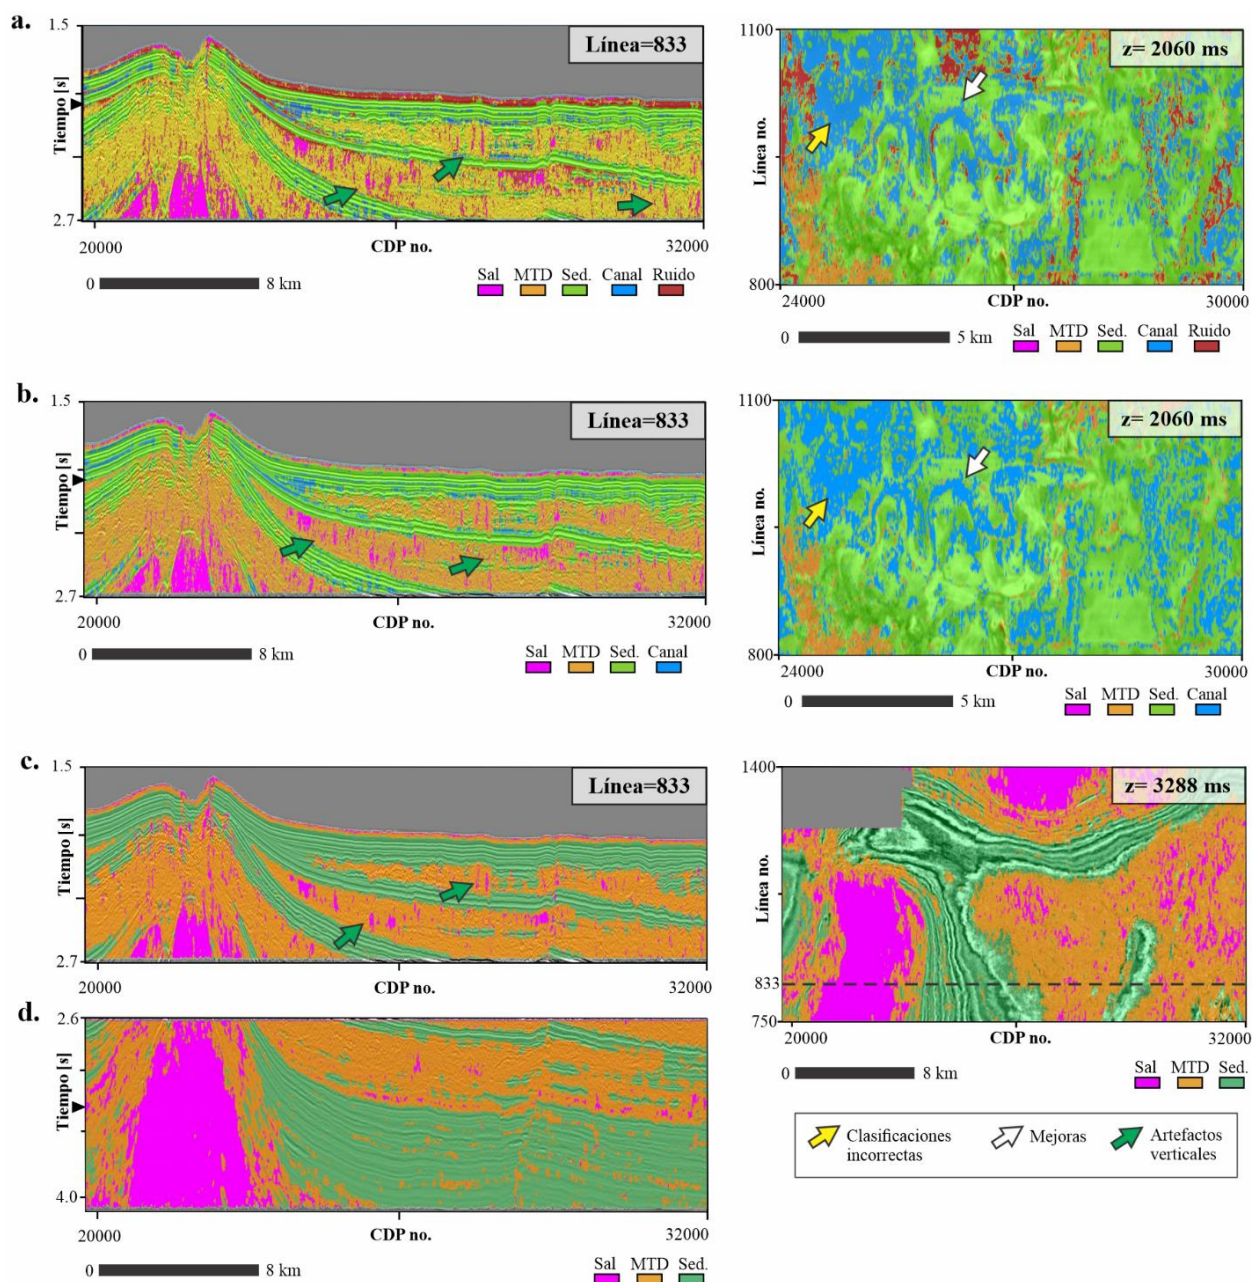
de clasificación se presentan especialmente dentro de las facies de MTD, donde los artefactos verticales son más notables. En el corte en tiempo a 2060 ms (Figura 13a), el canal y otras zonas incorrectamente clasificadas también fueron más resaltadas.

Los resultados del Modelo 2 fueron similares a aquellos obtenidos para el Modelo 1, el error más pequeño de 0.277 fue también más grande que el valor de error de la Prueba 2, y fue obtenido con un σ igual a 0.1 y la combinación de los atributos de k1, envolvente, y coherencia. La Figura 13b muestra el incremento de los errores de clasificación dentro de las facies MTD, las cuales también presentaron artefactos verticales. Adicionalmente, en el corte en tiempo a la derecha de la Figura 13b, se notó que no había ninguna mejoría significativa e importante entre la clasificación del canal en esta Prueba 4 y la Prueba 2.

La región somera del Modelo 3 (Figura 13c) tuvo el error más óptimo de 0.145 con un σ igual a 0.1 y usando los atributos de k1, envolvente, y coherencia. La región profunda tuvo el error de 0.081 usando los atributos de GLCM-desemejanza, envolvente, y coherencia, y σ igual a 0.1. La zona somera presentó los mismos artefactos observados en los Modelos 1 y 2 (Figura 13 a, b). En la zona profunda, la principal diferencia comparada con las pruebas anteriores fue que las zonas cerca al domo salino se interpretaron como MTD en vez de sal (Figura 13d). En el corte en tiempo a 3288ms del Modelo 3, las facies de MTD y sal fueron correctamente distinguidas y mostraron resultados similares a aquellos obtenidos en la Prueba 3.

Figura 13.

Volúmenes de predicción de facies de la Prueba 4.



Nota. Resultados obtenidos después de cortar el volumen sísmico en una zona somera y una zona profunda. a. Zona somera del Modelo 1, b. Zona somera del Modelo 2, c. Zona somera del Modelo 3, y d. Zona profunda del Modelo 3. En todos los modelos se obtuvo una respuesta más fuerte de los artefactos verticales en la zona somera. En la zona profunda las clasificaciones no mostraron una diferencia considerable con respecto a las pruebas anteriores.

10.5. Prueba 5: Curvatura con longitud de onda corta vs. no curvatura

El objetivo de esta prueba era eliminar o disminuir los artefactos verticales observados en los volúmenes de clasificación obtenidos en las pruebas anteriores. Para ello se crearon dos casos: Caso 1, usando atributos de curvatura calculados con longitud de onda corta, y Caso 2, el cual no incluyó atributos de curvatura. Estos casos se corrieron para la clasificación de facies del Modelo 3 únicamente.

Hasta este punto, la mejor clasificación obtenida para el Modelo 3, fue aquella obtenida en la Prueba 3. En esta clasificación, el Modelo 3 obtuvo un error de 0.092, con una combinación de k_1 (longitud de onda larga), GLCM-contraste, envolvente, y coherencia (Figura 12c). Con el objetivo de realizar una comparación imparcial, la clasificación realizada en el Caso 1 de esta prueba aplicó la misma combinación de atributos, pero con el atributo de curvatura k_1 calculado con longitud de onda corta. Esta combinación indicó un error de 0.113 usando un σ igual a 0.2. En la Figura 14a se observan los resultados obtenidos. Note que el patrón vertical observado en las áreas con facies mal clasificadas ya no es tan fuerte, especialmente en las zonas de fallas, donde fueron considerablemente disminuidos. A pesar de ello, note que después de usar k_1 (longitud de onda corta) en vez de k_1 (longitud de onda larga), el tope del domo salino no está tan bien definido como en las pruebas anteriores.

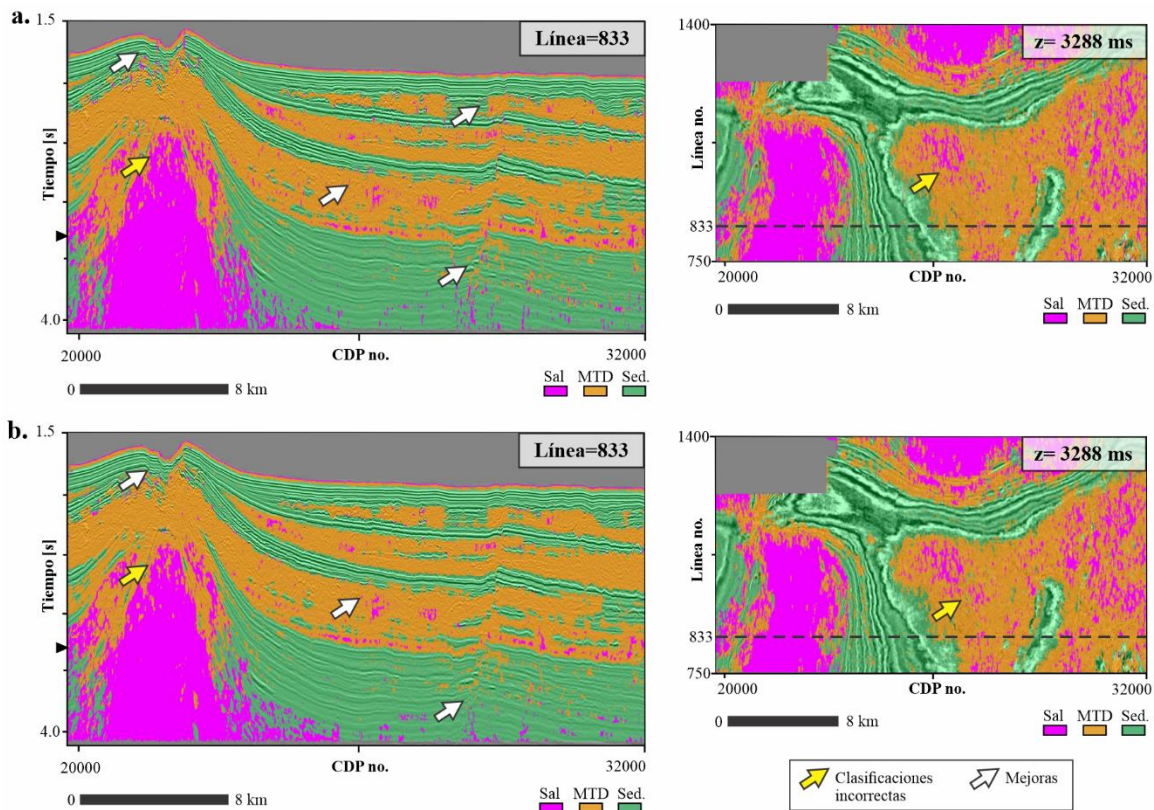
La Figura 14b muestra el segundo caso probado, no incluyendo ninguno de los atributos de curvatura. Para tener una comparación imparcial, la clasificación se realizó excluyendo el atributo k_1 y usando únicamente los atributos de GLCM-contraste, envolvente, y coherencia. De acuerdo con el algoritmo exhaustivo, esta combinación corresponde un error de 0.110 con σ de

0.2. En este caso, los errores de clasificación en las zonas de falla fueron completamente eliminados; sin embargo, nuevamente la definición del tope del domo salino se vió comprometida.

No queriendo sacrificar la definición del tope del dome salino por suprimir los artefactos verticales, se revisó nuevamente las diferentes opciones posibles de abordar esta situación y se decidió realizar otra prueba teniendo en cuenta dichas zonas más complejas.

Figura 14.

Volúmenes de predicción de facies del Modelo 3 en la Prueba 5.



Nota. a, Caso 1, usando k_1 calculado con longitud de onda corta, b. Caso 2, no usando atributos de curvatura. Note que en este Caso 1, se disminuyeron los errores de clasificación de las zonas de fallas, y en el Caso 2, fueron completamente eliminadas. En ambos casos, la definición del tope de los domos salinos se vio comprometida.

10.6. Prueba 6: Zonas geológicamente complejas

En esta prueba se corrieron tres casos diferentes: Caso 1, incluyendo facies de falla (Figura 15a), Caso 2, creando polígonos que envolvieran las zonas de fallas (Figura 15b), y Caso 3, incluyendo facies de zonas fracturadas (Figura 15c).

Para el primer caso, se creó otro modelo clasificando facies de sal, MTD, sedimentos conformes, y fallas. Estas clasificaciones se corrieron usando una ventana de análisis de $123 \text{ ft}^2 \times 393 \text{ ft}^2 \times 0.012 \text{ s}$ y se picaron dos líneas y dos cortes en tiempo como datos de entrenamiento. La clasificación se realizó con un valor σ igual a 0.3 y usando los atributos de k_1 y k_2 (longitud de onda larga), GLCM-desemejanza, envolvente, y coherencia. Esta combinación indicó un error de 0.108. A pesar de presentar un mayor tiempo de cómputo, este caso demostró que después de incluir las facies de fallas se obtuvieron mejores clasificaciones en dichas zonas de fallas. Sin embargo, también se observaron errores de clasificación adicionales dentro de los sedimentos conformes y facies MTD (Figura 15a).

Para el segundo caso, se usaron dos líneas y dos cortes en tiempo para picar nuevamente los polígonos de facies usados para el entrenamiento. Contrario a las pruebas anteriores, esta vez los polígonos de facies de sedimentos conformes se picaron encerrando las zonas de fallas presentes al tope del primer domo salino y en la falla normal observada en el medio del volumen sísmico (izquierda de la Figura 15b). Este caso se corrió con la combinación de atributos de k_1 (longitud de onda larga), GLCM-contraste, envolvente, y coherencia, y un valor σ de 0.2. El error asociado a dicha combinación correspondió a 0.102, y el cual correspondió al mínimo encontrado por el algoritmo exhaustivo. Los resultados de esta clasificación se muestran a lado derecho de la

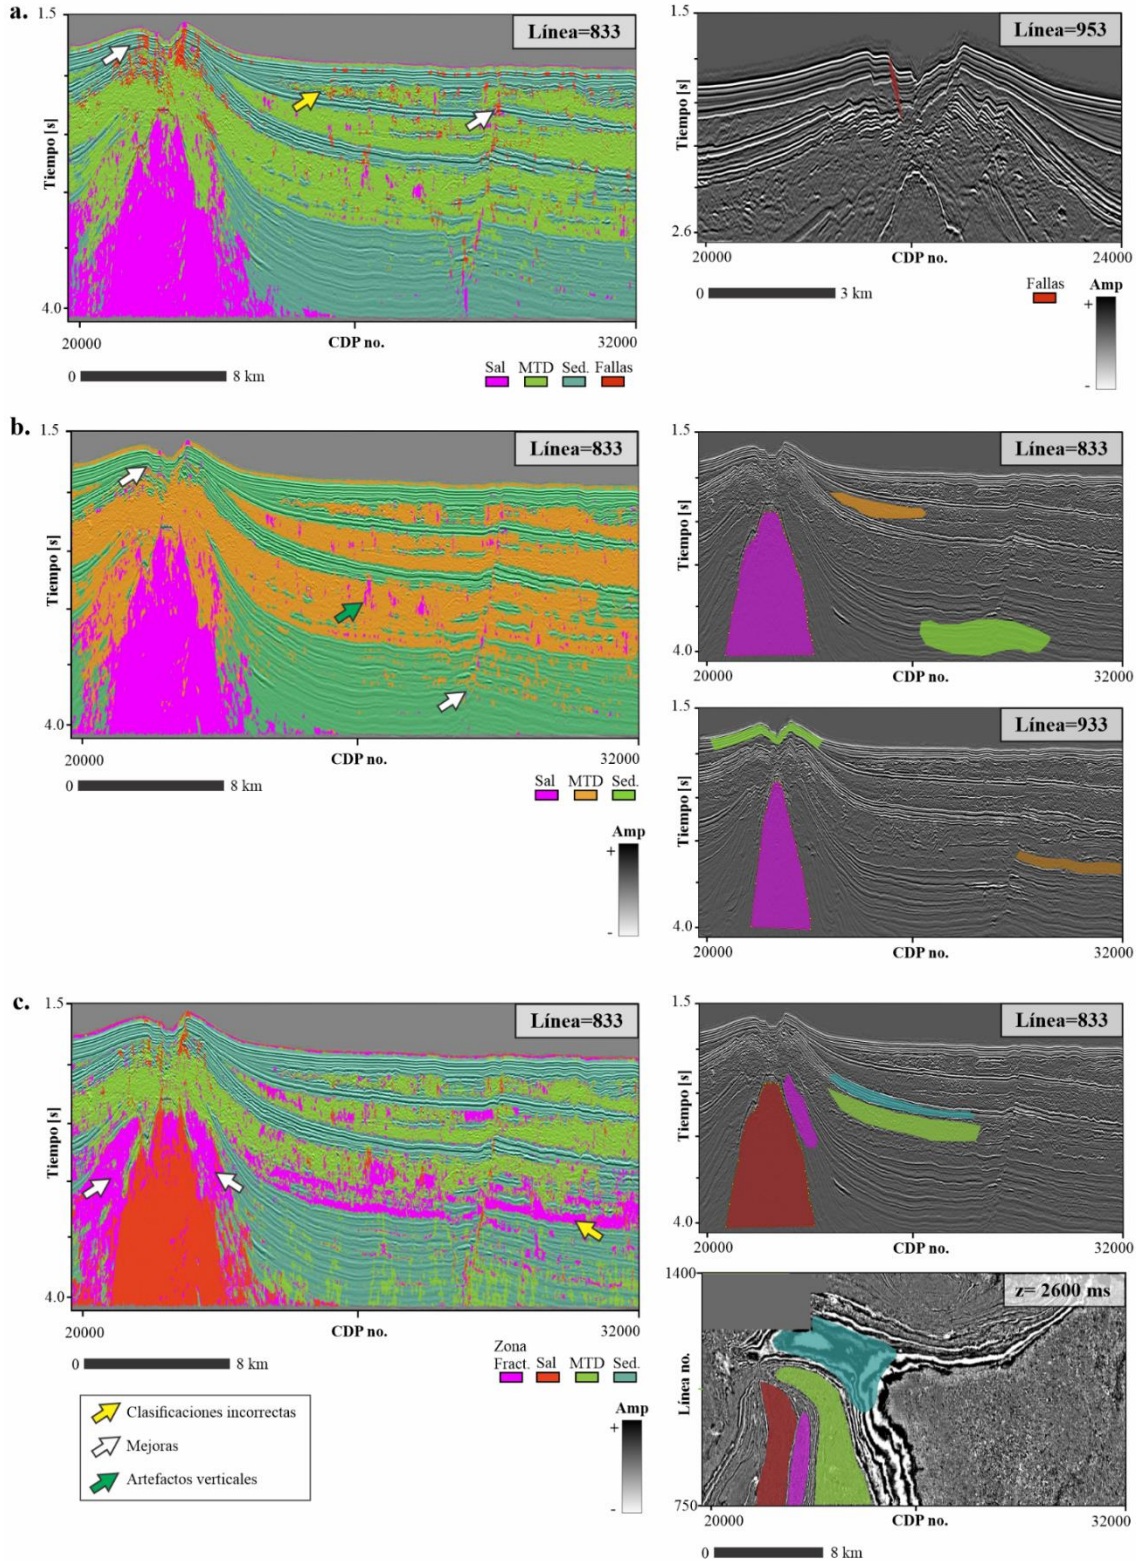
Figura 15b. Este caso eliminó satisfactoriamente las clasificaciones incorrectas encontradas dentro de las zonas de fallas al tope del primer domo salino, y en el medio del volumen.

Para el tercer caso de esta prueba, se clasificaron las facies de sal, MTD, sedimentos conformes, y zonas fracturadas (Figura 15c). La clasificación de este caso se realizó con la combinación de atributos de k_1 , envolvente, y coherencia, y un valor σ de 0.1. Esta combinación corresponde con un error de 0.239, de acuerdo con el algoritmo exhaustivo. A pesar de que los intervalos de MTD de las zonas profundas fueron incorrectamente clasificados como facies de zonas fracturadas, el algoritmo PNN clasificó correctamente las zonas fracturadas cercanas al domo salino (Figura 15c).

De estos tres casos, el Caso 1 y el Caso 3 mostraron los mayores tiempos de cómputo puesto que incluyeron facies adicionales. El Caso 2, por otro lado, tuvo el mismo tiempo de cómputo que en las clasificaciones previas del Modelo 3, pero mostró los mejores resultados (Figura 15b).

Figura 15.

Volúmenes de predicción de facies obtenidos en la Prueba 6.



Nota. Al lado izquierdo están los volúmenes de predicción de facies de la Prueba 6, y a la derecha, están algunos ejemplos de los polígonos de facies de entrenamiento picados para el caso correspondiente al lado izquierdo. a. Caso 1, después de incluir las facies de falla, b. Caso 2, después de picar los polígonos encerrando las zonas de falla, note que los nuevos polígonos de sedimentos conformes encierran las fallas. c, Caso 3, después de incluir las facies de zonas fracturadas que están alrededor del tope de los domos salinos. En el Caso 1 note que a pesar de que las fallas fueron correctamente clasificadas dentro de su facies correspondiente, este caso añadió clasificaciones incorrectas aleatorias de facies de falla dentro de las facies de MTD y sedimentos conformes. En el Caso 2, los errores de clasificación en las zonas de falla fueron exitosamente eliminados, y en el Caso 3, las zonas fracturadas fueron correctamente clasificadas, pero los intervalos profundos de MTD fueron incorrectamente clasificados como dichas facies también.

10.7. Prueba 7: Último análisis en las zonas con clasificaciones incorrectas

Antes de esta prueba, la mejor clasificación obtenida para el Modelo 3 fue la obtenida del segundo caso de la Prueba 6 con la combinación de atributos de k_1 (longitud de onda larga), GLCM-contraste, envolvente, y coherencia. A pesar de que en dicho caso se corrigieron los errores de clasificación en las zonas de fallas, otras zonas con clasificaciones incorrectas entre las facies de sedimentos conformes y MTD permanecieron igual. Dichas zonas se encuentran cerca al área del segundo domo salino, más específicamente, en el tope de este (derecha de la Figura 16a). Para abordar dichos errores, se exploró un atributo de no-parallelismo conocido como desviación del buzamiento, y que fue incluido dentro del primer caso de la Prueba 7.

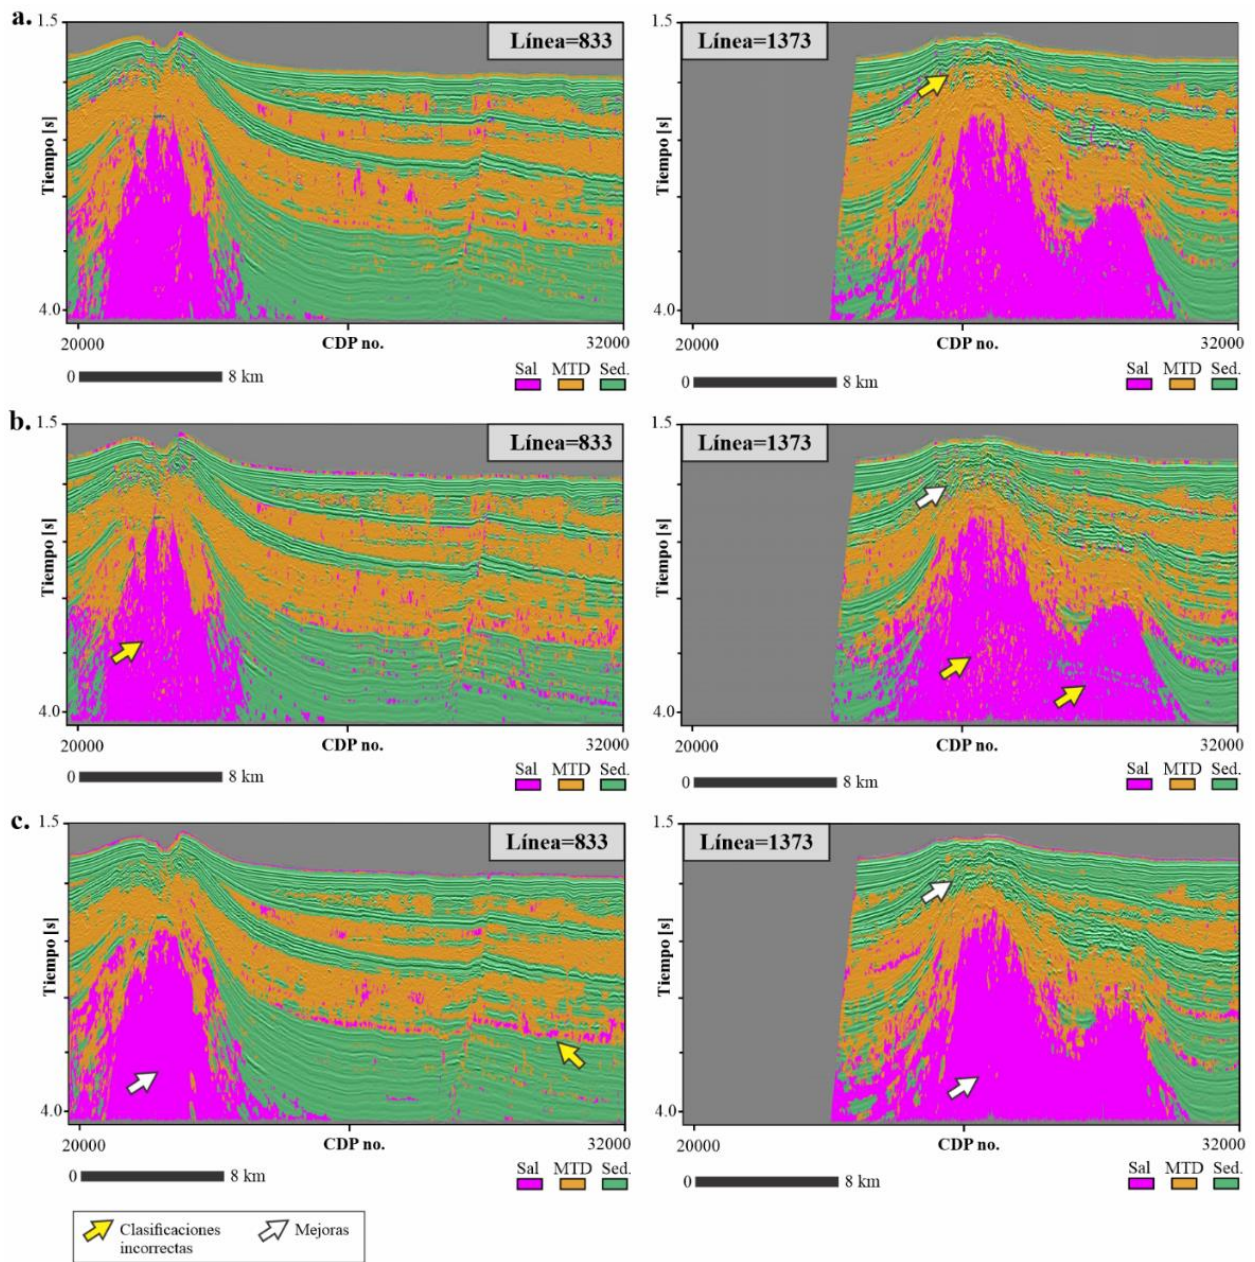
Debido a las similitudes entre el atributo de desviación de buzamiento y el atributo de coherencia, se decidió realizar la clasificación usando la combinación de k_1 (longitud de onda larga), GLCM-contraste, envolvente, y desviación de buzamiento, con el propósito de poder realizar una comparación imparcial. De acuerdo con el algoritmo exhaustivo, esta clasificación

obtuvo el error mínimo de 0.111 con un σ igual a 0.2. El lado derecho de la Figura 16a muestra una sección de segundo domo salino en el volumen de clasificación del segundo caso de la Prueba 6. En dicha sección los sedimentos conformes altamente fracturados al tope del domo salino fueron incorrectamente clasificados como facies de MTD. La Figura 16b muestra los resultados de clasificación después de usar el atributo de desviación de buzamiento en vez del atributo de coherencia. Note que, después de usar el atributo de desviación de buzamiento, todas áreas incorrectamente clasificadas fueron superadas correctamente, y se obtuvieron mejores resultados. Sin embargo, dentro del domo salino se puede observar unos errores de clasificación con patrón conforme, que pueden estar relacionadas con múltiples o artefactos resultantes del cálculo del atributo de desviación de buzamiento (Figura 16a).

Para el segundo caso de esta prueba, se decidió cambiar la manera de entrenar el algoritmo. Esta vez, los polígonos de facies se picaron en el área más compleja del segundo domo salino. Esta clasificación se realizó usando la combinación de atributos de k_2 , envolvente, y coherencia, con un σ igual a 0.2, y un error asociado de 0.103. Las clasificaciones en el área cerca al primer domo salino (izquierda de la Figura 16c) fueron casi idénticas a las obtenidas en el segundo caso de la Prueba 6, mientras que las clasificaciones en las áreas cercanas al segundo domo salino fueron considerablemente mejoradas (derecha de la Figura 16c). Los errores de clasificación entre las facies de MTD y sedimentos conformes, al tope del segundo domo salino fueron correctamente eliminados, y fue posible observar la continuidad de los estratos conformes en dicha área. Además, la mayoría de los artefactos dentro de los domos salinos fueron eliminados en comparación con las pruebas anteriores.

Figura 16.

Volúmenes de predicción de facies obtenidos en la Prueba 7.



Nota. Hacia la izquierda, secciones mostrando las predicciones de facies para el primer domo salino y hacia la derecha, secciones mostrando las predicciones de facies para el segundo domo salino. a. Muestra los resultados del Caso 2 en la Prueba 6 para comparación, b. muestra los resultados del Caso 1 en la Prueba 7 después de reemplazar el atributo de coherencia con el atributo de desviación de buzamiento. Note que los errores de clasificación al tope del segundo domo salino fueron eliminados, sin embargo, este caso añadió errores dentro de los dos domos, c. muestra los resultados del Caso 2 en la Prueba 7 después de entrenar el algoritmo en el área del segundo domo salino. Note que los errores de clasificación al tope del segundo domo salino fueron suprimidos y no se observan artefactos dentro de ninguno de los domos salinos.

11. Discusión

La Tabla 2 muestra que la mayoría de las mejores combinaciones de atributos sísmicos incluyeron: curvatura principal más positiva-k1, envolvente, y coherencia. Estos resultados complementan los descubrimientos de Lubo et al. (2019), donde se encontró que, para la clasificación de facies de sal y sedimentos conformes, la mejor combinación de atributos fue k1 y coherencia. En nuestro estudio, puesto que se incluyeron facies sísmicas adicionales, aparte de las estudiadas por Lubo et al. (2019), es esperable que el algoritmo también requiera la inclusión de atributos sísmicos adicionales para la obtención de resultados óptimos. En nuestro estudio, dicho atributo adicional resultó ser el de envolvente, que contrario a los otros atributos usados, no está relacionado con ninguna propiedad geométrica o textural de la señal sísmica, sino que está relacionado con la energía de esta. La Tabla 2, también indica los mejores valores sigma obtenidos, los cuales variaron entre 0.1 a 0.3. Dichos valores son menores al valor de 1.9 encontrado por Lubo et al. (2019). Esto confirma las declaraciones dadas por Masters (1995) respecto a la matemática detrás del PNN, donde a mayores datos de entrenamiento usados, también se espera que el valor sigma disminuya. En ese sentido, nuestros resultados se pueden correlacionar adecuadamente con ambos estudios.

Cuando se observan los resultados obtenidos en las primeras clasificaciones de la Prueba 1, se puede observar que el algoritmo tuvo limitaciones en la clasificación de las facies de sedimentos conformes de las zonas profundas, las cuales fueron incorrectamente clasificadas como facies de sal y ruido (Figura 10). Esto puede estar relacionado con el efecto de atenuación de amplitud, el cual muestra respuestas de amplitud más bajas en las zonas profundas que en las zonas someras, incluso si están relacionadas a la misma característica geológica. Por ello, si la respuesta de amplitud se ve comprometida, entonces el atributo de envolvente también se verá comprometido, y al hacer parte de todas las mejores combinaciones de atributos usadas en las clasificaciones, estas a su vez serán afectadas. En este escenario, si los sedimentos conformes de las zonas profundas están compuestos por reflectores subparalelos y continuos, pero de baja amplitud, es probable que el algoritmo los confunda con las facies de ruido. Además, si las capas de MTD de las zonas profundas presentan bajas amplitudes, entonces puede que sean incorrectamente clasificadas como facies de sal.

Los resultados obtenidos en la Prueba 2, muestran como el algoritmo PNN pudo vencer el efecto de atenuación de amplitud con la profundidad, y realizar mejores clasificaciones después de incluir el doble de los datos de entrenamiento iniciales. En esta prueba se evidenció como las clasificaciones de las facies de sedimentos conformes de las zonas profundas mejoraron significativamente para los tres modelos (Figura 11). Sin embargo, cuando se utilizó el triple de la cantidad de datos de entrenamiento para la clasificación de facies de sal, MTD, y facies conformes, los resultados fueron casi idénticos a los obtenidos usando el doble de los datos de entrenamiento. Esto puede ser atribuido a un sobrentrenamiento (*overtraining*) del algoritmo. Hampson (2001) obtuvo resultados similares cuando incluyó más atributos sísmicos. En dicho estudio, el error de validación dejó de disminuir en cierto punto, y las clasificaciones empezaron a

sobredecaerse (*overfit*) a los datos. Estos resultados también soportan las declaraciones de autores previos (Masters, 1995; West et al., 2002), en las cuales se indica que la técnica PNN no requiere de grandes cantidades de datos de entrenamiento para obtener resultados acertados con bajo costo computacional. Por esta razón, en las pruebas posteriores a la Prueba 2, se continuó utilizando dos líneas y dos cortes de tiempo, para mejorar las clasificaciones, no sobrentrenar el algoritmo y evitar altos tiempos de cómputo.

Después de usar una ventana de análisis más grande para el cálculo del filtro Kuwahara 3D en los atributos sísmicos, se evidenció una mejoría considerable en la clasificación de facies sísmicas relacionadas a elementos de gran escala. En el caso de elementos de pequeña escala, dicho aumento de la ventana de análisis degradó las clasificaciones especialmente de las facies de canal. Aunque se esperaba una respuesta más fuerte del canal en los atributos sísmicos y, por ende, en los volúmenes de predicción de facies, los resultados mostraron facies de canal siendo mezcladas con otras facies. En cuanto a las facies de ruido, estas mostraron la respuesta más fuerte que se esperaba, pero dicha respuesta se extendió más allá de los reflectores conformes someros (Figura 12a). Después se encontró que Luo et al. (2002) indicó que para este tipo de filtros de suavizado con preservación de bordes (*edge-preserving smoothing filters*) de hecho suprimen elementos geológicos asociados a canales si su anchura es menor que el tamaño de la ventana de análisis del filtro. Igualmente, Fehmers y Höcker (2003) notaron que este tipo de filtros no solo suprime ruido aleatorio, sino que también puede suprimir características estratigráficas y estructurales de pequeña escala. En este sentido, se sugiere seguir la recomendación de Qi et al. (2015) y aplicar grandes ventanas de análisis del filtro Kuwahara 3D solamente cuando se realizan clasificaciones de facies relacionadas a elementos de gran escala, pero no con elementos de pequeña escala.

Cuando se cortó el volumen sísmico en la Prueba 4, las clasificaciones en las zonas someras para los tres modelos exhibieron artefactos verticales con respuestas más fuertes, mientras que el único cambio en la zona profunda fue que lo que se interpretó como zonas fracturadas el algoritmo lo clasificó como facies de MTD en vez de facies de sal como en las pruebas anteriores. Un aspecto importante del Modelo 1 en esta prueba es que el canal y el ruido cercano al lecho marino fueron correctamente clasificados en sus respectivas facies. En otras palabras, el algoritmo mostró respuestas más fuertes tanto para las clasificaciones correctas como para las incorrectas y los artefactos. Una explicación para estos resultados puede ser un posible incremento de la confianza del algoritmo, el cual está calculando probabilidades más altas para las facies predominantes teniendo la misma cantidad de datos, pero un menor volumen a clasificar.

En general, se pudo observar que a pesar de que el canal y el ruido cerca al lecho marino fueron bien clasificados dentro de sus respectivas facies, hubo otras áreas que fueron constantemente mal clasificadas dentro de esas facies también. Dichos errores de clasificación se trataron de corregir a través de diferentes pruebas, sin embargo, los volúmenes de predicción de dichas facies relacionadas a elementos de pequeña escala continuaron mostraron interpretaciones incorrectas sin ninguna mejora. Contrario a esto, los volúmenes de clasificación de facies de gran escala mostraron mejores resultados progresivamente. Estos resultados pueden ser atribuidos a razones geológicas y/o geofísicas. Una razón sería la posible presencia de canales turbidíticos amalgamados; sin embargo, se requiere un análisis complementario con registros de pozo para confirmar o descartar si las facies de canal mal clasificadas de hecho corresponden con sistemas de canales amalgamados correctamente clasificados. Otra razón, podría ser la de facies diferentes con respuestas similares en ciertas zonas de los volúmenes de atributos sísmicos, haciendo más

difícil al algoritmo diferenciar entre ellas. En dicho caso, se debe investigar o explorar otros atributos sísmicos que permitan una mejor diferenciación de dichas facies.

Adicionalmente, en las pruebas anteriores se reconocieron algunos artefactos verticales que fueron clasificados como facies de sal en la mayoría de los volúmenes. En las Pruebas 5 y 6 se trató de suprimir o disminuir la respuesta de dichos artefactos. En cuanto al posible origen de dichos artefactos se consideró que podrían estar relacionados a las siguientes razones: 1) Es bien sabido que para fallas normales se tienen altos valores de curvatura positiva en los bordes de los bloques yacentes (*foot walls*) y altos valores de curvatura negativa en los bordes de los bloques colgantes (*hanging walls*) (Klein et al., 2008). Las respuestas similares entre los bloques yacentes y los domos salinos en el atributo de curvatura k_1 , explica por qué se observan dichos artefactos en las zonas de falla y por qué están siendo clasificados como facies de sal. 2) en el caso de los artefactos verticales observados dentro de las facies de MTD y que son menos obvios en otras facies, se consideró que podrían estar relacionados con el procesamiento. Cuando se revisó el volumen de amplitud se observó que dichos artefactos coinciden con patrones domales similares a los observados en el tope de los domos salino, por ende, implicando altos valores de curvatura positiva en el atributo de k_1 y que da lugar a confusiones con las facies de sal.

En la Prueba 5 se pudo observar que, al cambiar la longitud de onda usada para el cálculo del atributo de curvatura, es posible disminuir el patrón vertical de los artefactos previamente discutidos. El uso de la curvatura de longitud de onda corta ayudó a disminuir la fuerte respuesta de dichos artefactos verticales, mientras que al no usar atributos de curvatura suprimió completamente los artefactos de las zonas de fallas. No obstante, en ambos casos la definición del tope de los domos salinos se vio comprometida. En la Prueba 6, se encontró otro método para suprimir dichos artefactos verticales de las zonas de fallas, pero sin afectar la definición de los

topes de los domos salinos. Estos resultados indican que solo cambiando la manera de picar los polígonos de facies de tal manera que encierren las zonas de falla, se ayuda a eliminar los errores de clasificación en dichas zonas. En la Prueba 7 se obtuvieron resultados similares después de cambiar los polígonos de entrenamiento picados cerca al área del primer domo salino, por polígonos picados en el área del segundo domo salino. Con dicha prueba final, se corrigieron clasificaciones incorrectas en los sedimentos conformes altamente fracturados al tope del segundo domo salino y se obtuvieron respuestas más fuertes dentro de ambos domos (Figura 16c). Estos resultados permiten reconocer la importancia de la definición de los polígonos de facies, puesto que ello puede asegurar resultados de clasificación significativamente mejores.

Finalmente, las otras clasificaciones realizadas en las Pruebas 6 y 7 reiteraron como el procesamiento de los datos tiene un impacto importante en la clasificación de volúmenes. Cuando se clasificaron las facies de sal, sedimentos conformes, MTD, y zonas fracturadas, los intervalos profundos de MTD fueron incorrectamente clasificados como zonas fracturadas, a pesar de que las facies estrictamente relacionadas con las zonas fracturadas fueron correctamente clasificadas (Figura 15c). Esto se relaciona con intervalos de baja amplitud dentro de los MTD de las zonas profundas. Por otro lado, el uso del atributo de desviación de buzamiento ayudó a corregir los errores de clasificación en las facies de sedimentos conformes al tope del segundo domo salino (Figura 16b). Sin embargo, en dicho caso también se observaron artefactos conformes dentro de los domos salinos, probablemente debido a múltiples con patrón conforme. En este escenario, no se puede generalizar y decir que el atributo de desviación de buzamiento puede no funcionar y debe ser descartado para futuras clasificaciones. Si existen artefactos conformes o múltiples, se espera que este atributo falle en dichas zonas, ya que está directamente relacionado con el paralelismo de los reflectores.

La Tabla 3 resume el impacto cualitativo de cada parámetro modificado en la clasificación de facies sísmicas realizada en cada prueba. La Figura 17 muestra la evolución progresiva del Modelo 3 e ilustra claramente la importancia de incluir el criterio geocientífico para obtener mejores resultados. Por último, en la Figura 18 se compilan todas las lecciones aprendidas y se propone un nuevo flujo de trabajo que sirve de guía para futuros interpretes interesados en aplicar PNN para la clasificación de facies sísmicas. El criterio del geocientífico es muy importante puesto que permite inferir donde va a ser más difícil para el algoritmo clasificar correctamente. En este sentido, el paso más importante incluido en este nuevo flujo de trabajo es reconocer las áreas más geológicamente complejas y después picar los polígonos de facies de entrenamiento teniéndolas en cuenta. Incorporar dicho conocimiento y perspectiva del interprete ayudará al algoritmo a generar resultados más acertados y confiables desde el principio.

Tabla 3.

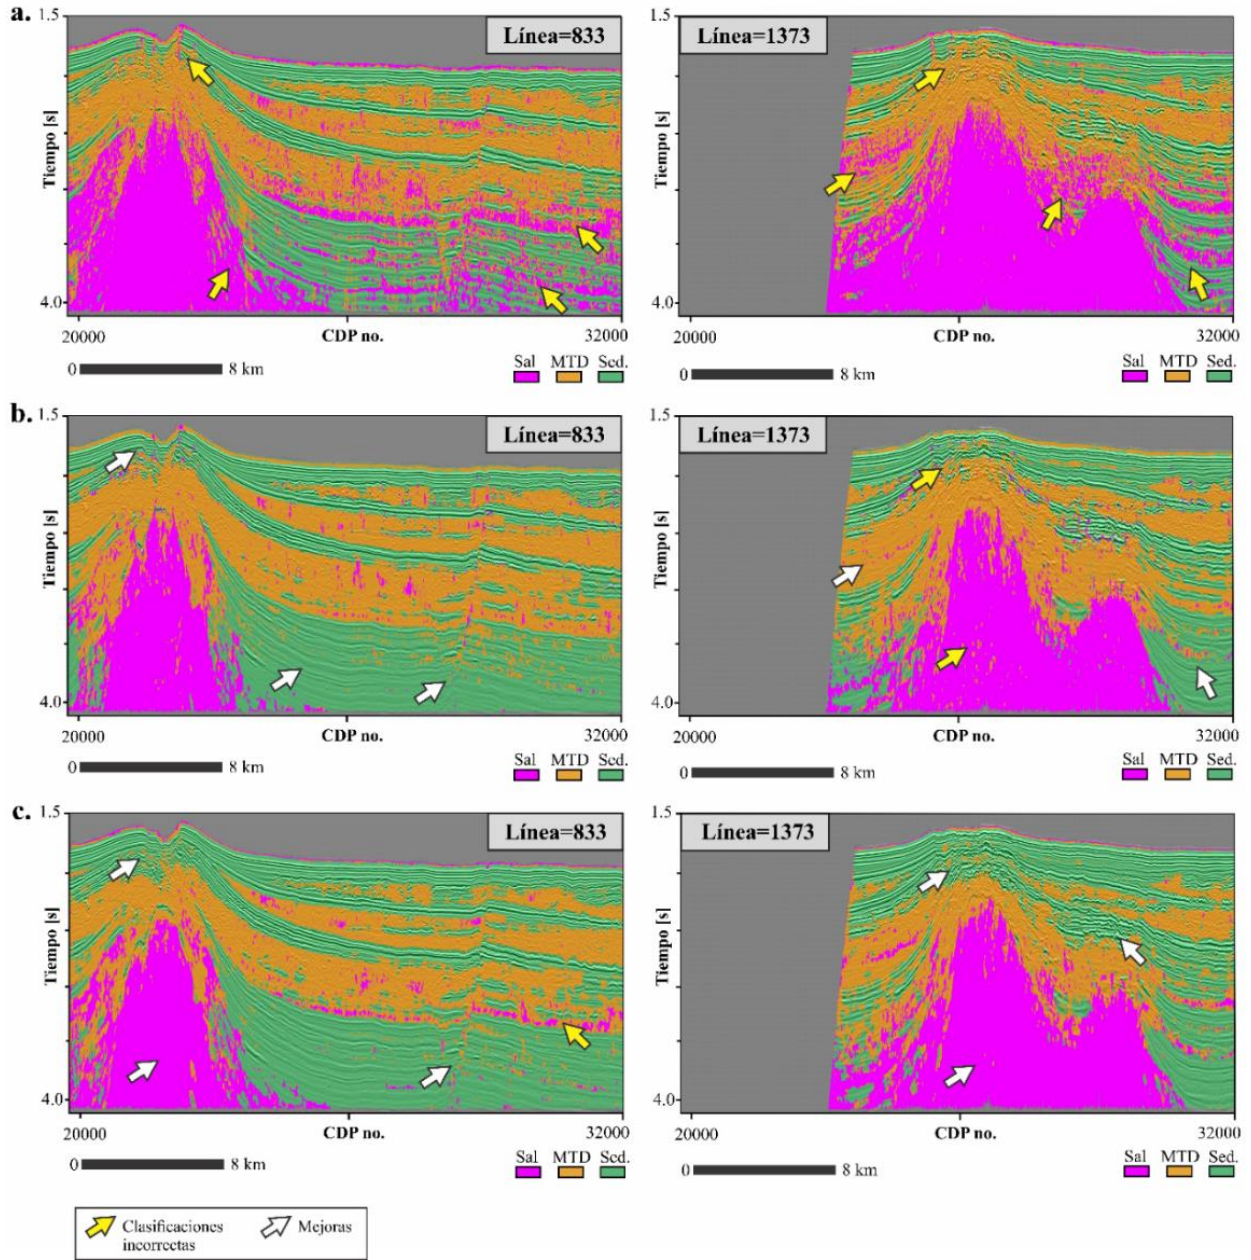
Impacto cualitativo de cada parámetro modificado en los volúmenes de predicción de facies obtenidos en cada caso.

Prueba	Parametro modificado	Caso	Modificación específica	Impacto	Comentario
Prueba 2.	Datos de entrenamiento	Caso 1	Aumento de la cantidad de datos de entrenamiento (2 líneas y 2 cortes en tiempo)	Muy positivo	Ayudó a eliminar clasificaciones incorrectas relacionadas con el efecto de atenuación de energía en las zonas más profundas del volumen sísmico
		Caso 2	Aumento de la cantidad de datos de entrenamiento (3 líneas y 3 cortes en tiempo)	Negativo	Ninguna mejora adicional pero sí un mayor costo computacional
Prueba 3.	Ventana de análisis	-	Aumento del tamaño de la ventana de análisis del filtro	Positivo y negativo	Positivo para las características de gran escala, negativo para las características de pequeña escala
Prueba 4.	Volumen cortado	Zona somera	Volumen cortado a una zona somera	Negativo	Incrementó la densidad de artefactos verticales en el volumen
		Zona profunda	Volumen cortado a una zona profunda	Neutral	Ninguna diferencia considerable en comparación con las clasificaciones previas
Prueba 5.	Atributos sísmicos seleccionados	Caso 1	Atributos de curvatura calculados con longitud de onda corta	Relativamente positivo	Disminuyó la respuesta vertical de los artefactos, pero comprometió la definición del tope de los domos salinos
		Caso 2	No atributos de curvatura	Relativamente positivo	Suprimió los artefactos verticales en las zonas de fallas, pero comprometió la definición del tope de los domos salinos
Prueba 6.	Facies sísmicas incluidas	Caso 1	Incluyendo facies de falla	Negativo	Clasificó más allá de los planos de falla, añadió clasificaciones incorrectas aleatoriamente e incrementó el costo computacional
	Datos de entrenamiento	Caso 2	Picando los polígonos de entrenamiento encerrando las zonas de falla	Muy positivo	Suprimió las clasificaciones incorrectas en las zonas de falla y no incrementó el costo computacional
	Facies sísmicas incluidas	Caso 3	Incluyendo facies de zonas fracturadas	Relativamente positivo	Clasificó correctamente las áreas altamente fracturadas cercanas al tope de los domos salinos pero aumento las clasificaciones incorrectas de la facies MTD en otras zonas
Prueba 7.	Atributos sísmicos seleccionados	Caso 1	Incluyendo el atributo de desviación de buzamiento	Relativamente negativo*	Suprimió las clasificaciones incorrectas de las facies de sedimentos conformes al tope del segundo domo salino. Añadió artefactos conformes dentro de los domos salinos
	Datos de entrenamiento	Caso 2	Picando los polígonos de entrenamiento en las zonas más geologicamente complejas cercanas al domo salino #2	Positivo	Disminuyó considerablemente las clasificaciones incorrectas de los sedimentos conformes altamente fallados al tope del segundo domo salino

Nota. En el caso del atributo de desviación de buzamiento, el impacto negativo no puede generalizarse puesto que los artefactos conformes observados están relacionados con el procesamiento sísmico.

Figura 17.

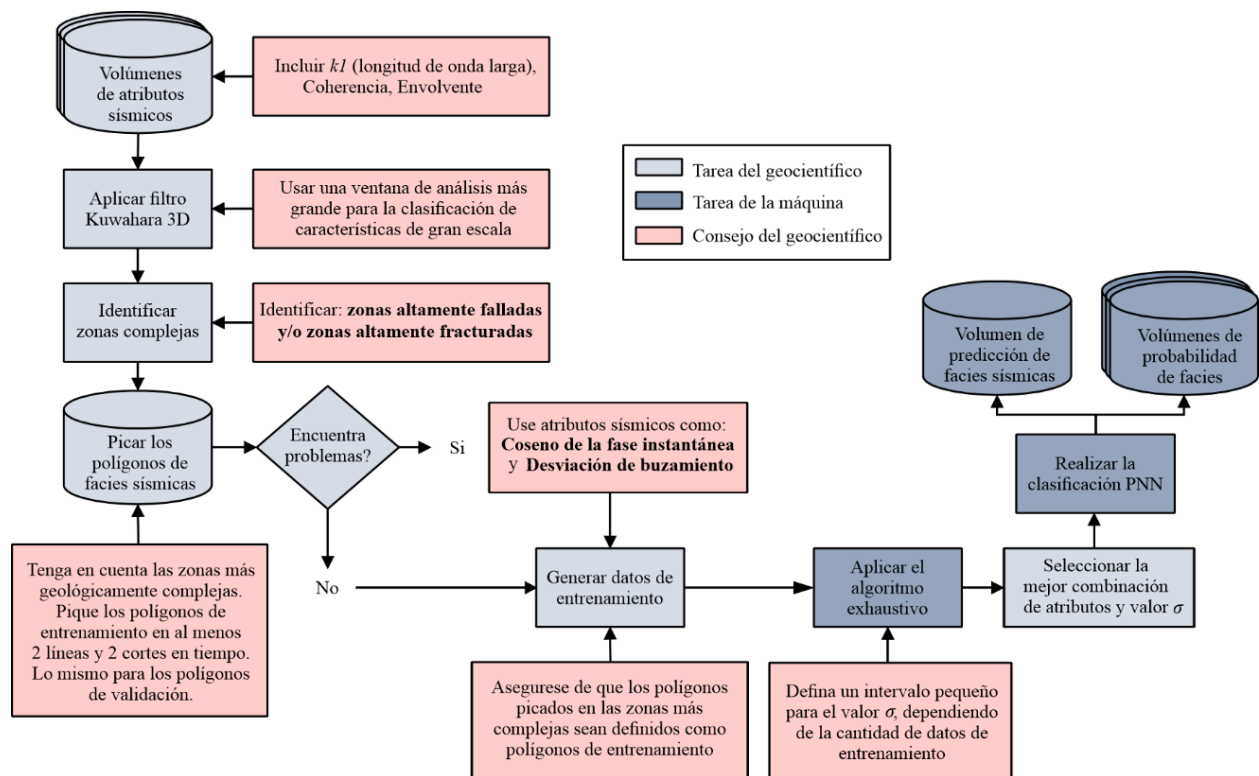
Evolución de las clasificaciones de facies del Modelo 3.



Nota. Note la mejoría progresiva después de incluir el criterio geocientífico para cambiar los parámetros iniciales. Note la mejoría progresiva después de incluir el criterio geocientífico para cambiar los parámetros iniciales. Hacia la izquierda están las secciones mostrando el área del primer domo salino, y hacia la izquierda están las secciones del segundo domo salino. a. Resultados del Modelo 3 en la Prueba 1, note los errores de clasificación en las zonas de falla y en las zonas profundas, b. Resultados del Modelo 3 en la Prueba 6 después de incluir los nuevos polígonos encerrando las áreas de fallas. En esta clasificación, también se usó el doble de la cantidad de datos de entrenamiento. Note que las clasificaciones en las zonas de fallas y en la zona profunda fueron corregidas, c. Resultados del Caso 2 en la Prueba 7, después de picar los polígonos de facies en las áreas más complejas del segundo domo salino. Note la corrección de los sedimentos conformes al tope del segundo domo salino.

Figura 18.

Propuesta de flujo de trabajo final.



Nota. Se incluyen las lecciones aprendidas y las sugerencias para obtener mejores resultados cuando se utiliza la técnica PNN para clasificación de facies sísmicas.

12. Conclusiones

La técnica PNN demostró ser una técnica supervisada de aprendizaje automatizado óptima para la clasificación de facies sísmicas, mostrando resultados remarcables y acertados en la clasificación de elementos de gran escala, y prometedores pero limitados resultados en la clasificación de elementos de pequeña escala. El algoritmo exhaustivo mostró que, para futuras clasificaciones de las facies sísmicas evaluadas en este estudio, es importante incluir los atributos de curvatura principal más positiva- k_1 , envolvente, y coherencia, ya que estos atributos constantemente estuvieron entre las mejores combinaciones calculadas por el algoritmo. Igualmente, el algoritmo exhaustivo demostró que, para grandes cantidades de datos, no es necesario considerar grandes intervalos para el valor σ , puesto que se evidenció que todas las mejores combinaciones se hicieron con valores entre 0.1 y 0.3.

En este estudio, se resaltó la importancia de incluir el criterio geológico para obtener resultados progresivamente mejores. Esto se realizó, primero mediante el entendimiento de los orígenes de las áreas con errores de clasificación, y segundo, ayudando al algoritmo a superar dichos errores mediante la modificación de parámetros iniciales. El efecto de atenuación de amplitud fue corregido mediante la adición de más datos de entrenamiento, mientras que los artefactos verticales fueron disminuidos mediante el cambio en el método de cálculo del atributo de curvatura. Finalmente, los errores de clasificación en las zonas de fallas y en los sedimentos conformes altamente fallados se corrigieron cambiando la manera de picar los polígonos de facies usados para el entrenamiento. Es importante recalcar que todas esas tareas son controladas y alteradas por el geocientífico y no por el algoritmo.

Adicionalmente, se mostró como los artefactos producto del procesamiento sísmico pueden impactar grandemente los volúmenes de clasificación finales. La atenuación de energía puede hacer que los sedimentos conformes tengan respuestas similares a aquellas relacionadas con el ruido presente cerca al lecho marino, así como también puede hacer que los MTD tengan respuestas similares a las de facies de sal. Los artefactos verticales observados en las zonas de fallas y dentro de los MTD tiene respuestas similares a aquellas observadas en los domos salinos, y, por ende, dando lugar a su incorrecta clasificación dentro de las facies de sal. También se observó que los artefactos con patrón conforme pueden influenciar en los atributos que miden el paralelismo de los reflectores, como el atributo de desviación de buzamiento, y así causar errores en los volúmenes de clasificación. El intérprete puede ayudar al algoritmo cambiando los atributos preseleccionados o alterando las maneras de calcularlos. Sin embargo, si dichos artefactos persisten, se debe entender como limitaciones heredadas que el intérprete puede entender, pero el algoritmo no puede vencer. En ese sentido, sería innecesario seguir tratando de obtener mejores resultados hasta que se tenga un volumen sísmico mejor procesado.

A manera de conclusión, se propuso un nuevo flujo de trabajo que incorpora las mejores prácticas aprendidas y que deben aplicarse cuando se utiliza la técnica PNN para clasificación de facies sísmicas. Si bien, la selección de atributos es crucial, se demostró que la generación de los polígonos de facies usados para el entrenamiento es igual de esencial. Por esta razón, se considera que el paso más importante incluido en el nuevo flujo de trabajo es el de usar el criterio del geocientífico para reconocer las áreas más geológicamente complejas y crear los polígonos de entrenamiento dentro de dichas áreas. Un análisis complementario a los resultados aquí obtenidos será el de incluir datos de registros de pozos para validar las interpretaciones de facies,

especialmente aquellas relacionadas con las facies de canal. Además, se sugiere realizar la extracción de geocuerpos para entender mejor la distribución espacial de cada una de las facies.

Referencias Bibliográficas

- Al Dossary, S. y Marfurt, K. (2006). 3D volumetric multispectral estimates of reflector curvature and rotation. *Geophysics*, 71 (5), 41–51. <https://doi.org/10.1190/1.2242449>
- Barnes, A. and Laughlin, K. (2002). Investigation of methods for unsupervised classification of seismic data. *SEG Annual Meeting*, 72, 2221–2224. <https://doi.org/10.1190/1.1817152>
- Chopra, S. y Marfurt, K. (2007a). Seismic attributes for prospect identification and reservoir characterization. *SEG Geophysical Developments Series*, 11. <https://doi.org/10.1190/1.9781560801900>
- Chopra, S. y Marfurt, K. (2007b). Curvature attribute applications to 3D surface seismic data. *The Leading Edge*, 26, 404–414. <https://doi.org/10.1190/1.2723201>
- Chopra, S. and Marfurt, K. 2011. Interesting pursuits in seismic curvature attribute analysis. *CSEG Recorder*, 36 (4), 40–50.
- Chopra, S. y Marfurt, K. (2018). Seismic facies classification using some unsupervised machine learning methods. *SEG Annual Meeting*, 88, 2056–2060. <https://doi.org/10.1190/segam2018-2997356.10>
- Coléou, T., Poupon, M. y Azbel, K. (2003). Unsupervised seismic facies classification: A review and comparison of techniques and implementation. *The Leading Edge*, 22(10), 942–953. <https://doi.org/10.1190/1.1623635>
- Deriche, M. (2016). Robust salt-dome detection using the ranking of texture-base attributes. *Applied Geophysics*, 13 (3), 449–458. <https://doi.org/10.1007/s11770-016-0569-6>
- Di, H., Li, Z., Maniar, H. and Abubakar, A. (2019). Seismic stratigraphy interpretation via deep convolutional neural networks. *SEG Annual Meeting*, 89, 2358–2362. <https://doi.org/10.1190/segam2019-3214745.1>

- Donovan, A., Casey, M., Sanabria, D., Willis, D. y Stauber, D. (2003). Composite Sequences, Seismic Facies, and Reservoir Distributions in the Dianna Hoover Basin: Gulf of Mexico. *AAPG, Annual Convention*.
- Fehmers, G. y Höcker, C. (2003). Fast structural interpretation with structure-oriented filtering. *Geophysics*, 68 (4), 1286–1293. <https://doi.org/10.1190/1.1598121>
- Galloway, W. (2008). Depositional Evolution of the Gulf of Mexico Sedimentary Basin. *Sedimentary Basins of the World*, 5, 505–549. [https://doi.org/10.1016/S1874-5997\(08\)00015-4](https://doi.org/10.1016/S1874-5997(08)00015-4)
- Gao, D. (2003). Volume texture extraction for 3D seismic visualization and interpretation. *Geophysics*, 68(4), 1294–1302. <https://doi.org/10.1190/1.1598122>
- Hampson, D., Shuelke, J. y Quirein, J. (2001). Use of multiattribute transforms to predict log properties from seismic data. *Geophysics*, 66 (1), 220–236. <https://doi.org/10.1190/1.1444899>
- Kim, Y., Hardisty, R. y Marfurt, K. (2019). Multivariate attribute selection in seismic facies classification. *SEG Annual Meeting*, 89, 2258–2262. <https://doi.org/10.1190/segam2019-3216101.1>
- Klein, P., Richard, L y James, H. (2008). 3D curvature attributes: a new approach for seismic interpretation. *First Break*, 26 (4), 105–111. <https://doi.org/10.3997/1365-2397.26.1118.27953>
- La Marca-Molina K., Silver, C., Bedle, H. y Slatt, R. M. (2019). Seismic facies identification in a deepwater channel complex applying seismic attributes and unsupervised machine learning techniques. A case study in the Taranaki Basin, New Zealand. *SEG Annual Meeting*, 89, 2059–2063., <https://doi.org/10.1190/segam2019-3216705.1>
- Liu, M., Li, W., Jarvis, M. y Nivlet, P. (2019). 3D Seismic Facies Classification using Convolutional Neural Network and Semi-supervised Generative Adversarial Network. *SEG Annual Meeting*, 89, 4995–4999. <https://doi.org/10.1190/segam2019-3216797.1>

- Lubo, D., Ha T., Lakshmivarahan S. y Marfurt K. (2019). Supervised seismic facies classification using Probabilistic Neural Networks: Which attributes should the interpreter use?. *SEG Annual Meeting*, 89, 2273–2277. <https://doi.org/10.1190/segam2019-3216841.1>
- Luo, Y., Marhoon, M., Al Dossary, S. y Alfaraj, M. (2002). Edge-preserving smoothing and applications. *The Leading Edge*, 21(2), 136–158. <https://doi.org/10.1190/1.1452603>
- Masters, T. (1995). *Advanced Algorithms for Neural Networks: a C++ Sourcebook*. Jhon Wiley & Sons, Inc.
- Mercado-Herrera, V., Russell, B. y Flores, A. (2006). Neural networks in reservoir characterization. *The Leading Edge*, 25(4), 402–411. <https://doi.org/10.1190/1.2193208>
- Miller, P., Dasgupta, S. and Shelander, D. (2012). Seismic Imaging of migration pathways by advanced attribute analysis, Alaminos Canyon 21, Gulf of Mexico. *Marine and Petroleum Geology*, 34(1), 111–118. <https://doi.org/10.1016/j.marpetgeo.2011.09.005>
- Nixon, L., Kazanis, E. y Alonso, S. (2014). Deepwater Gulf of Mexico. *U.S Department of the Interior. Bureau of Ocean Energy Management. Gulf of Mexico OCS Region*.
- Posamentier, H. W. y Kolla, V. (2003). Seismic geomorphology and stratigraphy of depositional elements in deep-water settings. *Journal of Sedimentary Research*, 73(3), 367–38. <http://dx.doi.org/10.1306/111302730367>
- Posamentier, H. W. y Martinsen, O. J. (2011). The character and genesis of submarine mass-transport deposits: insights from outcrop and 3D seismic data. *Mass-Transport Deposits in Deepwater Settings SEPM Special Publication*, 95, 7–38. <https://doi.org/10.2110/sepmsp.096.007>
- Qi, J. y Marfurt, K. (2015). Segmentation of salt domes, mass transport complexes on 3D seismic data volumes using Kuwahara windows and multiattribute cluster analysis. *SEG Annual Meeting*, 85, 1821–1825. <https://doi.org/10.1190/segam2015-5876831.1>

- Qi, J. y Marfurt, K., (2019). Nonparallelism attributes and data adaptive Kuwahara image processing. *SEG Annual Meeting*, 89, 1858–1862. <https://doi.org/10.1190/segam2019-3216022.1>
- Qi, J. Lin, T., Zhao, T., Li, F. y Marfurt, K. (2016). Semisupervised multiattribute seismic facies analysis. *Interpretation*, 4(1), SB91–SB106. <https://doi.org/10.1190/INT-2015-0098.1>
- Roy, A., Dowdell, B. y Marfurt, K. (2013). Characterizing a Mississippian tripolitic chert reservoir using 3D unsupervised and supervised multiattribute seismic facies analysis: An example from Osage County, Oklahoma. *Interpretation*, 1 (2), SB109–SB124. <https://doi.org/10.1190/INT-2013-0023.1>
- Sarkar, S., Marfurt, K., Ferrero, B. y Slatt, R. (2008). Attribute Expression of Mass Transport Deposits in an Intraslope Basin-A Case Study. *SEG Annual Meeting*, 78, 958–962. <https://doi.org/10.1190/1.3063797>
- Specht, D.F. (1988). Probabilistic Neural Networks for classification mapping, or associative memory. *Proceedings, IEEE International Conference on Neural Networks*, 1, 525–532. 10.1109/ICNN.1988.23887
- Specht, D. F. (1990). Probabilistic neural networks. *Neural Networks*, 3, 109–118. [https://doi.org/10.1016/0893-6080\(90\)90049-Q](https://doi.org/10.1016/0893-6080(90)90049-Q).
- Subrahmanyam, D. y Rao, P. (2008). Seismic Attributes-A Review. *7th International Conference & Exposition on Petroleum Geophysics*.
- Sullivan, M., Jensen, G., Goulding, F., Jennette, D., Foreman, L., Stern, D. (2000). Architectural Analysis of Deep-Water Outcrops: Implications for Exploration and Development of the Diana Sub-Basin, Western Gulf of Mexico. *Deep-Water Reservoirs of the World SEPM Special Publication*, 20, 1010–1031. <https://doi.org/10.5724/gcs.00.15.1010>
- Taner, M., Koehler, F. y Sheriff, R. (1979). Complex seismic trace analysis. *Geophysics*, 44 (6), 1041–1063. <https://doi.org/10.1190/1.1440994>

- Verma, S., Roy, A., Perez, R. y Marfurt, K. (2012). Mapping high fractability and high TOC zones in the Barnett Shale: Supervised Probabilistic Neural Network vs. unsupervised multi-attribute Kohonen SOM. *SEG Annual Meeting*, 82, 1–5. <https://doi.org/10.1190/segam2012-1494.1>
- Waldeland, A., Jensen, A.C., Gelius, L.J. y Schistad-Solberg, A.H. (2018). Convolutional neural networks for automated seismic interpretation. *The Leading Edge*, 37(7), 1938-3789. <https://doi.org/10.1190/tle37070529.1>
- Weimer, P. y Slatt, R. (2006). Petroleum geology of deepwater settings. *AAPG Studies in Geology*, 57 (8).
- West, B., May, S., Eastwood, J. y Rossen, C. (2002). Interactive seismic facies classification using textural attributes and neural networks. *The Leading Edge*, 21(10), 1042–1049. <https://doi.org/10.1190/1.1518444>
- Wrona, T., Pan. I., Gawthorpe, R. y Fossen, H. (2018). Seismic facies analysis using machine learning. *Geophysics*, 83(5), O83-O95. <https://doi.org/10.1190/geo2017-0595.1>
- Zhao, T., Verma, S., Qi, J. y Marfurt, K. (2015a). Supervised and unsupervised learning: how machines can assist quantitative seismic interpretation. *SEG Annual Meeting*, 85, 1734–1738. <http://dx.doi.org/10.1190/segam2015-5924540.1>
- Zhao, T., Jayaram, V., Roy, A. y Marfurt, K. (2015b). A comparison of classification techniques for seismic facies recognition. *Interpretation*, 3(4), SAE29–SAE58. <http://dx.doi.org/10.1190/INT-2015-0044.1>
- Zhao, T., Li, F. y Marfurt, K. (2018). Seismic attribute selection for unsupervised seismic facies analysis using user-guided data-adaptive weights. *Geophysics*, 83(2), O31–O44. <https://doi.org/10.1190/geo2017-0192.1>