



UNIVERSIDAD NACIONAL DE COLOMBIA

Modelo Multimodal para Pronóstico de Producción de Pozos Petroleros

David Esneyder Bello Angulo

Universidad Nacional de Colombia
Facultad de Ingeniería, Departamento de Ingeniería de Sistemas e Industrial
Bogotá D.C., Colombia
2024

Modelo Multimodal para Pronóstico de Producción de Pozos Petroleros

David Esneyder Bello Angulo

Tesis presentada como requisito parcial para optar al título de:
Magister en Ingeniería de Sistemas y Computación

Director(a):
Ph.D., Elizabeth León Guzmán

Línea de Investigación:
Minería de Datos - Clasificación y Pronóstico de Series de Tiempo Multimodales
Grupo de Investigación:
Grupo de Investigación en Minería de Datos MIDAS

Universidad Nacional de Colombia
Facultad de Ingeniería, Departamento de Ingeniería de Sistemas e Industrial
Bogotá D.C., Colombia

2024

Dedicatoria

A mi madre, a mi hermanita, a toda mi familia,
a mi prometida y a mis amigos por su amor y
por creer en mi más que yo mismo.

El que no ama, no ha conocido a Dios; porque
Dios es amor (1 Jn 4:8)

Agradecimientos

El presente trabajo fue posible gracias al apoyo moral e intelectual de muchas personas.

Deseo agradecer especialmente a la profesora Elizabeth León por su dirección y apoyo constante en el desarrollo de las actividades asociadas con esta investigación, por su visión sin la cual este trabajo no habría llegado a buen término, y por su liderazgo promoviendo espacios de intercambio de conocimiento enfocado en nuevas tecnologías, lo cual ha sido de gran importancia para este trabajo y para mi crecimiento intelectual y profesional.

Al profesor Jonatan Gómez por tener la disposición de ayudar y contribuir con su conocimiento para el desarrollo de esta tesis, y por su aporte en mi desarrollo personal e intelectual enseñándome no solo conceptos teóricos y su aplicación en problemas de ingeniería, sino también sus implicaciones en lo que llamamos realidad con evidencias de que la complejidad emerge de reglas simples.

Al profesor Erik Montes por ofrecer su apoyo en la búsqueda de soluciones para cualquier problema técnico que se presentara.

Al ingeniero Sergio Viveros y a todo el equipo de la Unión Temporal IJP por proveer los datos utilizados en esta investigación.

A los integrantes del grupo de investigación MIDAS por sus aportes y sugerencias en cada presentación y discusión de dudas relacionadas con la ejecución de este proyecto.

Resumen

El presente trabajo de investigación presenta un aporte en dos áreas de estudio de series de tiempo en el contexto de la producción de pozos petroleros, siendo estas la clasificación para identificar fallas en los pozos, y los pronósticos de producción. El conjunto de datos utilizado corresponde a la producción de pozos petroleros, incluyendo información multimodal como datos numéricos, imágenes y texto para cada punto temporal. En la clasificación de series de tiempo, se aborda la predicción de fallas en el siguiente paso temporal, logrando una exactitud del 61.3 % con un modelo multimodal conectado a una capa LSTM. En pronósticos de series de tiempo, los modelos multimodales con capas LSTM destacan, superando a modelos no multimodales y a implementaciones ARIMA en predicciones trimestrales y bi-anuales, presentando un error porcentual absoluto medio de 8 % llegando a 2 % en casos específicos. Este trabajo contribuye significativamente a los campos de clasificación y predicción de series de tiempo multimodales, proponiendo una arquitectura de *encoder* multimodal distribuido en el tiempo que puede ser implementada para series de tiempo multimodales de cualquier área de la industria.

Palabras clave: Clasificación de series de tiempo, Pronósticos de series de tiempo, Multimodal, Redes neuronales, Aprendizaje automático, Aprendizaje profundo.

Abstract

Multi-Modal Model for Production Forecasting in Oil Wells

This research presents a contribution to two areas of time series study, in the context of oil well production, these are the classification to identify possible failures and the production forecasting. The dataset utilized corresponds to the production of oil wells, consisting in multimodal information such as numerical data, images, and text for each temporal point. In time series classification, the prediction of failures in the subsequent time step is addressed, achieving an accuracy of 61.3% with a multimodal model connected to an LSTM layer. In time series forecasting, multimodal models with LSTM layers excel, outperforming non-multimodal models and ARIMA implementations in quarterly and bi-annual predictions, presenting a mean absolute percentage error of 8%, reaching 2% in specific cases. This work significantly contributes to the fields of multimodal time series classification and prediction, proposing a temporally distributed multimodal *encoder* architecture that can be implemented for multimodal time series across various industry domains.

Key words: Timeseries classification, Timeseries forecasting, Multimodal, Neural networks, Machine learning, Deep learning.

Esta tesis de maestría se sustentó el 12 de abril de 2024 a las 10:00 a.m., y fue evaluada por los siguientes jurados:

Jorge Eliecer Camargo Mendoza (Phd.)
Profesor Asociado
Universidad Nacional de Colombia

Luis Fernando Niño Vasquez (Phd.)
Profesor Titular
Universidad Nacional de Colombia

Contenido

Agradecimientos	vii
Resumen	ix
1 Introducción	2
1.1 Objetivos	3
1.2 Metodología	4
1.3 Contribuciones	5
1.3.1 Contribuciones técnicas y conjuntos de datos	5
1.3.2 Publicaciones	6
1.4 Distribución del documento	6
2 Estado del arte	8
2.1 Modelos de aprendizaje para series de tiempo	8
2.1.1 Modelos de clasificación de series de tiempo	9
2.1.2 Modelos de pronósticos de series de tiempo	10
2.2 Modelos de aprendizaje multimodal	11
2.3 Modelos de predicción de series de tiempo de información petrolera	13
2.3.1 Modelos para Predecir la Producción de Hidrocarburos	16
2.3.2 Predicción de Fallas en los Pozos Petroleros	21
2.3.3 Preprocesamiento de Datos de Pozos Petroleros	21
3 Preprocesamiento: Extracción y transformación de datos	24
3.1 Fuentes de información	25
3.1.1 Libro de pruebas	25
3.1.2 Historial de servicios a pozo	28
3.1.3 Datos numéricos de la aplicación TWM	29
3.1.4 Datos binarios de la aplicación TWM: Imágenes del comportamiento del sistema	32

3.2	Extracción de la información	34
3.2.1	Extracción de la información numérica	34
3.2.2	Extracción de las imágenes del comportamiento del sistema	37
3.3	Transformación y consolidación de la información	38
3.3.1	Etiquetado del historial de servicios a pozo: Clasificación de fallas a partir de texto en lenguaje natural	40
3.3.2	Selección inicial de variables del libro de pruebas y datos numéricos de TWM	43
3.3.3	Consolidación de información numérica en series de tiempo	50
3.3.4	Imputación de datos nulos en variables numéricas	52
3.3.5	Primera estructuración de ejemplos para clasificación de series de tiempo con todas las fuentes de datos independientes	52
3.3.6	Reducción de dimensionalidad y normalización	53
3.3.7	Elaboración del conjunto de datos final	55
3.3.8	Construcción de ejemplos con ventanas de tiempo para entrenamiento de redes neuronales	58
3.4	Estrategia de fusión de datos multimodales	61
3.5	Discusión de resultados	61
4	Modelo de predicción de fallas mediante clasificación de series de tiempo multimodales	65
4.1	Arquitectura de encoder propuesta para procesar los datos secuenciales multimodales	65
4.2	Modelos de clasificación sobre datos balanceados	67
4.2.1	Mododelo multimodal	69
4.2.2	Comparación del modelo multimodal contra otros modelos	73
4.3	Modelo de Boosting con datos desbalanceados	74
4.4	Discusión de resultados	79
5	Modelo de predicción de la producción con series de tiempo multimodales	80
5.1	Arquitectura de modelos multimodales	80
5.2	Entrenamiento y validación de modelos multimodales	84
5.3	Comparación de modelos multimodales con modelos de línea base	86
5.3.1	Entrenamiento de modelos de línea base	86
5.3.2	Comparación de modelos	87
5.4	Discusión de resultados	94

6 Conclusiones y trabajo futuro	104
6.1 Conclusiones	104
6.2 Trabajo futuro	106
Bibliografía	109

Lista de Figuras

2-1	Esquema de la técnica de fusión multimodal de datos [10]	12
2-2	Modelo CNN-BiLSTM para pronósticos de series de tiempo con entradas multimodales [56]	13
2-3	Autoencoder multimodal para llevar los distintos tipos de datos a una representación conjunta [61]	14
2-4	Modelo multimodal basado en imágenes para clasificación de series de tiempo multivariadas [25]	14
2-5	Esquema de un pozo petrolero con bombeo mecánico.	15
2-6	Dinagrama (a la izquierda) y prueba de válvula (a la derecha) de un pozo con bombeo mecánico.	16
2-7	Ejemplo de la historia de producción de un pozo petrolero.	17
2-8	Flujo de trabajo aplicando PCA, agrupación y redes neuronales [34].	19
2-9	Flujo de trabajo con redes neuronales para pozos nuevos [7]	19
2-10	Flujo de trabajo con redes neuronales para pozos existentes [7]	20
2-11	Esquema representativo de las series de tiempo multimodales	23
3-1	Preprocesamiento realizado para generar los conjuntos de datos para el modelo multimodal.	26
3-2	Ejemplo del formato de una hoja del libro de pruebas correspondiente a un pozo.	28
3-3	Nube de palabras de los comentarios de los servicios realizados a pozo.	30
3-4	Comportamiento de los datos numéricos de la aplicación TWM.	33
3-5	Comportamiento de las variables asociadas con producción de los datos numéricos de la aplicación TWM.	34
3-6	Visualización de un dinagrama dentro de la interfaz de la aplicación TWM.	35
3-7	Visualización de una prueba de válvula dentro de la interfaz de la aplicación TWM.	36
3-8	Variables presentadas en la fuente "Libro de pruebas".	37
3-9	Ejemplo de un dinagrama visto desde la aplicación TAM [16].	38

3-10	Ejemplo de un pdf de un pozo exportado desde la aplicación TAM [16].	39
3-11	Arquitectura del modelo LSTM.	42
3-12	Historial de entrenamiento del modelo LSTM.	43
3-13	Arquitectura del modelo convolucional de 3 capas.	44
3-14	Historial de entrenamiento del modelo convolucional de 3 capas.	45
3-15	Arquitectura del modelo convolucional de 2 capas.	46
3-16	Historial de entrenamiento del modelo convolucional de 2 capas.	47
3-17	Matrices de confusión de los tres modelos en paralelo para comparar resultados.	47
3-18	Datos nulos por variable. El umbral de aceptación es de 60 % de datos nulos.	48
3-19	Datos nulos por variable. El umbral de aceptación es de 60 % de datos nulos.	49
3-20	Ejemplo de los datos de libro de pruebas y TWM para un pozo.	51
3-21	Aplicación de PCA para los datos de series de tiempo numéricas con reducción a 10 variables.	56
3-22	Aplicación de PCA para los datos de series de tiempo numéricas con reducción a 20 variables.	56
3-23	Aplicación de PCA para los datos de series de tiempo numéricas con reducción a 30 variables.	57
3-24	Representación final de un dinagrama a la izquierda y una prueba de válvula a la derecha.	58
3-25	Ejemplo de serie de tiempo con granularidad completa y todas las fuentes de datos cargadas.	59
3-26	Ejemplo de serie de tiempo con granularidad mensual y todas las fuentes de datos cargadas.	60
3-27	Ejemplo para entrenamiento de modelos con granularidad original con un tamaño de ventana 36 para predecir 12 pasos de tiempo en el futuro.	62
3-28	Ejemplo para entrenamiento de modelos con granularidad mensual con un tamaño de ventana 36 para predecir 12 pasos de tiempo en el futuro.	63
4-1	Modelo multimodal para procesar información de distintas fuentes en cada paso del tiempo.	66
4-2	Modelo multimodal distribuido temporalmente para procesar información de series de tiempo multimodales.	68
4-3	Submodelos convolucionales para procesar las entradas de datos de tipo imagen.	70

4-4	Submodelo multimodal que procesa los datos para cada paso de tiempo. Las capas <i>Sequential</i> corresponden a los submodelos convolucionales usados para procesar los datos de tipo imagen	71
4-5	Submodelo multimodal que procesa los datos para cada paso de tiempo con capa <i>custom dropout</i>	71
4-6	Modelo multimodal para clasificación de series de tiempo. La capa <i>Time-Distributed</i> contiene internamente el modelo multimodal que se ejecuta para cada paso del tiempo	72
4-7	Matriz de confusión del modelo multimodal para clasificación de series de tiempo con capa recurrente LSTM	75
4-8	Curva ROC para el modelo de <i>boosting</i> con promedio de probabilidades	76
4-9	Curva ROC para el modelo de <i>boosting</i> con votación	76
4-10	Curva ROC para el modelo multimodal entrenado sobre datos balanceados	77
4-11	Matriz de confusión para el modelo de <i>boosting</i> con promedio de probabilidades	77
4-12	Matriz de confusión para el modelo de <i>boosting</i> con votación	78
4-13	Matriz de confusión para el modelo multimodal entrenado sobre datos balanceados	78
5-1	Modelo multimodal con salida múltiple para realizar pronósticos de series de tiempo.	81
5-2	Modelo multimodal basado en LSTM con w_{size} de 36 y y_{steps} de 24.	83
5-3	Modelo multimodal basado en transformers con w_{size} de 36 y y_{steps} de 24.	83
5-4	Modelo univariado basado en LSTM con w_{size} de 36 y y_{steps} de 24.	86
5-5	Modelo multivariado basado en LSTM con w_{size} de 36 y y_{steps} de 24.	87
5-6	Análisis de casos donde el modelo ARIMA presentó resultados superiores a los modelos multimodales.	94
5-7	Resultados para un pozo determinado en la ventana de predicción de $w_{size} = 36$ y $y_{steps} = 24$	95
5-8	Resultados antes y después del proceso de fine-tuning.	95
5-9	Resultados para un pozo determinado después del proceso de fine-tuning para todos los modelos.	103

Lista de Tablas

3-1	Resultados de los modelos de clasificación de textos de servicios a pozo	41
3-2	Número de ejemplos realizados para la serie con granularidad original	61
4-1	Resultados de los modelos utilizados para predicción de fallas	73
4-2	Resultados de los modelos utilizados para predicción de fallas sobre datos no balanceados	79
5-1	Número de parámetros de los modelos multimodales de acuerdo con el tamaño de la ventana w_{size} y pasos a predecir y_{steps}	84
5-2	Resultado del entrenamiento de los modelos multimodales	85
5-3	Número de parámetros de los modelos no multimodales de acuerdo con el tamaño de la ventana w_{size} y pasos a predecir y_{steps}	88
5-4	Resultado del entrenamiento de los modelos no multimodales	89
5-5	Comparación de casos específicos contra la línea base de modelos ARIMA para 3 pasos de tiempo (trimestre)	90
5-6	Comparación de casos específicos contra la línea base de modelos ARIMA para 6 pasos de tiempo (semestre)	91
5-7	Comparación de casos específicos contra la línea base de modelos ARIMA para 12 pasos de tiempo (1 año)	92
5-8	Comparación de casos específicos contra la línea base de modelos ARIMA para 24 pasos de tiempo (2 años)	93
5-9	Resultado de predicción de 3 pasos de tiempo con una ventana de 6 para un pozo específico	96
5-10	Resultado de predicción de 6 pasos de tiempo con una ventana de 12 para un pozo específico	97
5-11	Resultado de predicción de 6 pasos de tiempo con una ventana de 24 para un pozo específico	98
5-12	Resultado de predicción de 6 pasos de tiempo con una ventana de 36 para un pozo específico	99

5-13 Resultado de predicción de 12 pasos de tiempo con una ventana de 24 para un pozo específico	100
5-14 Resultado de predicción de 12 pasos de tiempo con una ventana de 36 para un pozo específico	101
5-15 Resultado de predicción de 24 pasos de tiempo con una ventana de 36 para un pozo específico	102

1 Introducción

En la era actual, caracterizada por el aumento en la cantidad de datos provenientes de diversas fuentes y modalidades, la clasificación y predicción de series de tiempo se ha vuelto esencial en una amplia gama de industrias. Este trabajo de investigación presenta un aporte en estas dos áreas de estudio, particularmente en el caso de series de tiempo con distintas fuentes y tipos de datos, esto es, datos multimodales. Tradicionalmente, las técnicas de clasificación y pronóstico se han centrado en datos univariados y multivariados, sin embargo, este estudio propone un enfoque innovador mediante el empleo de modelos multimodales de redes neuronales.

La singularidad de este trabajo radica en el desarrollo de una arquitectura de *encoder* multimodal diseñada para abordar fenómenos temporales multimodales que utiliza una estrategia de fusión híbrida, donde cada punto en el tiempo incorpora información proveniente de diversas modalidades, como datos numéricos e imágenes, que ingresan al modelo de forma independiente, y son procesadas en capas especializadas para cada tipo de dato, para posteriormente ser concatenadas y procesadas en conjunto en las siguientes capas del modelo. Esta arquitectura no solo captura el comportamiento de cada fuente de datos por separado, sino que también explora las complejas interrelaciones entre diferentes fuentes, permitiendo al modelo realizar un aprendizaje más profundo del fenómeno en estudio, puesto que el todo es más que la suma de las partes.

El conjunto de datos utilizado para el presente estudio corresponde al fenómeno de producción de pozos petroleros con bombeo mecánico como sistema de levantamiento artificial, el cual contiene información multimodal como información numérica, imágenes y texto para cada paso del tiempo.

En el área de la clasificación de series de tiempo, el problema abordado es la predicción de fallas en el siguiente paso del tiempo, lo que constituye un problema de clasificación binaria. Uno de los modelos propuestos, que consiste en una arquitectura multimodal dis-

tribuida en el tiempo y conectada a una capa LSTM, muestra una exactitud del 61.3 %, que si bien puede considerarse un resultado modesto para una clasificación binaria, supera a otros modelos no multimodales empleados y se considera aceptable dada la naturaleza de los datos y las limitaciones de la cantidad de ejemplos para el entrenamiento del modelo. La motivación para clasificar las series de modo que se indique si el pozo fallará o no en el siguiente paso del tiempo consiste en la necesidad de establecer un cronograma de mantenimiento para los pozos de tal manera que se disminuyan los tiempos donde el pozo no está en producción. Adicionalmente, los pronósticos de producción acompañados de un resultado que indique si el pozo va a fallar o no, son útiles para que la compañía operadora pueda establecer una mejor planeación financiera.

En la sección de pronósticos de series de tiempo, el problema a abordar es la predicción de la producción en los siguientes meses, tomando ventanas de 3, 6, 12 y 24 meses. En este caso, los modelos multimodales con capas LSTM destacan sobre los modelos de redes neuronales no multimodales basados únicamente en datos numéricos, especialmente en predicciones trimestrales y bi-anales con periodicidad mensual, donde supera también a las implementaciones de la metodología ARIMA, presentando un error porcentual absoluto medio de 8 % llegando a 2 % en casos específicos. Sin embargo, se ha observado que el rendimiento del modelo ARIMA supera al multimodal en casos donde la serie de tiempo de producción presenta valores cercanos a la media y baja dispersión.

1.1. Objetivos

El objetivo general de esta tesis es proponer un modelo multimodal con los distintos tipos de datos disponibles sobre los pozos petroleros, para pronosticar la producción y la probabilidad de fallas. Para alcanzar este objetivo, se proponen los siguientes objetivos específicos:

- Elaborar un algoritmo que realice un primer nivel de fusión de datos mediante el etiquetado de clases de fallas y su impacto en la producción, para facilitar la fusión de datos y la predicción.
- Definir los operadores y variables que serán usados para la fusión de datos mediante un proceso de optimización, para estructurar el set de datos sobre el que se realizarán las predicciones.

- Elaborar los algoritmos de predicción ajustándolos a la estructura del set de datos generado por fusión multimodal, y estructurando la salida de acuerdo con el formato de la variable a predecir.
- Evaluar el desempeño del modelo midiendo tiempo de cómputo, ajuste a los datos, y exactitud de la predicción, para poder compararlo con otros modelos.

1.2. Metodología

La metodología empleada para desarrollar la presente investigación consistió en:

1. Una revisión detallada del estado del arte asociada con los problemas de clasificación y pronóstico de series de tiempo, manejo de datos multimodales, y modelos empleados con conjuntos de datos de pozos petroleros.
2. Revisión y preprocesamiento de la información entregada por la empresa colaboradora:
 - Consolidación y limpieza de las fuentes de datos numéricas entregadas
 - Extracción de imágenes de dinagramas y pruebas de válvula
 - Clasificación de la información de tipo texto entregada en Servicio, Servicio Menor y Falla.
 - Consolidación de imágenes y variables numéricas en un solo conjunto de datos utilizando la dimensión temporal para cada pozo
 - Etiquetado de las fechas en las que el pozo presenta un comentario de tipo falla
 - Selección por juicio de experto de las variables numéricas relevantes para la producción de petróleo.
 - Aplicación de PCA para obtener un conjunto de datos adicional que permita comparar el impacto de la selección de variables en el modelo.
 - Consolidación de ejemplos para clasificación y pronóstico de acuerdo con las ventanas de tiempo seleccionadas.
3. Diseño e implementación de la arquitectura de *encoder* multimodal distribuido en el tiempo que permita a la red neuronal aprender los patrones y relaciones entre cada fuente de datos.

4. Desarrollo de los modelos para clasificación y pronóstico de series de tiempo cambiando la capa de salida del modelo de acuerdo con la variable a predecir
5. Implementación de modelos no multimodales para comparar resultados con el modelo multimodal midiendo el ajuste de la predicción en términos de exactitud para la predicción de fallas y error porcentual absoluto medio para los pronósticos de producción.

1.3. Contribuciones

1.3.1. Contribuciones técnicas y conjuntos de datos

En el desarrollo del presente trabajo se consolidan los siguientes aportes:

- Metodología para el preprocesamiento de datos multimodales de pozos petroleros con bombeo mecánico.
- Conjunto de datos de 10805 ejemplos de textos generados por los operadores de pozos petroleros etiquetados como Servicio, Servicio menor y Falla.
- Conjunto de 15281 ejemplos balanceados para predicción de fallas en pozos petroleros (clasificación) con 613 ejemplos positivos y 14668 negativos.
- Conjunto de 1226 ejemplos balanceados mediante muestreo estratificado para clasificación binaria de las series de tiempo.
- Conjunto de datos de 366 series de tiempo multimodales con la granularidad de tiempo original y ajustadas a periodicidad mensual
- Conjunto de ejemplos para entrenamiento de modelos de pronósticos de series de tiempo multimodales con ventanas de tiempo de 6, 12, 24 y 36 pasos de tiempo en el pasado para predecir 3, 6, 12 y 24 pasos en el futuro donde cada ejemplo contiene:
 - Todas las variables sin normalizar
 - Todas las variables normalizadas por cada pozo
 - Variables obtenidas mediante la aplicación de PCA
 - Imágenes de pruebas de válvula para cada paso del tiempo

- Imágenes de cartas dinamométricas para cada paso del tiempo

Para el caso de la serie con granularidad completa se tienen entre 44598 y 56872 ejemplos, y para la serie mensual se tienen entre 4322 y 10484 ejemplos dependiendo del tamaño de ventana.

- Arquitectura de modelo multimodal implementada en TensorFlow [1] para clasificación y pronósticos de series de tiempo

1.3.2. Publicaciones

El presente trabajo contribuye al estado del arte con las siguientes dos publicaciones:

- *Multi-Modal Recurrent Model for Timeseries Classification: A Use Case on Failure Prediction in Oil Wells with Rod Lift System* [5] presentado en la conferencia "Fourth International Conference on Electrical, Communication and Computer Engineering ICECCE 2023" el 31 de diciembre de 2023 en Dubai (presentado en modalidad virtual).
- *Multi-Modal Model based on LSTM for Production Forecasting in Oil Wells with Rod Lift System* aceptado en la conferencia "10th International conference on Time Series and Forecasting ITISE 2024" del 15 al 17 de julio de 2024 en Gran Canaria España con publicación en *Engineering Proceedings MDPI*.

1.4. Distribución del documento

El presente documento se distribuye en los siguientes capítulos:

- **Capítulo 2 - Estado del arte:** Contiene una revisión de la literatura y los avances realizados en las áreas de clasificación y pronóstico de series de tiempo univariadas, multivariadas y multimodales. Adicionalmente incluye una revisión de estudios relacionados con estas áreas realizados con datos de pozos petroleros.
- **Capítulo 3 - Preprocesamiento: Extracción y transformación de datos:** Contiene la descripción de los datos, el preprocesamiento realizado que comprende la extracción de la información de fuentes de datos reales, y la transformación para su posterior uso en modelos multimodales para predicción de fallas y predicción de la producción en distintos intervalos de tiempo.

-
- **Capítulo 4 - Modelo de predicción de fallas mediante clasificación de series de tiempo multimodales:** Presenta los modelos multimodales utilizados para predecir las fallas en los pozos con datos balanceados y desbalanceados, y los compara con modelos de una sola modalidad.
 - **Capítulo 5 - Modelo de predicción de la producción con series de tiempo multimodales:** Presenta la arquitectura de los modelos multimodales para pronósticos de producción en distintas ventanas de tiempo, y compara su comportamiento frente a modelos no multimodales.
 - **Capítulo 6 - Conclusiones y trabajo futuro:** Contiene la discusión de los resultados del presente trabajo, y muestra el enfoque para el trabajo futuro.

2 Estado del arte

En este capítulo se realiza una revisión del estado del arte relacionado con el presente trabajo, el cual se relaciona con las áreas de clasificación de series de tiempo (TSC), pronóstico o predicción de series de tiempo (TSF), y series de tiempo multimodales. Cada una de estas áreas se han visto influenciadas en los años recientes por modelos de *deep learning*, presentándose modelos basados en redes neuronales convolucionales, residuales, recurrentes, y modelos basados en *transformers* que se presentarán a continuación.

2.1. Modelos de aprendizaje para series de tiempo

Dentro del área de la minería de datos, existen dos problemas relacionados con series de tiempo, clasificación de series de tiempo (TSC), y pronósticos de series de tiempo (TSF). En años recientes, el aprendizaje profundo ha influenciado significativamente el área de la clasificación de series de tiempo multivariadas (MTSC). Una revisión de este tema es presentada por Fawaz en 2019 [17] y actualizada por Foumani en 2023 [20].

En cuanto al área de pronósticos de series de tiempo (TSF), este se encuentra muy relacionado con el de clasificación de este tipo de datos, y ha tenido diferentes aproximaciones que inician desde los modelos clásicos de regresión lineal, los cuales marcan la línea base para el análisis de estos tipos de datos. En los años recientes esta área se ha visto influenciado por *deep learning*, siendo aplicados modelos de redes recurrentes, redes residuales y modelos basados en *transformers*. Tan [49] presenta en 2020 una revisión completa del estado del arte en esta área.

2.1.1. Modelos de clasificación de series de tiempo

Modelos basados en redes neuronales convolucionales

Wang introduce en 2016 las Redes Neuronales Completamente Convolucionales (FCN) y las Redes Residuales (ResNet) donde FCN en lugar de capas de *MaxPooling* utiliza *Global Average Pooling* (GAP) antes de la clasificación, y ResNet implementa conexiones residuales para atenuar el problema de desvanecimiento del gradiente en estructuras profundas [54]. *Inception-Time*, propuesto por Fawaz [17], es un conjunto de redes residuales que utiliza una estructura de cuello de botella o *bottleneck* con capas convoluciones de diferentes longitudes para capturar patrones a diferentes escalas. La robustez del modelo se mejora con capas de *max pooling* y capas *bottleneck* para tratar pequeñas perturbaciones, siendo destacado por incluir conexiones residuales [19].

Modelos basados en redes neuronales recurrentes

Las redes neuronales recurrentes RNNs presentan un uso extensivo para la predicción de series de tiempo, y en menor medida para la clasificación de series de tiempo. No obstante, diversos estudios las aplican con éxito a tareas de clasificación también. Estas aplicaciones aprovechan arquitecturas que incluyen capas de *Long Short-Term Memory* (LSTM) [50], *Gated Recurrent Units* (GRUs) [35], y modelos híbridos que combinan Redes Neuronales Convolucionales (CNN) con LSTMs [40], demostrando la versatilidad y eficacia de las redes recurrentes para manejar datos temporales en diferentes dominios.

Modelos basados en *transformers*

La adaptación de la arquitectura de *transformers* [52] para datos de series de tiempo se encuentra en modelos como BENDR [27] y un Marco de Trabajo basado en *transformers* (TST) [58]. Estos modelos se inspiran en el éxito del aprendizaje auto-supervisado en *transformers*, utilizando solo la parte del *encoder* y entrenándolo previamente con datos enmascarados para el aprendizaje de características de manera no supervisada.

Numerosos estudios buscan mejorar los mecanismos de *encoding* posicional dentro de los modelos de *transformers* [23], [55], [12]. Estos avances son fundamentales ya que abordan las limitaciones iniciales de la arquitectura de *transformers* para capturar la na-

turalidad secuencial de los datos de series de tiempo. Foumani [19] propone una mejora en la codificación posicional de los *transformers* con *Time absolute position encoding* (tAPE) y *Efficient relative position encoding* (eRPE), dando lugar al modelo ConvTran que utiliza capas convolucionales y de *transformers*, mejorando el rendimiento sobre los modelos que no son de aprendizaje profundo.

2.1.2. Modelos de pronósticos de series de tiempo

Modelos de Regresión Clásicos: Incluyen métodos como *Support Vector Machine* (SVM), *Linear Regression* (LR) y *Random Forest* (RF). Estos modelos, diseñados inicialmente para datos tabulares, aprenden una función de mapeo a partir de características extraídas de las series de tiempo, tratando a veces las series como datos tabulares. Sin embargo, esta aproximación a menudo no considera la dimensión temporal crítica en las series de tiempo [49].

Modelos Funcionales Lineales (FLM): Extendiendo el modelo de regresión lineal múltiple a datos funcionales, los FLM utilizan funciones de base como componentes principales funcionales (FPC) o funciones de *B-spline* para manejar la naturaleza continua de las series de tiempo [21].

Algoritmos Basados en Intervalos: Enfoques como el *Time Series Forest* extraen características de intervalos específicos de la serie de tiempo, ofreciendo a menudo un rendimiento mejor que los modelos basados en toda la serie [11].

Algoritmos Basados en Diccionarios: Estos métodos construyen un "diccionario" de patrones frecuentes en las series de tiempo, siendo ejemplos notables *Bag of Patterns* (BOP) y *Symbolic Aggregation Approximation Vector Space* (SAXVSM) [30].

Algoritmos Basados en Distancias: Modelos como *k-Nearest Neighbors* (*k-NN*) con diferentes medidas de distancia, incluyendo la distancia euclidiana y *Dynamic Time Warping* (DTW), se utilizan para calcular la similitud entre series de tiempo [49].

Modelos basados en Deep Learning

Las Redes Residuales o ResNet, una de las arquitecturas más influyentes, se destaca en el tratamiento de series de tiempo univariadas. Su estructura consiste en bloques residuales lo cual facilita el entrenamiento de redes profundas al aliviar el problema del desvanecimiento del gradiente [54].

La arquitectura *Fully Convolutional Neural Networks (FCN)* es otra arquitectura clave, se compone exclusivamente de capas convolucionales. Esta estructura la hace ideal para tareas de regresión y clasificación en series de tiempo. La arquitectura consiste en tres bloques convolucionales, cada uno acompañado de normalización por lotes y activación ReLU, y seguido de una capa de *Global Pooling* [54].

Adicionalmente las redes con capas *inception* representan un avance significativo, mejorando los modelos de aprendizaje profundo existentes para series de tiempo [17]. Su arquitectura incluye dos bloques residuales diferentes, conectando la entrada de un bloque con la entrada del siguiente. Cada bloque residencial consta de tres módulos *Inception*, que incorporan una capa embudo para reducir la dimensión de la serie de tiempo y varios filtros de diferentes longitudes, junto con operaciones *MaxPooling*. Este enfoque permite a la red *Inception* manejar filtros más largos que ResNet, mejorando la captura de patrones temporales.

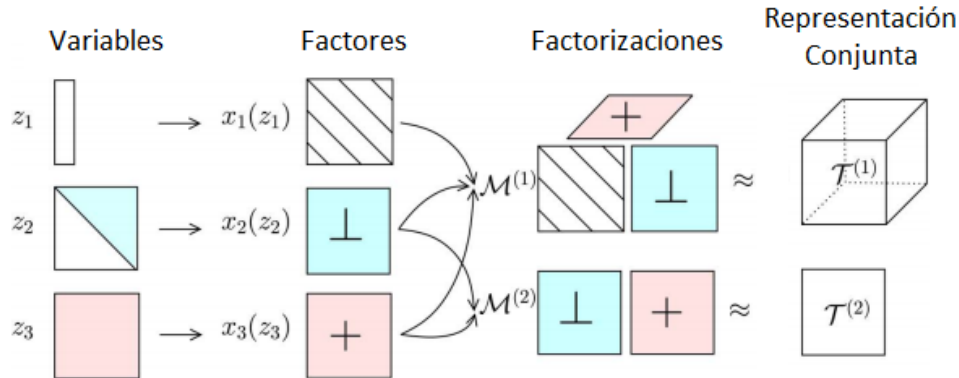
Otros estudios recientes introducen arquitecturas basadas en *transformers* ajustando la función de costo, obteniendo resultados mejores que los obtenidos con modelos de perceptrón multicapa (MLP) para los datos estudiados [57].

2.2. Modelos de aprendizaje multimodal

Los modelos anteriormente mencionados trabajan con datos de una o múltiples variables numéricas, salvo en el caso del modelo CNN-LSTM que se usa para series de tiempo de imágenes, sin embargo pocos modelos del estado del arte se realizan con datos multimodales.

La multimodalidad de datos se refiere a las distintas fuentes de las cuales se puede ob-

Figura 2-1: Esquema de la técnica de fusión multimodal de datos [10]



tener información acerca de un mismo fenómeno. Debido a esta variedad, se genera la necesidad de tomar la información útil y relacionarla en conjuntos de datos que permitan manejar hacer modelos y predicciones.

La fusión multimodal de datos es una técnica inspirada por el manejo que realizan los seres vivos de la información de los distintos sensores externos e internos, validando, relacionando, cotejando y descartando información según el proceso, necesidad o situación, lo que permite una eficiente toma de decisiones [10].

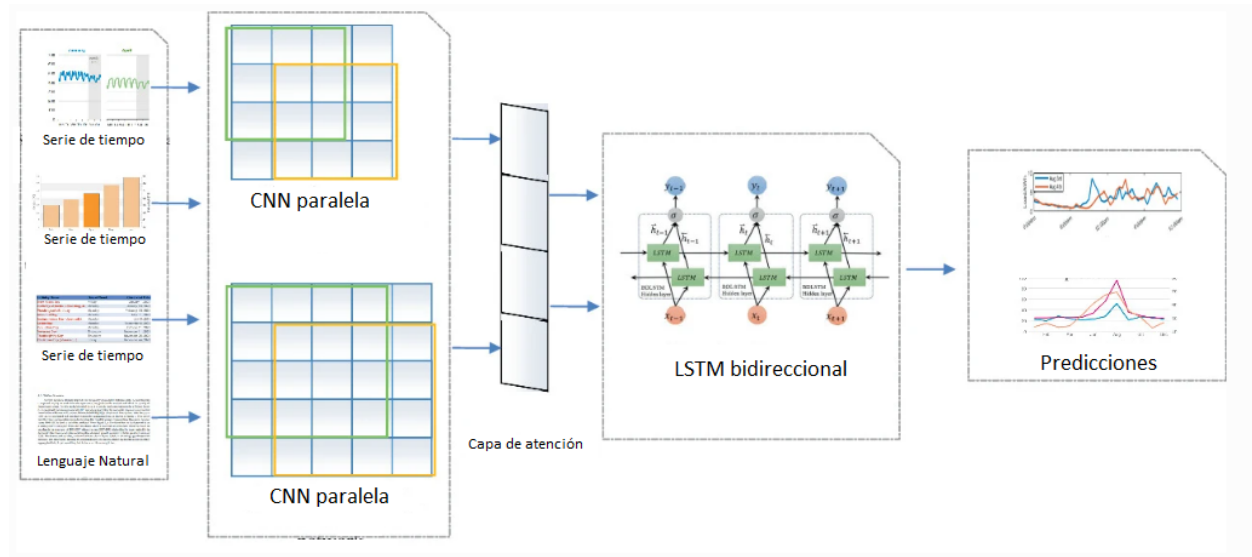
La Figura 2-1 representa el procedimiento de fusión multimodal de datos, donde las variables (que en el ejemplo son vectores y matrices) son transformadas y mapeadas usando factores, para luego ser integradas en una representación conjunta.

En cuanto a la elaboración de pronósticos, se presenta una aproximación que integra redes recurrentes y convolucionales para integrar datos de series de tiempo e imágenes mediante un modelo CNN-BiLSTM [56] donde dos entradas con capas convolucionales reciben los datos de distintas fuentes y luego la representación conjunta ingresa a una capa recurrente bidireccional con unidades LSTM como se muestra en la Figura 2-2 sin embargo para este caso específico, la serie de tiempo es una entrada de datos diferente de la imagen, por lo que no constituye una serie de tiempo multimodal sino un conjunto de datos multimodal con series de tiempo e imágenes.

Otro trabajo importante en pronósticos de series de tiempo con entradas multimodales es el propuesto por Zhu en 2021 [61] donde se utiliza un modelo en dos etapas, primero

2.3 Modelos de predicción de series de tiempo de información petrolera

Figura 2-2: Modelo CNN-BiLSTM para pronósticos de series de tiempo con entradas multimodales [56]



un *autoencoder* multimodal (ver Figura 2-3) para llevar los datos a una representación conjunta, que luego se ingresan a una red LSTM para realizar los pronósticos.

Jiang presenta en 2022 [25] un enfoque de clasificación con datos multimodales, utilizando imágenes y series de tiempo multivariadas, convirtiendo series de tiempo en imágenes y luego introduciéndolas en un *transformer* con *embeddings* posicionales y de tipo modal (ver Figura 2-4).

2.3. Modelos de predicción de series de tiempo de información petrolera

Los pozos petroleros son estructuras que permiten el flujo del petróleo y/o gas, que está almacenado en la roca almacén o reservorio, hacia la superficie. En la Figura 2-5 se presenta el esquema de un pozo con bombeo mecánico como sistema de levantamiento artificial, y acuífero activo como mecanismo de empuje.

La producción de un pozo petrolero corresponde al caudal de petróleo que proporciona, medido regularmente en términos de barriles estándar por día. Este caudal es afectado

Figura 2-3: Autoencoder multimodal para llevar los distintos tipos de datos a una representación conjunta [61]

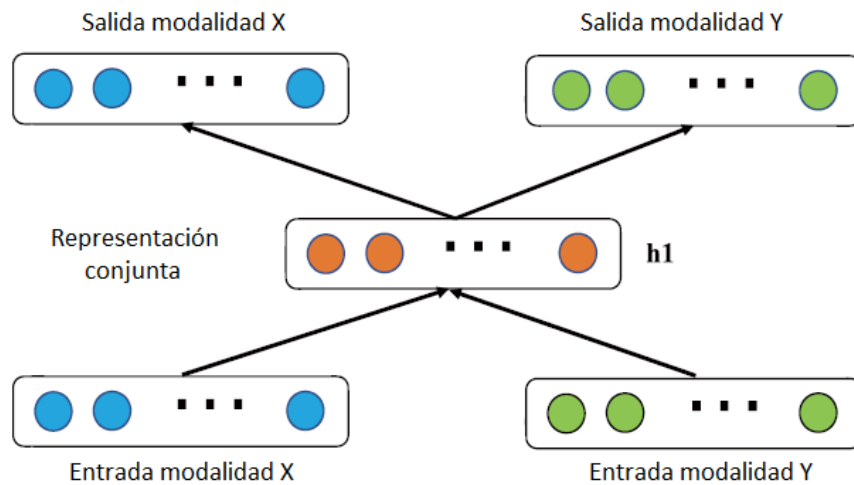
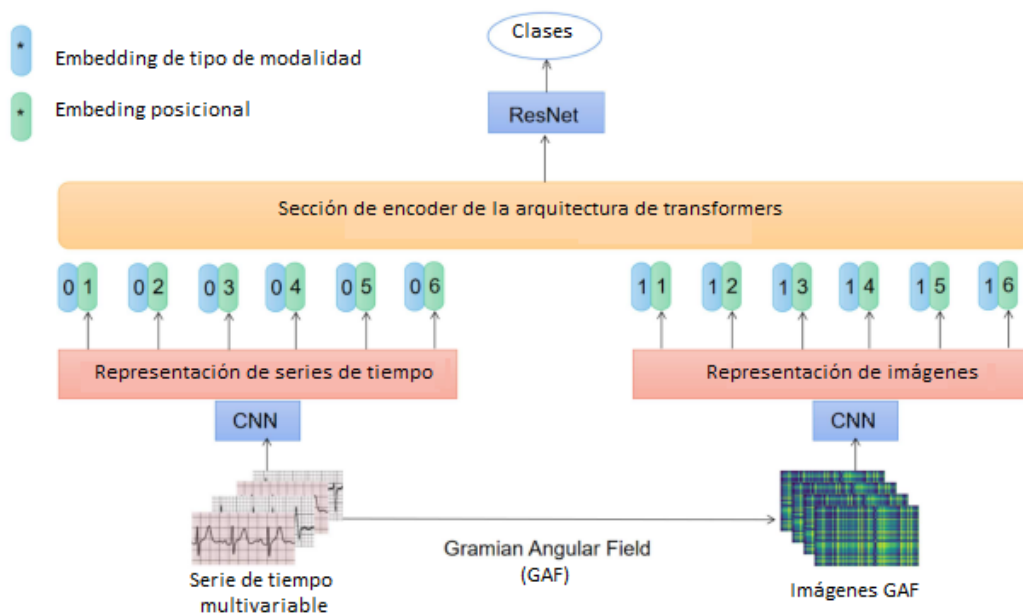



Figura 2-4: Modelo multimodal basado en imágenes para clasificación de series de tiempo multivariadas [25]



2.3 Modelos de predicción de series de tiempo de información petrolera

Figura 2-5: Esquema de un pozo petrolero con bombeo mecánico.




por distintas variables, tanto del pozo como del yacimiento, algunas de las cuales son:

- Tipo de hidrocarburo que produce: Los tipos de hidrocarburos están dados por su comportamiento termodinámico a condiciones normales, dividiéndose en aceite negro, aceite volátil, gas condensado, gas húmedo, y gas seco. Adicionalmente, es posible clasificar los hidrocarburos por su contenido de azufre, asfaltenos, entre otros.
- Sistema de levntamiento: Es la maquinaria que se utiliza para llevar el petróleo desde el fondo de los pozos hasta superficie. Algunos ejemplos son bombeo mecánico, bombeo electro-sumergible, y bombeo por cavidades progresivas.
- Historia de producción: Son datos en formato de serie de tiempo de la producción total, producción de petróleo, y contenido de sólidos registrada por unidad de tiempo durante la vida productiva.
- Corte de agua: La cantidad barriles de agua que sale del pozo por barril de líquido producido.
- Historia de fallas: Reportes escritos por los operadores del pozo acerca de las fallas presentadas.

El presente trabajo se realiza con datos de un campo petrolero con bombeo mecánico como sistema de levantamiento artificial, por lo que incluye variables adicionales como las cartas dinamométricas de carga contra desplazamiento (dinagramas) y pruebas de válvula que corresponden a imágenes que relacionan la carga soportada por el sistema y el comportamiento de la válvula en un recorrido o ciclo completo. La Figura 2-6 muestra un ejemplo de dinagramas y prueba de válvula.

Figura 2-6: Dinagrama (a la izquierda) y prueba de válvula (a la derecha) de un pozo con bombeo mecánico.



La producción inicia desde cero, y aumenta rápidamente hasta un punto máximo que marca el inicio del periodo de declinación. En la Figura 2-7 se presenta el comportamiento típico del caudal de producción de un pozo petrolero a lo largo de su vida útil.


La importancia de la predicción de la producción radica en que las empresas operadoras de los campos petroleros deben realizar su planeación y presupuesto con respecto a la producción que esperan tener para el siguiente mes o año [37].

2.3.1. Modelos para Predecir la Producción de Hidrocarburos

Los modelos de predicción clásicos datan desde 1945, siendo los basados en curvas de declinación exponencial, armónica, e hiperbólica los más utilizados [4], seguidos por las curvas tipo de Fetkovich [18]. Estos modelos han sido objeto de diversas variaciones, y han servido como base para la construcción de nuevos modelos empíricos y analíticos

2.3 Modelos de predicción de series de tiempo de información petrolera

Figura 2-7: Ejemplo de la historia de producción de un pozo petrolero.



[51], [9], resultando en mejoras en cuanto al ajuste de los pronósticos.

Uno de los modelos propuestos en las últimas dos décadas es el modelo de producción exponencial estrecho "SEPD" [51], introducido en el año 2010 para describir el comportamiento de la producción en pozos de gas no convencionales. Otro modelo es el que Collins, et al. propusieron en el 2014 [9], que consiste en un modelo basado en curvas empíricas de Arps (específicamente en la curva hiperbólica), con el fin de ajustarlas a hidrocarburos no convencionales.

Olominu y Sulaimon [41] publicaron un trabajo donde se utiliza el modelo ARIMA (Autorregresivo Integrado de Media Móvil) para predecir el comportamiento futuro del pozo. En los resultados del artículo se evidencia que los órdenes de los modelos utilizados en ningún caso superaron el segundo grado.

En el 2015 Montes [37] utiliza una simulación numérica para evaluar las variables que más influencia tenían sobre la declinación de la producción, y luego, en el 2016 [39] realiza experimentos con ARIMA (p,d,q) para realizar los pronósticos (basándose solo en la serie de tiempo de la producción) implementando una malla con paso 1 para los órdenes p,d y q, evaluando cada modelo de acuerdo con los valores de AIC (*Akaike Information Criterion*), el cual mide la pérdida de información, para al final seleccionar el mejor modelo (con menor AIC).

Popa en 2012 [43] utiliza redes neuronales para predecir la producción de pozos sometidos a inyección cíclica de vapor mediante el reconocimiento de patrones. Su objetivo es encontrar el ciclo óptimo (de acuerdo con las variables) para ir más allá de la predicción, e intentar aumentar la producción. Sin embargo, su estudio no se extiende a otros tipos de pozos.

En algunos casos se combina el uso de redes neuronales con el análisis de series de tiempo [45], [22] para analizar la producción u otras variables que varían en el tiempo, tales como corte de agua (WOC), relación gas aceite (GOR), entre otros. Sin embargo, solo se tienen en cuenta los tipos de datos que tienen estructura de series de tiempo numéricas. Un artículo publicado por Ma en 2015 [34], aunque se enfoca únicamente en SAGD (*Steam Assisted Gravity Drainage*), que es una técnica que aplica únicamente para extracción de crudos pesados y extrapesados, aplica tres técnicas: PCA para preprocesamiento, agrupación aplicando el algoritmo *K-Means*, y ANN para predicción. La Figura 2-8 muestra el flujo de trabajo que los autores proponen para aplicar las técnicas. Existen otros casos aplicación de Redes Neuronales en SAGD en la literatura, como es el caso de la estimación de los parámetros desconocidos del modelo de datos [14], y de la aplicación de esquemas que representen la heterogeneidad del yacimiento (capas de roca menos o nada porosas) para evaluar su impacto en el rendimiento de la técnica [59].

En las Figuras 2-9 y 2-10 se presenta un flujo de trabajo propuesto en 2016 [7] donde se manejan pronósticos tanto para pozos nuevos, como para pozos existentes. El método presentado en el artículo para validar la predicción para un pozo nuevo es ocultar un pozo existente (se divide la base de datos, y el pozo que se tratará como "nuevo" o no perforado aún, es la base para evaluación o pruebas), predecir su producción como si no se hubiese perforado y luego comparar los datos reales con la predicción.

También se encuentran en la literatura estudios comparativos de los pronósticos obtenidos con redes neuronales y métodos empíricos [48], incluyendo modelos combinados entre redes neuronales tanto con curvas de declinación (el modelo clásico de identificación de la tendencia con curvas empíricas) [29], como con análisis de series de tiempo [24]. Aizenberg [2] incursiona en el uso de redes neuronales de valores complejos argumentando que es posible aumentar la funcionalidad y mejorar su rendimiento con respecto a las de valores reales.

2.3 Modelos de predicción de series de tiempo de información petrolera

Figura 2-8: Flujo de trabajo aplicando PCA, agrupación y redes neuronales [34].

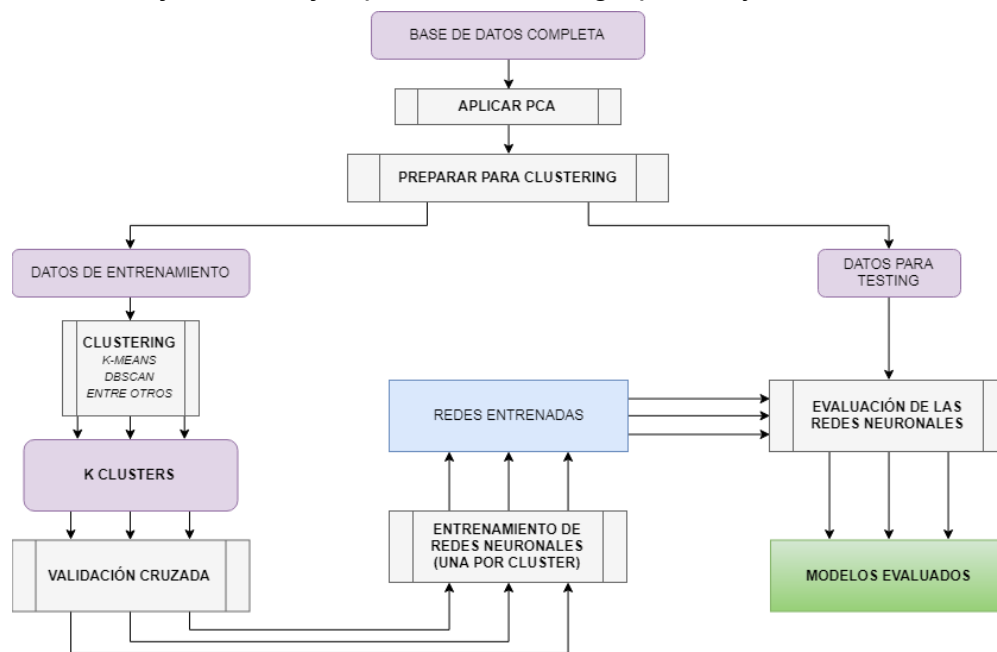


Figura 2-9: Flujo de trabajo con redes neuronales para pozos nuevos [7]

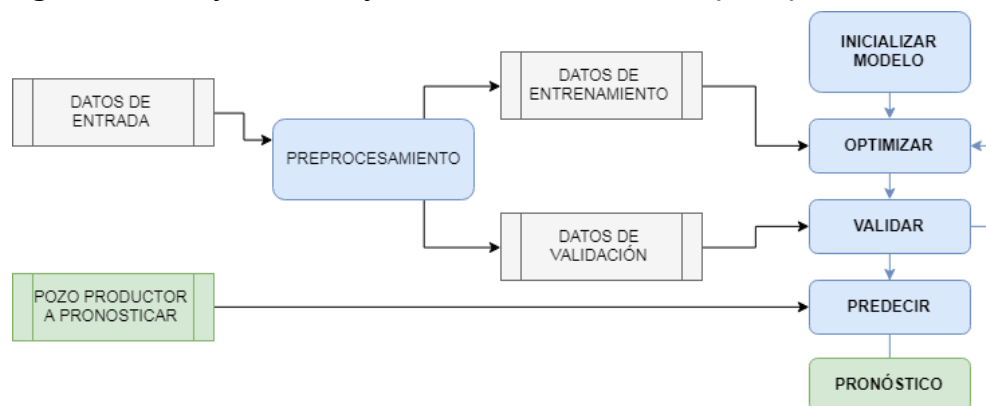
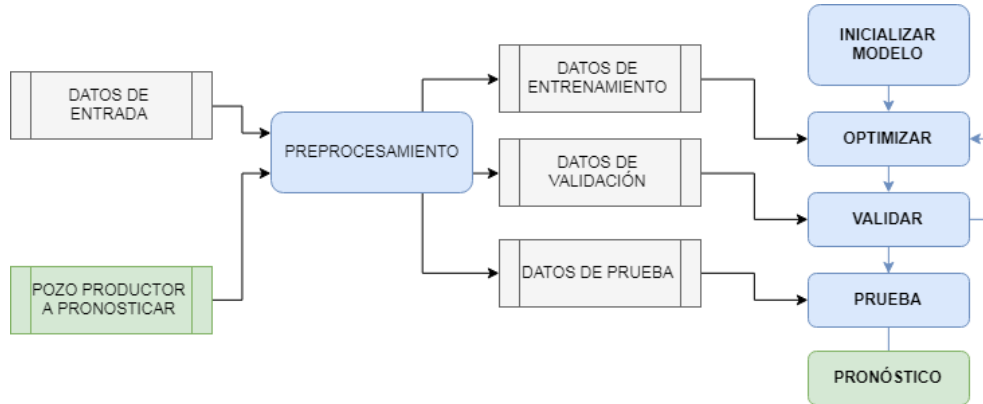


Figura 2-10: Flujo de trabajo con redes neuronales para pozos existentes [7]



Otros modelos de aprendizaje automático son propuestos por Vyas, donde se realizan predicciones con máquinas de soporte vectorial, *random forest*, y la técnica MARS (*Multivariate Adaptive Regression Splines*), y al final se realiza un promedio ponderado [53]. También se propone una aplicación para campos con recobro mejorado [36], que se divide en dos pasos: primero usa PCA para reducción de dimensionalidad, y luego SVR para predecir la producción basándose en los datos de todos los pozos vecinos.

En el contexto de los hidrocarburos no convencionales, existe una herramienta [3] que implementa métodos como SVM, RF, PCA, agrupación (con el algoritmo *K-Means*) presentada en el 2016 en el evento *Unconventional Resources Technology Conference*.

Li en 2013 [28] realiza un análisis comparativo entre redes neuronales, NDT (*Neuronal Decision Tree*), y Algoritmo C4.5, encontrando que, para los casos de estudio, los mejores resultados los presenta el modelo de redes neuronales, seguido por NDT.

En el 2018 Schuetter [46] publica un estudio comparativo entre distintas técnicas, incluyendo SVM, árboles de decisión mostrando su uso en un yacimiento de *Shale*, identificando las ventajas y desventajas en su aplicación. La conclusión principal es que la mejor opción sería combinar las predicciones encontrando un promedio ponderado. Se tienen distintas variables “predictoras”, y la respuesta esperada del modelo es la producción acumulada a 12 meses, con respecto a esto, se generan arboles de decisión, y se clasifican en buenos y malos pozos. La utilidad del trabajo propuesto es usar los modelos para tomar decisiones sobre perforar o no un pozo determinado de acuerdo con las variables que se tienen.

2.3.2. Predicción de Fallas en los Pozos Petroleros

Las fallas en los pozos generan tiempos de no producción que afectan directamente en el éxito de los pronósticos, además, si no se tiene prevista la falla, el tiempo gastado en logística aumenta las pérdidas de la empresa operadora. Se hace entonces necesario predecir estas fallas y dar alertas tempranas, además de modificar el pronóstico de producción de ese pozo. Este problema se encuentra dentro de la línea de trabajo de clasificación de series de tiempo.

Liu propone en 2010 [32] una metodología para predecir las fallas de los pozos con sistema de bombeo mecánico (MP), usando, a partir de los datos del pozo, técnicas de minería de datos y aprendizaje automático. Más adelante Raghavenda en 2013 [44], implementa máquinas de soporte vectorial como clasificadores, en un modelo que devuelve un valor booleano que indica si el pozo está propenso a fallar o no, en el corto plazo. Liu utiliza en 2015 [31] *autoencoders*, para predecir las fallas en los pozos que usan bombeo mecánico. Como restricción o dificultad para su aplicación, está el que los datos que ingresan deben ser capturados por un sensor especial, pero como punto a favor, los resultados evaluados en un rango de entre 30, 40, 50 y 60 días presentan una precisión de 90 % y un recall de 86.1 % con un margen de 30 días.

2.3.3. Preprocesamiento de Datos de Pozos Petroleros

Para poder obtener buenos resultados al implementar los modelos mencionados, es necesario realizar preprocesamiento de los datos. En el caso de los pozos de hidrocarburos, las actividades de preprocesamiento corresponden principalmente a reducción de dimensionalidad.

Debido al aumento en la cantidad de datos que son medidos en los pozos, algunos de estos en tiempo real, se hace necesario seleccionar las variables adecuadas que contengan la mayor cantidad de información. En el año 2013 [13] fue propuesta la técnica SAK (*Segmented Attribute Kerneling*), que permite utilizar varios métodos de medición de importancia de los atributos, con segmentos de los datos, y luego combinar los resultados para obtener un ranking.

Más tarde, en el 2016, Lolon analiza el impacto de diversos parámetros sobre la producción acumulada a 180 días [33], hallando matrices de correlación y construyendo distintos modelos con diferentes parámetros para encontrar las variables que mejor la describen (y por tanto, que más la afectan). El enfoque dado, es la optimización de la producción en pozos horizontales, hallando los valores óptimos para las variables más importantes, pero puede ser extendido hacia la evaluación de la importancia de las dimensiones disponibles en los pozos convencionales, para eliminar atributos poco relevantes y construir los modelos con un menor costo de procesamiento.

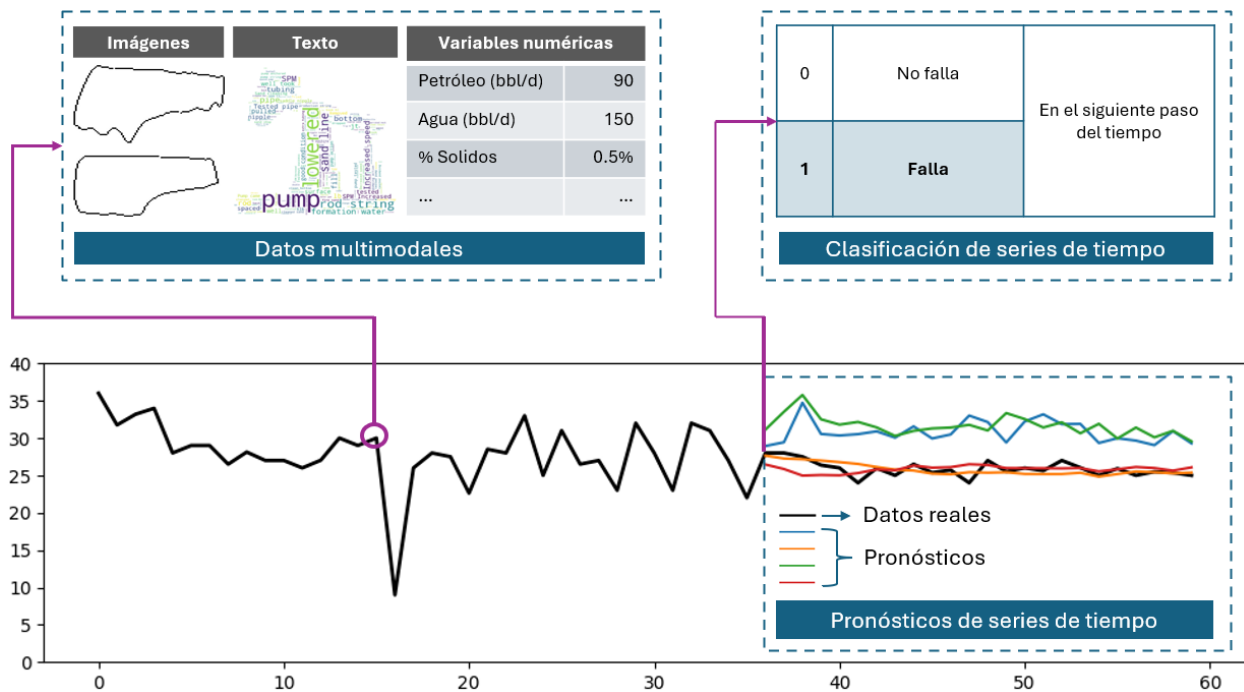
El análisis de sensibilidad es otra técnica usada para definir el orden de importancia de las variables [29] y para encontrar los parámetros del yacimiento que más se relacionan con la producción, para luego aplicar PCA (*Principal Component Analysis*) y obtener el menor número de atributos, manteniendo la mayor cantidad de información, para luego pasarlo a una red neuronal.

Una vez elegidas las variables a trabajar, muchos autores optan por usar PCA para reducir dimensionalidad [29],[60]. Chen [8] debido a su campo de estudio sobre el problema de canalización en los yacimientos, menciona que al aplicar PCA *Principal Component Analysis* se pierde información geológica valiosa, y propone una variante (que resulta de combinar dos técnicas) llamada *Cumulative Distribution Function based PCA*, lo que finalmente permite usar PCA conservando la información que se necesita. Es importante decir que las técnicas mencionadas en esta sección se utilizan para el preprocesamiento de datos de manera aislada, con datos de un mismo tipo, que para estos casos son variables asociadas con la geología del pozo.

Finalmente, la revisión del estado del arte presentada para las áreas de clasificación y pronósticos de series de tiempo muestra los diferentes acercamientos realizados en la literatura tanto para series de tiempo univariadas como multivariadas, sin embargo, se observan pocos trabajos que abordan el problema de la multimodalidad en estas áreas. El presente trabajo propone modelos de *deep learning* que permiten realizar clasificación y pronósticos de series de tiempo utilizando toda la información disponible cuando las series de tiempo son multimodales, esto es, cuando cada paso del tiempo contiene fuentes de distintas modalidades como se muestra esquemáticamente en la Figura 2-11, utilizando datos de producción de pozos petroleros con bombeo mecánico para predecir la producción y las fallas asociadas al proceso.

2.3 Modelos de predicción de series de tiempo de información petrolera

Figura 2-11: Esquema representativo de las series de tiempo multimodales



3 Preprocesamiento: Extracción y transformación de datos

En este capítulo se presenta el preprocesamiento realizado que comprende la extracción de la información de fuentes de datos reales, y la transformación para su posterior uso en modelos multimodales para predicción de fallas y predicción de la producción en distintos intervalos de tiempo.

Para el desarrollo de este estudio, se emplea información provista por la Unión Temporal Ismocol Joshi Parko (UT IJP), empresa operadora de campos petroleros en Colombia. La información de los pozos se encuentra anonimizada en el presente documento por la confidencialidad de los datos. La información suministrada por la UT IJP contiene datos de 261 pozos petroleros, en formatos de Excel, datos numéricos y datos binarios de la aplicación TWM, que es una herramienta de software para manejo de información de pozos petroleros [15]. Para este conjunto de datos se aplica proceso de extracción, transformación, resultando en 100360 registros de pruebas de pozos. De estos registros, 44646 incluyen mediciones de sensores en formato numérico de TWM, 22824 contienen imágenes de dinagramas, y 22788 contienen imágenes de pruebas de válvula. Además, se dispone de 10805 registros de servicios realizados a los pozos.

El resultado del preprocesamiento es un conjunto de ejemplos para el modelo multimodal, donde cada ejemplo consiste en una ventana de tiempo que tiene tres entradas estructuradas para cada paso del tiempo como variables independientes. Se estructuraron ejemplos para ventanas de 6, 12, 24 y 36 pasos de tiempo, y las variables son:

- Datos numéricos: Consolida todas las entradas de datos numéricos para cada paso del tiempo, y se realiza reducción de dimensionalidad con dos técnicas en paralelo para probar modelos con los dos conjuntos de datos distintos: Selección de variables por juicio de experto, con 15 variables numéricas seleccionadas, y análisis de

componentes principales con 30 variables seleccionadas de un total de 49. En el presente capítulo se indica el significado de cada variable.

- Imágenes de dinagramas: Contiene las imágenes como matrices de un solo canal, con dimensiones [120, 100].
- Imágenes de pruebas de válvula: Contiene las imágenes como matrices de un solo canal, con dimensiones [120, 200] .

Se tienen dos variables dependientes, una para el área de clasificación de series de tiempo, donde se busca predecir las fallas del pozo, y una para los pronósticos de producción de cada pozo:

- Variable dependiente para el modelo de clasificación de series de tiempo (TSC): Consiste en una clase binaria que indica si el pozo presentará o no falla en el siguiente paso del tiempo.
- Variable dependiente para el modelo de pronósticos de series de tiempo (TSF): Consiste en los pasos de producción de petróleo a predecir en el futuro. Se elaboran ejemplos para predecir 3, 6, 12 y 24 pasos de producción en el futuro de acuerdo con los requisitos de la industria.

La Figura 3-1 muestra el proceso realizado para la extracción y transformación de los datos desde sus fuentes iniciales hasta la consolidación del conjunto de datos para el modelo multimodal.

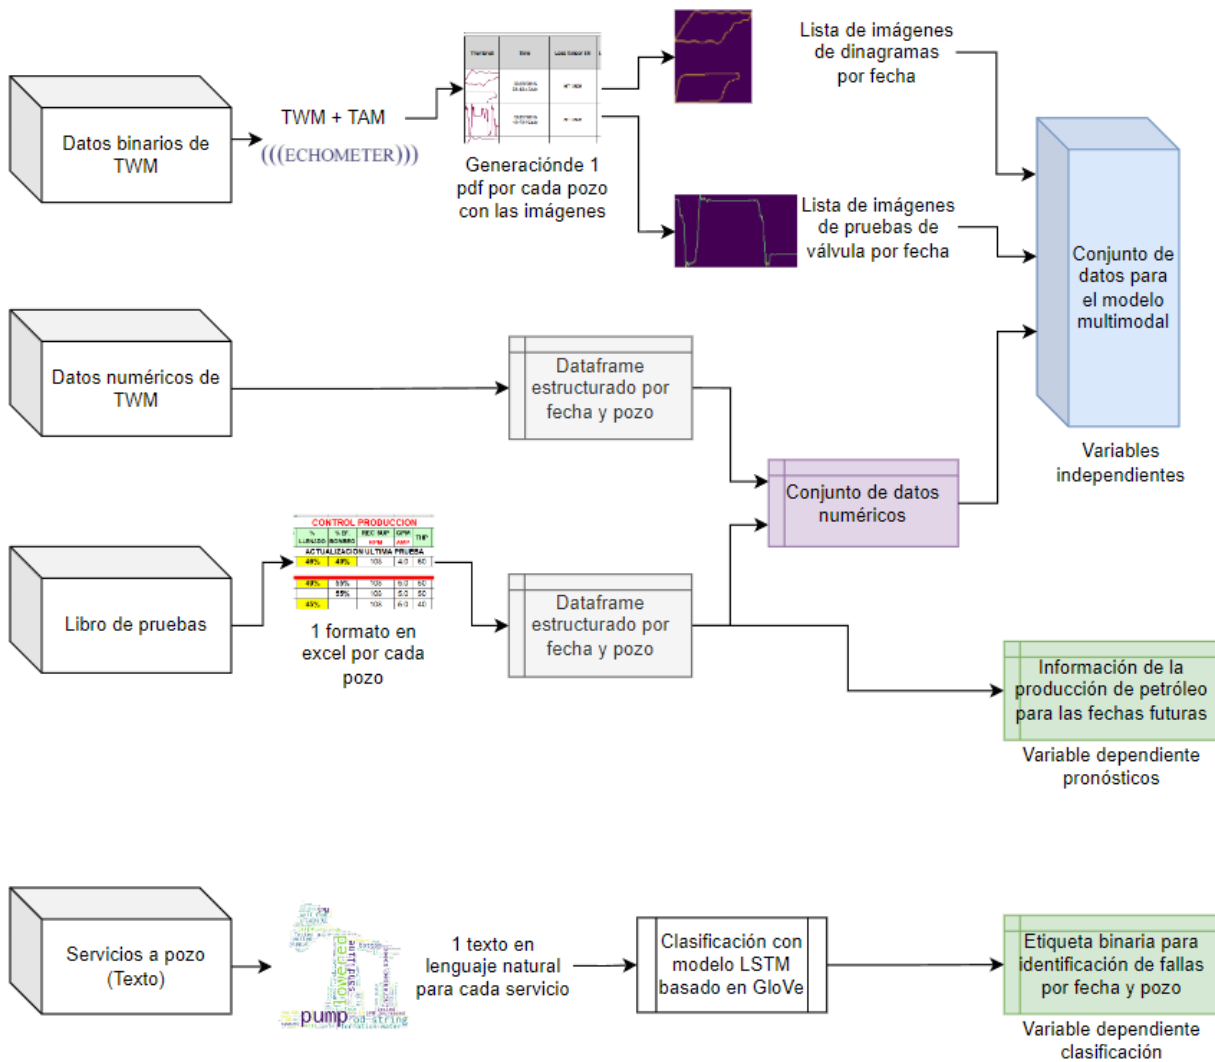
3.1. Fuentes de información

Como se mencionaba anteriormente se tienen cuatro fuentes principales de información las cuales serán descritas en detalle en esta sección.

3.1.1. Libro de pruebas

El "Libro de Pruebas" proporcionado en formato Excel por la Unión Temporal Ismocol Joshi Parko (UT IJP) está estructurado de manera que contiene una hoja por pozo organizada cronológicamente por fechas. En este libro, se combinan los datos de medición

Figura 3-1: Preprocesamiento realizado para generar los conjuntos de datos para el modelo multimodal.



de pruebas realizadas a los pozos y, en las fechas de servicios realizados, se detallan estos servicios en celdas combinadas. La Figura 3-2 muestra un ejemplo del formato empleado para diligenciar dicha información. La información en cada hoja se desglosa en las siguientes columnas:

- field: Nombre del campo petrolero.
- well: Identificación del pozo.
- date: Fecha de la prueba.
- qt: Producción (caudal) total, incluye producción de agua y petróleo.
- bsw: Contenido de agua y sólidos dentro del petróleo.
- qo: Producción de petróleo.
- depth: Profundidad de la bomba.
- flopt: Nivel de fluido total sobre la bomba.
- flopl: Nivel de líquido sobre la bomba.
- fp: Porcentaje de llenado de la bomba.
- pep: Presión de entrada del fluido a la bomba.
- rec_sup_rpm: RPM de la superficie.
- gpm_amp: Amperaje del sistema medido en superficie.
- thp: Presión en la cabeza del pozo.
- chp: Presión en el *casing* del pozo.
- pt_t_engine: Temperatura del motor PT.
- annular: Columna sin información.
- salt: Salinidad.
- tem: Temperatura ambiente.
- niv: Nivel de fluido total en el pozo.

- api: Gravedad API (medida de densidad) del petróleo producido.
- gas: Producción de gas.
- gor: Relación gas-aceite.
- bm_pcp: Indica si el pozo tiene bombeo mecánico o bombeo por cavidades progresivas. Sin embargo todos los pozos de los que se tiene información cuentan con bombeo mecánico.

Figura 3-2: Ejemplo del formato de una hoja del libro de pruebas correspondiente a un pozo.

CONTROL PRODUCCION																						
FECHA	BFPD	BSW	BOPD	BMB	PROF	NFSB TOTAL	NFSB LIQ	% LLENADO	% EF. BOMBEO	REC SUP RPM	GPM AMP	THP	CHP	PT T. MOTOR	ANULAR	SAL	TEM	NIV	°API	GAS	GOR	
ACTUALIZACION ULTIMA PRUEBA																						
12-oct-19	56(*)	12%	49	1.50	5,314	974	789	46%	49%	108	4.0	60	49	304,093	L.FLUJO	23,025	24	4,333	16.0	3.0	61	
COMENTARIOS Y OBSERVACIONES																						
31-may-18	62(*)	7%	58	1.50	5,314	1,218	839	49%	55%	108	5.0	50	47	297,924	L.FLUJO	23,025	24	4,065	16.2	10.1	174	
28-jun-18	62(*)	10%	56	1.50	5,314		839		55%	108	5.0	50	47		L.FLUJO	22,024	24		16.1	10.9	195	
12-jul-18	57			1.50	5,314	895	812	45%		108	5.0	40	40	281,147	L.FLUJO		24	4,397				
26-jul-18	66(*)	10%	59	1.50	5,314	1,077	817	50%	47%	108	5.0	50	51	299,832	L.FLUJO	24,026	24	4,210	16.0	9.0	153	
9-ago-18				1.50	5,314	824	557			108	5.0	40	38		L.FLUJO		24	4,469				
18-ago-18	65(*)	12%	57	1.50	5,314	1,034	807	48%	46%	108	5.0	50	52	279,035	L.FLUJO	23,025	24	4,254	16.1	5.5	96	
31-ago-18	58(*)	12%	51	1.50	5,314	1,035	746	52%	41%	108	5.0	55	54	299,027	L.FLUJO	23,025	24	4,253	16.1	16.3	320	
3-sep-18	118			1.50	5,314	1,591	1,488	85%		108	5.0	0	40	192,161	L.FLUJO		24	3,681				
Pozo parado por no bombeo, revisión equipo de subsuelo.																						
3-sep-18	Cambio de bomba: Con bomba anclada en niplesilla probó tubería con 500 psi, no sostuvo. Desancló bomba con 9 Kilbs de overpull. Sacó sarta de bombeo con varillas de 7/8" y 3/4" y bomba RWAC de 2-1/2" x 1-1/2" x 18' x 151". Probó tubería con 1.000 psi, ok. Verificó fondo con tubería @ 5.647' (T. Arena), fondo @ 5.693' (T. Cemento), relleno: 46", rat hole: 21". Sacó quebrando tubería extra y ubicó Niplesilla @ 5.314'. Bajó bomba RWAC de 2-1/2" x 1-1/2" x 18' x 151" con sarta de varillas de 3/4" y 7/8". Ancló y espacio bomba con 6", probó acción de bombeo con 500 psi, ok.																					
5-sep-18	105	100%		1.50	5,314	1,166	788	86%		108	4.9	45	43	299,406	L.FLUJO	22,024	24	4,137				
6-sep-18		73%		1.50	5,314										L.FLUJO	21,023	24					
7-sep-18		36%		1.50	5,314										L.FLUJO	22,024	24					
8-sep-18		10%		1.50	5,314										L.FLUJO	22,024	24					

3.1.2. Historial de servicios a pozo

La fuente "Historial de Servicios a Pozo" proporcionada es otra fuente del conjunto de datos para el análisis de los pozos petroleros operados por la Unión Temporal Ismocol Joshi Parko (UT IJP). Una nube de palabras de los servicios a pozo se encuentra en la

Figura 3-3. Este conjunto de datos se encuentra también en formato Excel y se estructura a través de las siguientes columnas:

- **field:** Nombre del campo petrolero donde se encuentra el pozo.
- **well:** Identificación del pozo. Este dato es clave para asociar cada servicio realizado con el pozo específico al que corresponde, asegurando una correcta correlación con los datos de producción y pruebas contenidos en el "Libro de Pruebas".
- **date:** Fecha en la que se realizó el servicio. Esta información temporal es vital para comprender la cronología de los servicios realizados en cada pozo y su posible impacto en la producción y el comportamiento del pozo.
- **comentario:** Detalles o notas relacionadas con el servicio realizado. Esta columna ofrece información cualitativa valiosa sobre la naturaleza del servicio, las observaciones realizadas durante el mismo, o cualquier otro comentario relevante que pueda influir en la interpretación de los datos de producción y en la toma de decisiones operativas. Esta información es utilizado en el presente estudio para clasificar los servicios en "Servicio mayor" que constituyen intervenciones al pozo donde se debe parar y utilizar maquinaria pesada, "Servicio menor" que constituye cambio de velocidad de producción o revisiones periódicas, y "Falla" que constituye un evento donde el pozo deja de producir, y se puede dar por distintas razones como bloqueo de la bomba por arena o gas, fugas en válvula o tubería, y finalmente ruptura de alguno de los componentes del sistema como la varilla o la tubería.

Este historial de servicios a pozo es un complemento importante al "Libro de Pruebas", proporcionando una visión más amplia de las actividades de mantenimiento y operaciones realizadas en cada pozo. La integración y el análisis conjunto de estos datos permite obtener etiquetas en el tiempo para identificar cuándo se presentó una falla.

3.1.3. Datos numéricos de la aplicación TWM

Los datos numéricos de la Aplicación TWM contienen distintas variables almacenadas en dicha aplicación, que corresponden tanto a información de sensores como a información digitada por los operadores. El detalle de las variables se relaciona a continuación:

- **Well:** Identificación del pozo.
- **Date:** Fecha de la medición.

- *Water Specific Gravity (Sp.Gr.H2O)*: Gravedad específica del agua.
- *Gas Specific Gravity (Sp.Gr.AIR)*: Gravedad específica del gas.
- *Measured Stroke Length (in)*: Longitud medida del golpe (en pulgadas).
- *Oil (Bo) (RB/STB)*: Factor volumétrico del petróleo.
- *Water (Bw) (RB/STB)*: Factor volumétrico del agua.
- *Gas (Bg) (RB/Mscf)*: Factor volumétrico del gas.
- *Oil Viscosity (cp)*: Viscosidad del petróleo (centipoises).
- *Water Viscosity (cp)*: Viscosidad del agua (centipoises).
- *Gas Viscosity (cp)*: Viscosidad del gas (centipoises).
- *Tubing OD (in)*: Diámetro exterior del *tubing* (en pulgadas).
- *MPRL (lb)*: Carga máxima de la varilla pulida (libras).
- *PPMPL (lb)*: Carga pico en la mitad del ciclo de la varilla pulida (libras).
- *MPMPL (lb)*: Carga máxima en la mitad del ciclo de la varilla pulida (libras).
- *Polished Rod Power (HP)*: Potencia de la varilla pulida (caballos de fuerza).
- *Polished Rod / Motor Eff. (%)*: Eficiencia de la varilla pulida / motor (porcentaje).
- *Plunger Stroke (in)*: Carrera del émbolo (en pulgadas).
- *SPM (spm)*: Golpes por minuto.
- *Pump Volumetric Fillage (%)*: Relleno volumétrico de la bomba (porcentaje).
- *Effective Plunger Stroke (in)*: Carrera efectiva del émbolo (en pulgadas).
- *Pump Displacement (BBL/D)*: Desplazamiento de la bomba (barriles por día).
- *Unaccounted Friction (lb)*: Fricción no contabilizada (libras).
- *PPRL (lb)*: Carga pico en la varilla pulida (libras).
- *Calc. Buoyant Rod Weight + Fluid Load (lbf)*: Cálculo del peso flotante de la varilla + carga de fluido (libras fuerza).

- *Measured Load TV (lbf)*: Carga medida en la varilla pulida (libras fuerza).
- *Leakage (BBL/D)*: Fugas (barriles por día).
- *Calculate Buoyant Rod Weight (lbf)*: Cálculo del peso flotante de la varilla (libras fuerza).
- *Measured Load SV (lbf)*: Carga medida en la válvula de succión (libras fuerza).
- *Intake Pressure (psi (g))*: Presión de admisión (psi, manométrica).
- *Calc. Fluid Load (lbf)*: Cálculo de la carga de fluido (libras fuerza).
- *Measured Load (Klbf)*: Carga medida (kilo libras fuerza).
- *Water Production Potential (BBL/D)*: Potencial de producción de agua (barriles por día).
- *Gas Production Potential (Mscf/D)*: Potencial de producción de gas (miles de pies cúbicos estándar por día).
- *Oil Production Potential (BBL/D)*: Potencial de producción de petróleo (barriles por día).

La Figura 3-4 muestra el comportamiento de estos datos, observando que variables clave como la de *Oil Production* (ver Figura 3-5), se mantienen constantes en varios periodos de tiempo debido a que cuando no se ha diligenciado el dato para la medición realizada, la herramienta replica el dato anterior, por este motivo, para las variables que se encuentran tanto en el libro de pruebas como en los datos numéricos de la aplicación TWM se toma la decisión de priorizar los datos de la primera fuente.

3.1.4. Datos binarios de la aplicación TWM: Imágenes del comportamiento del sistema

Los datos binarios de la aplicación TWM contienen toda la información asociada a las variables numéricas, y adicionalmente las imágenes asociadas a los dinagramas y pruebas de válvula que son importantes para analizar del desempeño del sistema de bombeo y la interacción con todos los elementos del sistema como la bomba de fondo, la varilla pulida, y la sarta de varillas. Sin embargo estos son accesibles únicamente desde la interfaz de la aplicación cargando mediciones individuales como se muestra en las Figuras 3-6

Figura 3-4: Comportamiento de los datos numéricos de la aplicación TWM.

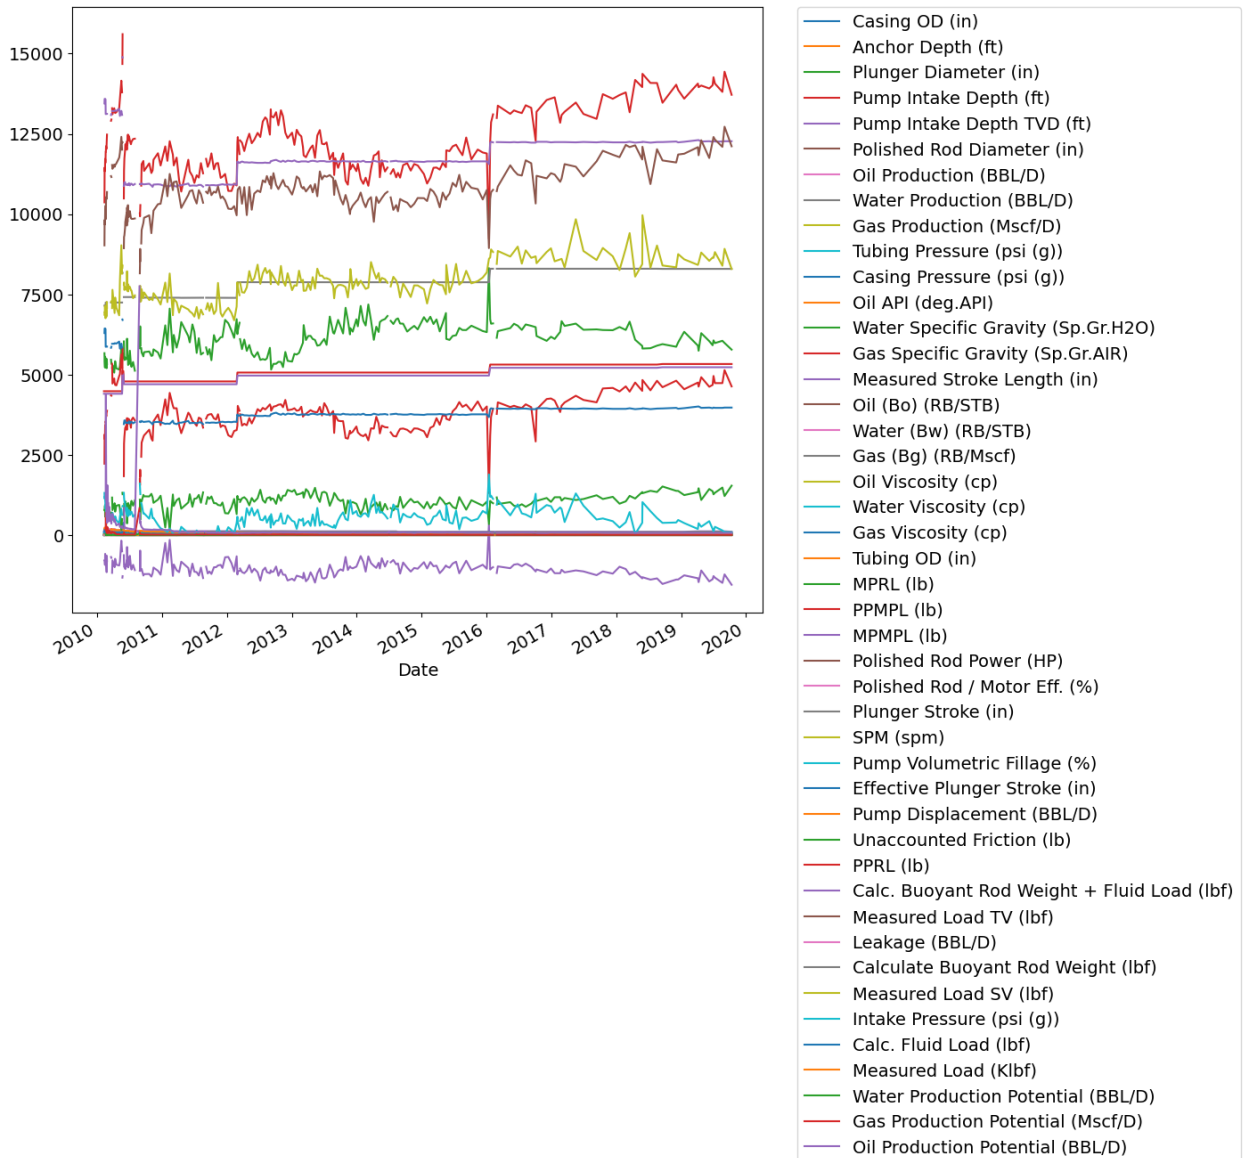



Figura 3-5: Comportamiento de las variables asociadas con producción de los datos numéricos de la aplicación TWM.



y 3-7, por lo que requiere un proceso de extracción y transformación para obtener esta información en un conjunto de datos procesable.

3.2. Extracción de la información

La extracción de la información constituye un paso fundamental en el presente estudio para procesamiento de los datos recopilados para el análisis de los pozos petroleros. Se implementaron métodos específicos para el libro de Pruebas y los datos binarios de TWM, que permitieron la integración y preparación de los datos para su análisis y uso efectivo. Esta sección detalla los pasos y técnicas utilizados en el proceso de extracción de la información, destacando las herramientas y enfoques adoptados para garantizar la integridad de los datos en cada etapa del proceso.

3.2.1. Extracción de la información numérica

Dado que el libro estaba compuesto por múltiples hojas de Excel, una para cada pozo, como paso inicial se desarrolla una subrutina en Visual Basic para Aplicaciones (VBA) con el objetivo de unificar de los datos contenidos en cada hoja del libro y estructurarlos en un formato estructurado. Este proceso permite extraer los datos de las diversas columnas mencionadas anteriormente, tales como *'field'*, *'well'*, *'date'*, *'qt'*, *'bsw'*, entre otras, y los consolidó en una única tabla. Esta tabla resultante corresponde a la información numérica

Figura 3-6: Visualización de un dinagrama dentro de la interfaz de la aplicación TWM.

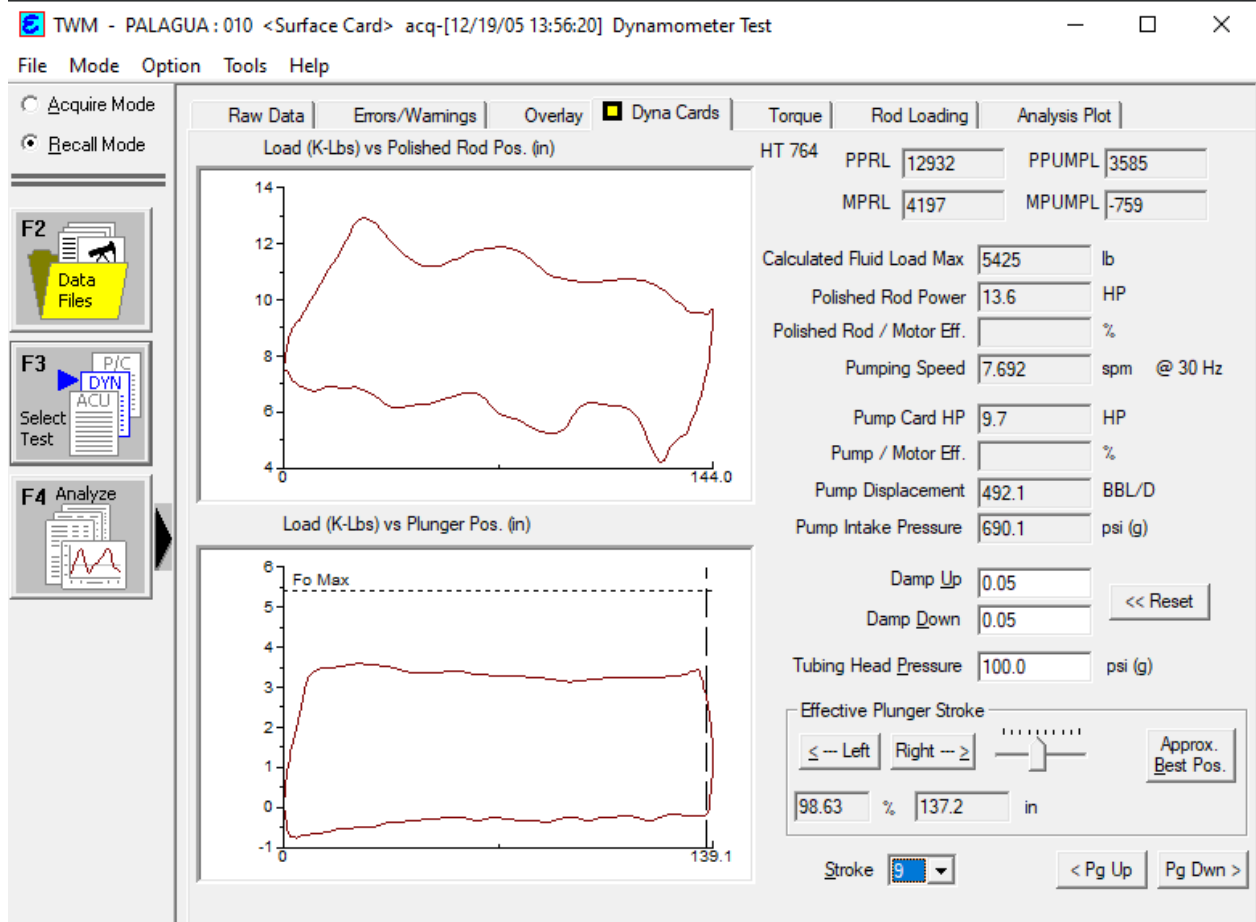
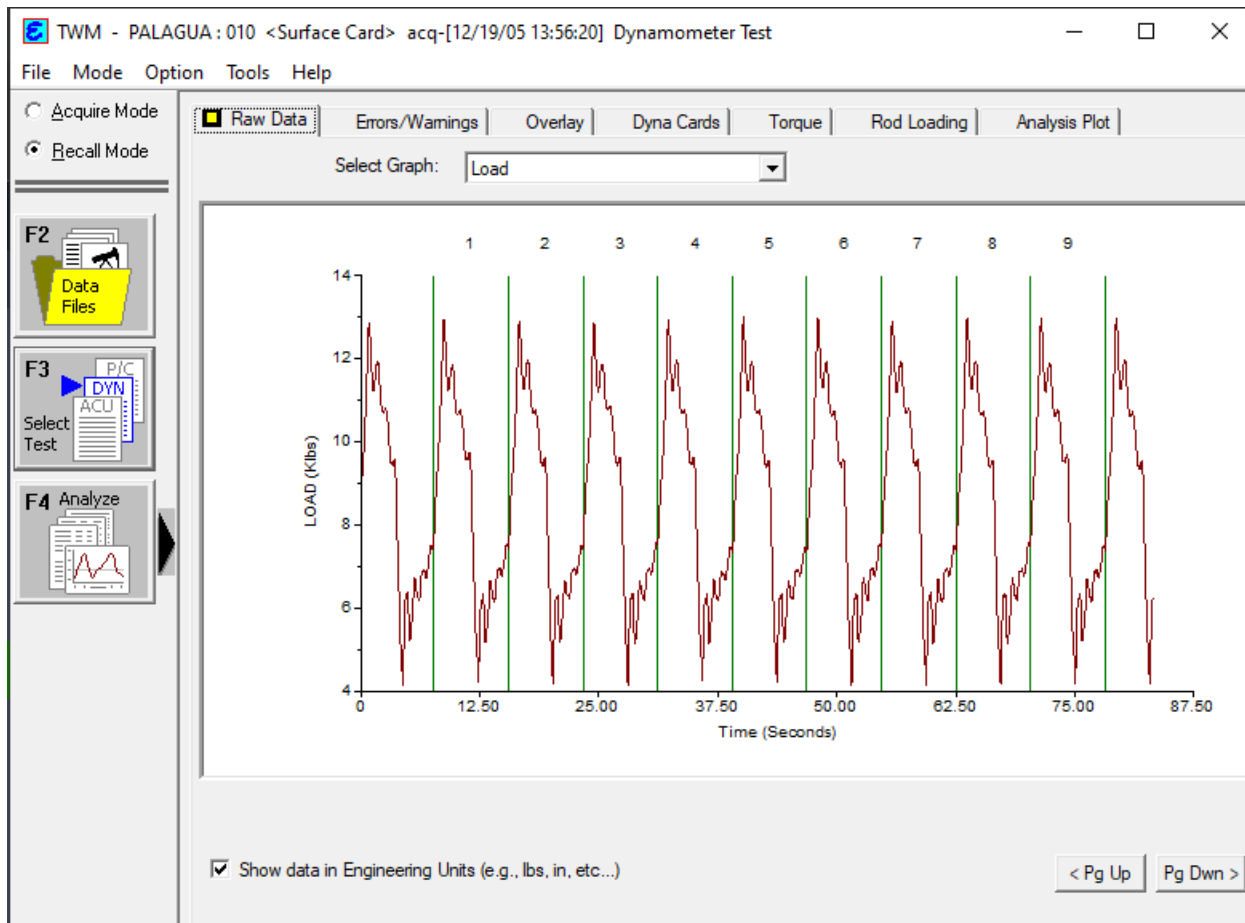



Figura 3-7: Visualización de una prueba de válvula dentro de la interfaz de la aplicación TWM.



detallada de todos los pozos, con lo que se consigue un conjunto de datos unificado. La Figura 3-8 muestra una gráfica del resultado de la extracción de datos para un pozo determinado.

Figura 3-8: Variables presentadas en la fuente "Libro de pruebas".

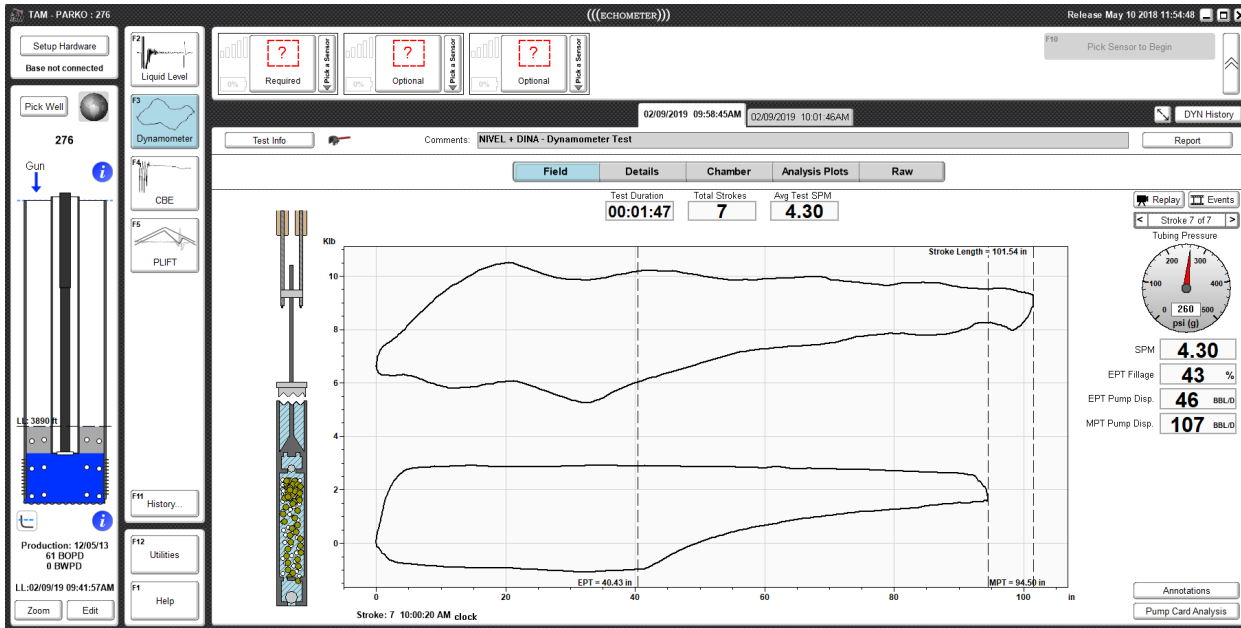


3.2.2. Extracción de las imágenes del comportamiento del sistema

En la fase de extracción de datos binarios de la aplicación TWM, enfocada en la obtención de imágenes de dinagramas y pruebas de válvula, se implementó una metodología para el manejo masivo de estos archivos. La estrategia adoptada involucró una migración de datos desde TWM hacia el software *Total Asset Monitor* (TAM) [16] que es otra herramienta de manejo de datos de pozos petroleros, que permite exportar documentos que incluyen las imágenes históricas de los dinagramas y pruebas de válvula, un paso esencial para facilitar la manipulación y exportación de las imágenes. La Figura 3-9 muestra la interfaz de TAM. Esta migración se diseñó para generar un archivo PDF específico para cada pozo, conteniendo tablas que agrupan las imágenes junto con las fechas asociadas. Este enfoque permite una organización eficiente y una recuperación sistemática de las imágenes relevantes sin pérdidas de información. La Figura 3-10 muestra un pdf de

ejemplo para un pozo determinado exportado desde TAM donde se puede observar el cambio en la forma de los dinagramas y las pruebas de válvula a cada paso del tiempo.

Figura 3-9: Ejemplo de un dinagrama visto desde la aplicación TAM [16].



Posteriormente, con un script en Python se extraen individualmente las imágenes de los archivos PDF. Cada imagen es almacenada en archivos separados y debidamente indexados en una tabla de referencia. En esta tabla se registró la asociación de cada imagen con su respectivo pozo y fecha de captura, permitiendo una integración eficiente de las imágenes en el conjunto de datos más amplio, permitiendo que todos los tipos de datos se organizaran en el tiempo, facilitando el proceso de elaboración de una arquitectura de red neuronal capaz de recibir esta información multimodal para cada paso del tiempo y procesarla para finalmente realizar la tarea de clasificación o predicción de la variable objetivo, llevando internamente los datos a una representación conjunta.

3.3. Transformación y consolidación de la información

Con la culminación exitosa del proceso de extracción, los datos son convertidos a un formato estructurado. Esta transformación marca un avance significativo en el flujo de trabajo, preparando el terreno para la siguiente fase: la transformación estos datos para

Figura 3-10: Ejemplo de un pdf de un pozo exportado desde la aplicación TAM [16].

(((ECHOMETER))) 014 10/12/2019 08:10:31AM												
Thumbnail	Time	Load Sensor SN	Load Sensor Name	Strokes	Fillage	Valve Test	Power	Leakage	Pressure	Pressure Sensor SN	Pressure Sensor Name	Comments
	02/28/2016 08:42:43AM	HT 1806		5	70.92	No	No		No	NA	NA	Dynamometer Test
	02/07/2016 10:52:29AM	HT 1806		0	0.00	Yes	No	0.00	No	NA	NA	Valve Test
	02/07/2016 10:49:19AM	HT 1806		5	81.49	No	No		No	NA	NA	Dynamometer Test
	01/27/2016 09:18:50AM	HT 1806		0	0.00	Yes	No	0.00	No	NA	NA	Valve Test
	01/27/2016 09:15:46AM	HT 1806		6	86.93	No	No		No	NA	NA	Dynamometer Test
	01/22/2016 08:26:28AM	HT 1806		0	0.00	Yes	No	0.00	No	NA	NA	Valve Test
	01/22/2016 08:20:14AM	HT 1806		4	97.22	No	No		No	NA	NA	Dynamometer Test
	01/15/2016 09:04:35AM	HT 1806		0	0.00	Yes	No	0.01	No	NA	NA	Valve Test
	01/15/2016 09:00:24AM	HT 1806		4	3.33	No	No		No	NA	NA	Dynamometer Test
	01/15/2016 08:26:03AM	HT 1806		0	0.00	Yes	No	0.00	No	NA	NA	Valve Test
	01/15/2016 08:21:05AM	HT 1806		6	85.45	No	No		No	NA	NA	Dynamometer Test
	01/03/2016 10:21:24AM	HT 1806		0	0.00	Yes	No	0.01	No	NA	NA	Valve Test
	01/03/2016 10:17:59AM	HT 1806		3	66.83	No	No		No	NA	NA	Dynamometer Test

la obtención conjunto de datos final. En esta etapa, se aplican técnicas de procesamiento de datos para limpiar, normalizar y consolidar la información extraída, asegurando que los datos sean no solo completos y precisos, sino también coherentes y listos para ser integrados en los modelos predictivos.

3.3.1. Etiquetado del historial de servicios a pozo: Clasificación de fallas a partir de texto en lenguaje natural

Dada la naturaleza del lenguaje natural de los servicios a pozo, se hace necesaria la implementación de un modelo de clasificación para determinar a cuál de los siguientes tipos de evento corresponde cada registro.

- Servicio Mayor: Implica una revisión o reparación extensa que puede requerir un paro operativo del pozo.
- Servicio Menor: Se refiere a mantenimientos rutinarios o ajustes menores que no afectan significativamente la operación del pozo.
- Falla: Indica un evento no planificado que resulta en una disfunción o paro del sistema.

Dado que el problema de clasificación corresponde a un problema de aprendizaje supervisado, es necesario tener un conjunto de datos de entrenamiento correctamente etiquetado. En este caso se etiquetan manualmente 4242 servicios a pozo, de los cuales 1104 corresponden a Servicio, 1812 a Servicio menor, y 1326 a Falla.

Los ejemplos etiquetados se dividen en relación 80:10:10 para entrenamiento, validación y prueba (test) quedando 2649 ejemplos para entrenamiento, 330 para validación, y 330 para prueba. El optimizador utilizado es Adam [26], y la métrica para validación es la exactitud (*accuracy*). Se implementa un *callback* para parar el entrenamiento anticipadamente cuando el modelo no mejora en las últimas 5 iteraciones para evitar sobreajuste o problemas de explosión de gradiente.

Para la clasificación, se utiliza GloVe [42] como vectores de representación de cada palabra (word embeddings), y se prueban tres arquitecturas de modelos diferentes:

- Modelo LSTM: Este modelo secuencial utiliza una capa de *Embedding* seguida de dos capas LSTM con *Dropout*, culminando en una capa *Dense*. Con un total de 520243 parámetros, de los cuales 19043 son entrenables, el modelo destaca por

su habilidad para capturar dependencias temporales en los datos de texto. La arquitectura del modelo se encuentra en la Figura 3-11, y el historial de entrenamiento se encuentra en la Figura 3-12

- Modelo Convolutivo de 3 capas: Este modelo incluye una capa de *Embedding* y tres capas Conv1D, seguidas de *Max Pooling* y capas *Dense* con *Dropout* para un total de 542387 parámetros totales y 41187 entrenables. La arquitectura del modelo se encuentra en la Figura 3-13, y el historial de entrenamiento se encuentra en la Figura 3-14
- Modelo Convolutivo de 2 capas: Similar al modelo anterior, pero con un diseño más ligero, tiene dos capas Conv1D seguidas de *Max Pooling* y capas *Dense* con *Dropout*. Totaliza 532115 parámetros, con 30915 entrenables. La arquitectura del modelo se encuentra en la Figura 3-15, y el historial de entrenamiento se encuentra en la Figura 3-16

Los modelos se evaluaron en términos de tiempo de entrenamiento, tiempo de ejecución en el conjunto de prueba, y métricas como la exactitud (*accuracy*), precisión ponderada y *recall* ponderado. Los resultados se muestran en la Tabla 3-1:

Tabla 3-1: Resultados de los modelos de clasificación de textos de servicios a pozo

Modelo	Parámetros Entrenables	Tiempo de Entrenamiento	Tiempo de Ejecución	Exactitud	Precisión Ponderada	Recall Ponderado
Modelo LSTM	19043	23.7 s	0.6 s	95.45 %	95.48 %	95.45 %
Modelo convolutivo de 3 capas	41187	8.5 s	0.0 s	87.58 %	87.60 %	87.58 %
Modelo convolutivo de 2 capas	30915	8.2 s	0.0 s	88.48 %	88.63 %	88.48 %

El mejor rendimiento en términos de exactitud, precisión y *recall* es obtenido con el modelo LSTM, requiriendo sin embargo más tiempo para entrenarse. Los modelos convolucionales, aunque menos precisos, son significativamente más rápidos tanto en entrenamiento como en ejecución, con el modelo convolutivo de 2 capas ofreciendo una buena relación entre eficiencia y precisión. La Figura 3-17 muestra las matrices de confusión de los tres modelos en paralelo para comparar resultados, a la izquierda el modelo LSTM, en el centro el modelo convolutivo de 3 capas, y a la derecha el modelo convolutivo de 2

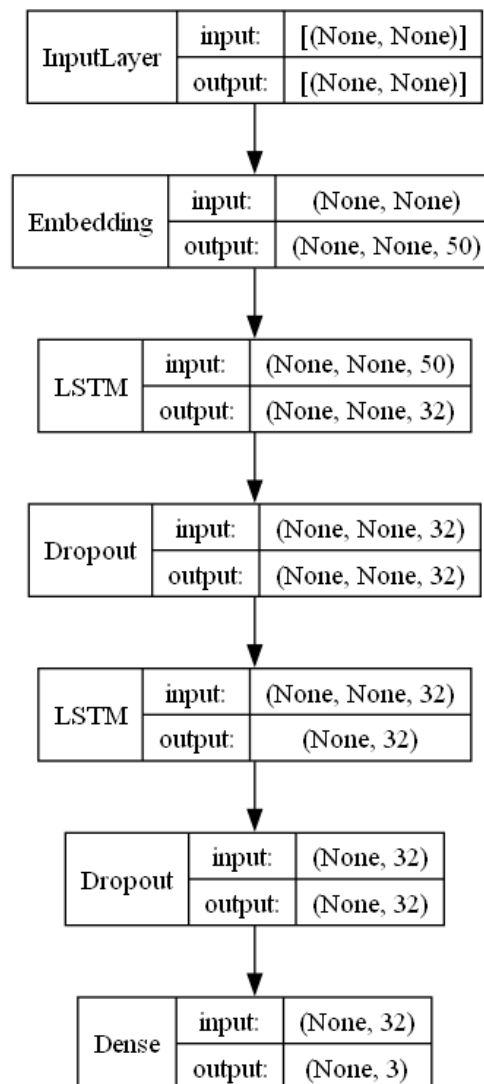
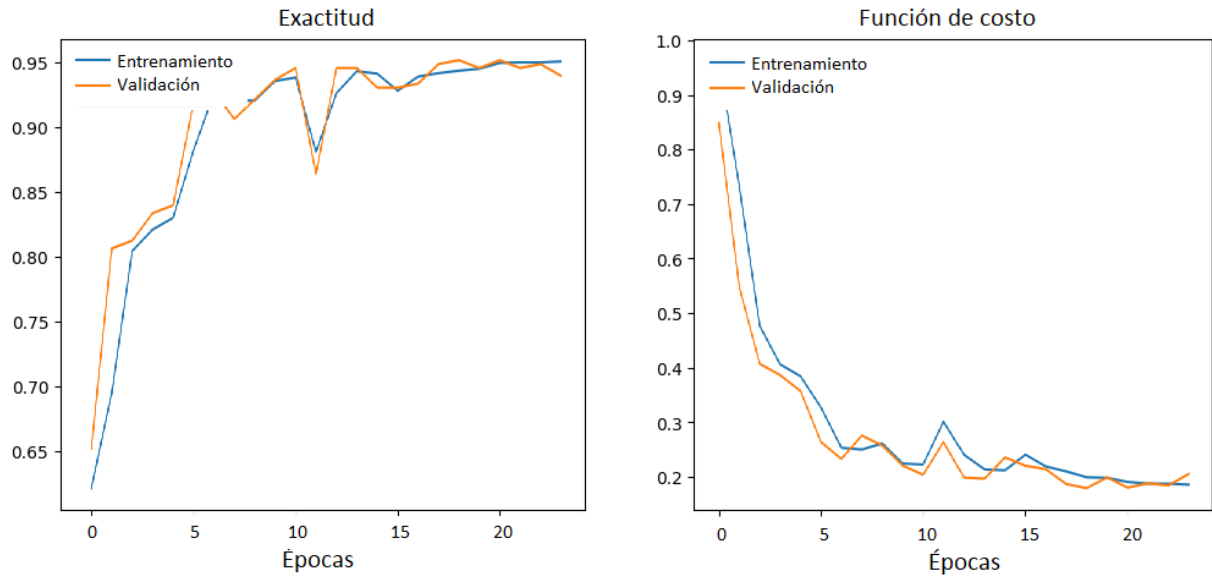
Figura 3-11: Arquitectura del modelo LSTM.

Figura 3-12: Historial de entrenamiento del modelo LSTM.

capas.

Para continuar con el proceso, se toman los datos de fallas proporcionados por el modelo LSTM para clasificar los ejemplos que no se encontraban etiquetados, para un total de 10805 ejemplos de los cuales, de los cuales 2204 correspondieron a Servicio, 5386 a Servicio menor, y 3215 a Falla.

3.3.2. Selección inicial de variables del libro de pruebas y datos numéricos de TWM

En el proceso de preparación de datos del "Libro de Pruebas", es requerida una selección inicial de variables con el objetivo de optimizar la dimensionalidad del conjunto de datos y garantizar la calidad de la información para el análisis. Para ello, se toma la decisión de reducir dimensionalidad don un criterio de eliminación basado en el porcentaje de valores nulos, donde aquellas variables con más del 60 % de sus datos faltantes son descartadas.

La Figura 3-18 muestra el porcentaje de nulos por variable. Las variables que superan el umbral son:

- flopt: Nivel de fluido total sobre la bomba. No se considera una variable crítica dado

Figura 3-13: Arquitectura del modelo convolucional de 3 capas.

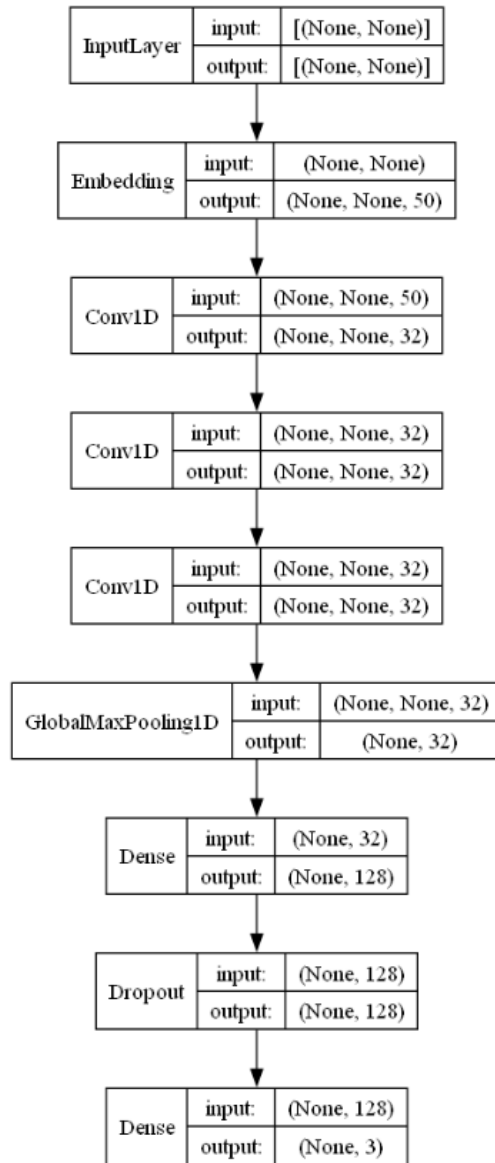



Figura 3-14: Historial de entrenamiento del modelo convolucional de 3 capas.

que la información relevante de esta variable se obtiene con el nivel de líquido (flopI)

- pep: Presión de entrada del fluido a la bomba. Para el sistema de levantamiento por bombeo mecánico la presión de entrada no es una variable crítica, puesto que utiliza una bomba de desplazamiento positivo (bomba de pistón), que a diferencia de las bombas centrífugas y de turbina no dependen de la presión de entrada.
- api: Gravedad API (medida de densidad) del petróleo producido. Esta variable es similar para todos los pozos del campo puesto que producen de la misma roca reservorio.
- gas: Producción de gas. Dado que el campo es de crudo pesado el gas no es un hidrocarburo de interés comercial para este caso.

Esta decisión se fundamenta en la necesidad de evitar la introducción de una cantidad excesiva de información artificial o imputada, lo cual podría distorsionar los resultados del análisis. Es importante destacar que, en este proceso de selección, se verifica que ninguna de las variables eliminadas sea crítica para el entendimiento o la resolución del problema en estudio. De esta manera, se asegura que la eliminación de estas variables no comprometa la integridad ni la relevancia del análisis posterior.

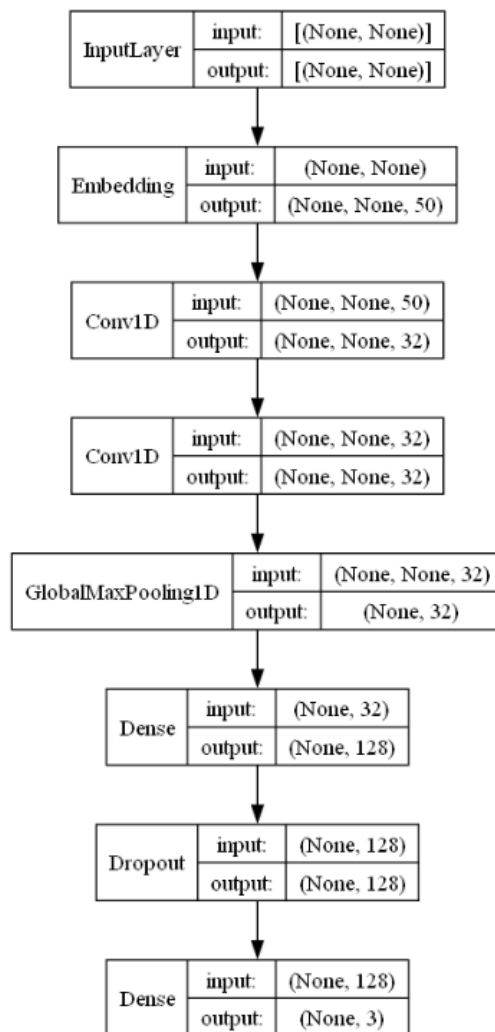
Figura 3-15: Arquitectura del modelo convolucional de 2 capas.

Figura 3-16: Historial de entrenamiento del modelo convolucional de 2 capas.

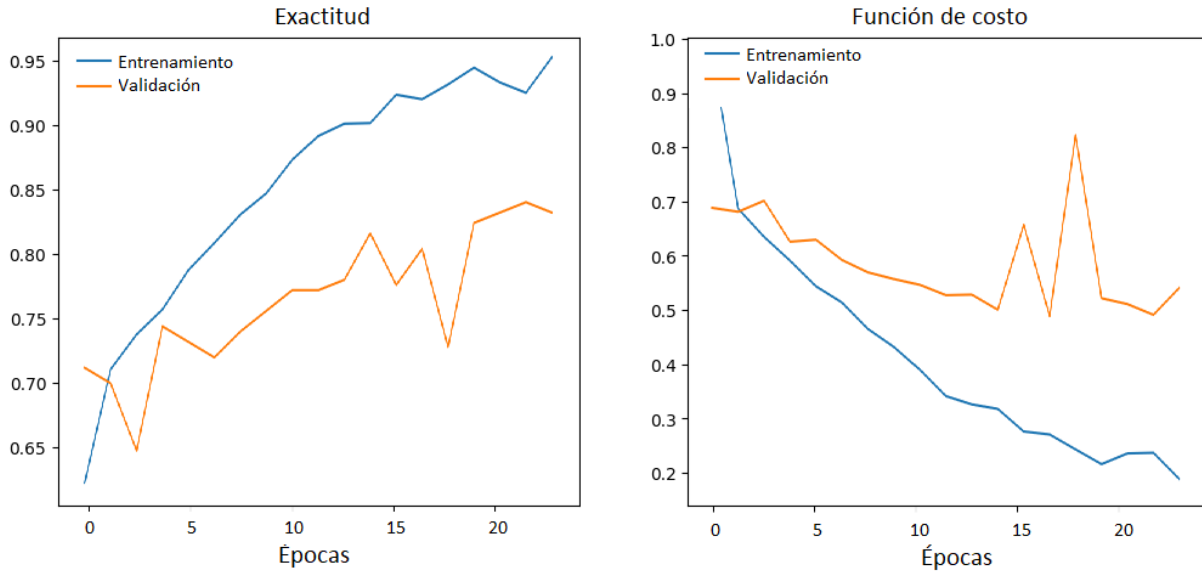


Figura 3-17: Matrices de confusión de los tres modelos en paralelo para comparar resultados.

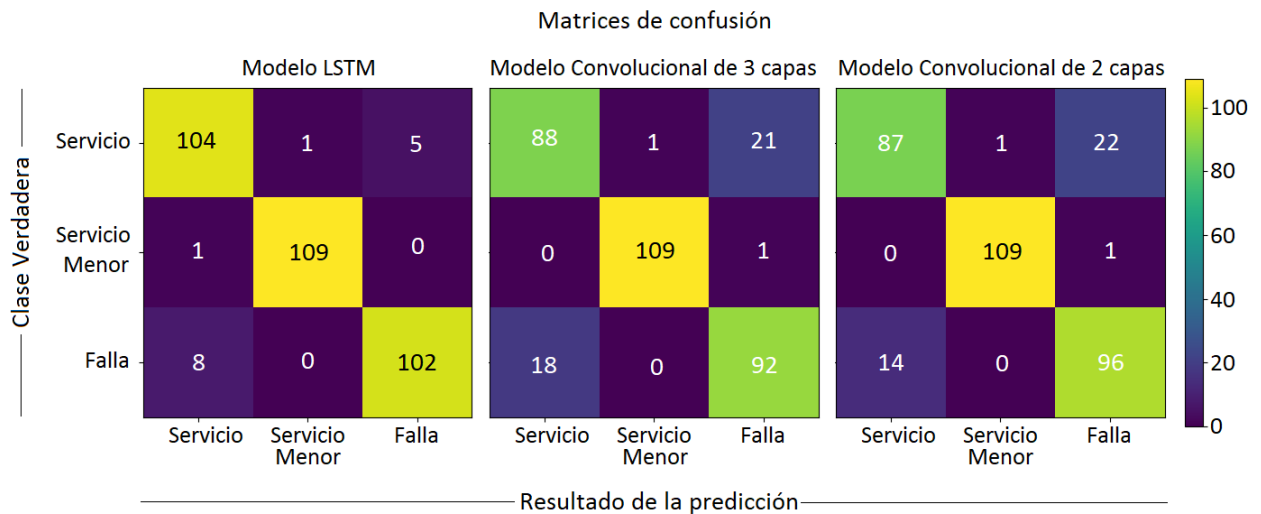



Figura 3-18: Datos nulos por variable. El umbral de aceptación es de 60 % de datos nulos.




La Figura 3-19 muestra el porcentaje de nulos por variable. Las variables que superan el umbral son:

- *Anchor Depth (ft)*: Profundidad del anclaje (en pies).
- *Oil (Bo) (RB/STB)*: Factor volumétrico del petróleo.
- *Water (Bw) (RB/STB)*: Factor volumétrico del agua.
- *Gas (Bg) (RB/Mscf)*: Factor volumétrico del gas.
- *Oil Viscosity (cp)*: Viscosidad del petróleo (centipoises).
- *Water Viscosity (cp)*: Viscosidad del agua (centipoises).
- *Gas Viscosity (cp)*: Viscosidad del gas (centipoises).
- *Polished Rod / Motor Eff. (%)*: Eficiencia de la varilla pulida / motor (porcentaje).
- *Measured Load (Klbf)*: Carga medida (kilo libras fuerza).

Similar al enfoque adoptado para el "Libro de Pruebas", en el conjunto de datos provenientes de la aplicación TWM también se realiza una selección inicial de variables. Siguiendo el mismo criterio, se descartan aquellas variables que presentaban más de un 60 % de

Figura 3-19: Datos nulos por variable. El umbral de aceptación es de 60 % de datos nulos.



valores nulos. En este caso es importante mencionar que todas las variables descartadas presentan más del 90 % de datos nulos, por lo que no contienen información relevante para un análisis de series de tiempo.

Este proceso de filtrado de variables es un paso esencial para mantener la calidad del conjunto de datos. Al excluir las variables con altos porcentajes de datos faltantes, se reduce la necesidad de imputación extensiva, lo que a su vez minimiza el riesgo de introducir errores o asunciones erróneas en el modelo.

3.3.3. Consolidación de información numérica en series de tiempo


Dado que los datos de libro de pruebas y los datos numéricos de TWM tienen una misma modalidad, en el conjunto de datos para elaboración de pronósticos se pueden unir de acuerdo al índice de fecha y pozo. Esto es especialmente útil en el caso de pronósticos de producción, puesto que una arquitectura con muchas modalidades podría generar cuello de botella y por tanto bajo ajuste hacia la modalidad numérica que es la que contiene los datos históricos de la variable a predecir. De manera paralela se genera un conjunto de datos donde se manejaban los datos del libro de pruebas y de TWM como fuentes distintas, el cual es utilizado para los modelos de predicción de fallas puesto que en las pruebas iniciales realizadas muestran un mejor comportamiento. El resultado de la unión de estos datos se presenta en la Figura **3-20**.

Dados los espacios de observaciones sin datos para la variable objetivo que es la producción de petróleo, se toma la decisión de dividir los datos de un mismo pozo en series de tiempo distintas si hay un intervalo de más de cuatro meses sin medición de producción. Para los demás datos nulos, se realiza una imputación de datos, para evitar agregar ceros artificiales al modelo que puedan afectar los pronósticos.

La técnica utilizada para imputación de datos nulos fue la media móvil de una ventana de tiempo de 4 datos en el pasado, esta metodología se utiliza debido a que en la literatura se menciona que es la técnica adecuada para este caso de uso específico [39].

Al realizar la división, de un total de 258 pozos con datos de series de tiempo se obtienen 529 series, las cuales, para poder realizar pruebas, se filtran únicamente las series de

Figura 3-20: Ejemplo de los datos de libro de pruebas y TWM para un pozo.



tiempo que tienen más de 48 observaciones, con lo que al final se obtienen 366 series de tiempo para realizar las pruebas.

3.3.4. Imputación de datos nulos en variables numéricas

La imputación de datos nulos en variables numéricas es un paso crítico en el preprocesamiento de datos, especialmente en conjuntos de datos con registros temporales como los del "Libro de Pruebas" y la aplicación TWM. Para abordar este desafío, se utiliza la técnica de media móvil, utilizada por [38] y [6], que permite reemplazar los valores nulos con un promedio calculado a partir de los datos disponibles más recientes. Este método es seleccionado por su capacidad para preservar la tendencia y la coherencia temporal de los datos.

La imputación por media móvil se realiza considerando los últimos 4 pasos de tiempo. Esto implica que cada valor nulo en una serie temporal se reemplaza por el promedio de los 4 valores anteriores no nulos.

$$x_t = \frac{\sum_{i=1}^4 x_{t-i}}{4} \quad (3-1)$$

Matemáticamente, la imputación para un valor nulo en el tiempo se define en la Ecuación 3-1. Esta fórmula garantiza que los valores imputados reflejen de manera más precisa la tendencia reciente de los datos, manteniendo la coherencia con las observaciones adyacentes y reduciendo la distorsión que podría introducir una imputación más arbitraria.

Esta técnica de imputación es particularmente adecuada para series temporales en el contexto de datos de producción petrolera [39], donde los patrones temporales y las tendencias son fundamentales para un análisis preciso y significativo.

3.3.5. Primera estructuración de ejemplos para clasificación de series de tiempo con todas las fuentes de datos independientes

Para la primera exploración en modelos multimodales para clasificación de series de tiempo se toman las cuatro fuentes de datos por separado como una modalidad independiente, reduciendo la granularidad de la serie de tiempo a periodicidad mensual tomando el

promedio de los valores numéricos y la primera imagen de dinagramas y pruebas de válvula existente para cada mes.

Debido al desbalanceo de clases, se realiza un muestreo estratificado de los ejemplos negativos para falla mediante la selección de estos dentro de cada serie de acuerdo con el número de ejemplos positivos que presenta, asegurándose de que los ejemplos estén igualmente separados entre sí. Para la clase positiva se hace un muestreo aleatorio simple con reemplazo para aumentar la cantidad de ejemplos positivos, garantizando que todos los ejemplos positivos se encuentren al menos una vez en el conjunto de datos final. De esta manera se garantiza que se cuente con igual número de ejemplos positivos que negativos, y que los ejemplos negativos representen el comportamiento general de la serie mejor que un muestreo aleatorio simple.

El resultado de esta primera aproximación presenta un conjunto de 1226 ejemplos balanceados para clasificación binaria de las series de tiempo, y un total de 15281 ejemplos sin balanceo (613 positivos y 14668 negativos).

3.3.6. Reducción de dimensionalidad y normalización

De cada una de las series de tiempo se extraen las últimas 24 posiciones para realizar pruebas en los modelos realizados. Estos datos no son tenidos en cuenta ni en la normalización, ni en el análisis de componentes principales (PCA), con el objetivo de evaluar finalmente el modelo de producción simulando una aplicación real donde no se conocen los valores futuros.

Para la normalización de los datos, se emplea normalización estándar (ver Ecuación 3-2) para ajustar las variables numéricas a una media de cero (μ) y una desviación estándar (σ) de uno. Esto se realiza para cada variable y para cada serie de tiempo (ts).

Si bien en la literatura se plantea el uso de *autoencoders* como una técnica robusta para llevar las distintas fuentes de datos a una representación conjunta, que además es utilizada para reducción de dimensionalidad, se toma la decisión de no utilizarla en este caso de uso por no contar con una cantidad de datos suficiente que permita que el modelo de *autoencoders* se ajuste para lograr una adecuada representación de los mismos.

$$x_{\text{normalizado}} = \frac{x - \mu_{ts}}{\sigma_{ts}} \quad (3-2)$$

En cuanto a la reducción de dimensionalidad, se consideran dos enfoques:

Selección Basada en Juicio de Expertos: Se seleccionan las siguientes 15 variables identificadas como las más relevantes para el análisis de los pozos petroleros:

- *qo*: Producción de petróleo. Se selecciona debido a que es la variable a predecir.
- *qt*: Producción total. Se selecciona debido a que involucra la producción de agua, lo que tiene implicaciones tanto en el volumen de crudo producido como en la probabilidad de falla.
- *bsw*: Contenido de agua y sólidos en el petróleo. Se selecciona porque un alto contenido de sólidos puede afectar el funcionamiento de la válvula.
- *flop*: Nivel de líquido sobre la bomba. Se selecciona debido a que un bajo nivel de líquido sobre la bomba puede dar lugar a que en algún momento el nivel de fluido baje lo suficiente como para aumentar la producción de gas y disminuir la producción de petróleo.
- *fp*: Porcentaje de llenado de la bomba. Variable directamente relacionada con el funcionamiento de la bomba.
- *thp*: Presión en la cabeza del pozo. Variable directamente relacionada con el funcionamiento del sistema.
- *chp*: Presión en el *casing* del pozo. Variable directamente relacionada con el funcionamiento del sistema.
- *salt*: Salinidad. Se selecciona porque un alto contenido de sal puede afectar el funcionamiento del sistema por corrosión.
- *MPMPL (lb)*: Carga máxima en la mitad del ciclo de la varilla pulida. Variable directamente relacionada con el funcionamiento del sistema y con los dinagramas.
- *PPMPL (lb)*: Carga pico en la mitad del ciclo de la varilla pulida. Variable directamente relacionada con el funcionamiento del sistema y con los dinagramas.

- *MPRL (lb)*: Carga máxima de la varilla pulida. Variable directamente relacionada con el funcionamiento del sistema y con los dinagramas.
- *PPRL (lb)*: Carga pico en la varilla pulida. Variable directamente relacionada con el funcionamiento del sistema y con los dinagramas.
- *Pump Displacement (BBL/D)*: Desplazamiento de la bomba. Variable directamente relacionada con la producción.
- *Pump Volumetric Fillage (%)*: Relleno volumétrico de la bomba. Se selecciona debido a que un bajo porcentaje de llenado afecta la producción.
- *Unaccounted Friction (lb)*: Fricción no contabilizada. Se tiene en cuenta debido a que la fricción genera desgaste del sistema lo que da lugar a ruptura de componentes y mal funcionamiento.

Análisis de Componentes Principales (PCA): La aplicación de PCA en este contexto mostró los siguientes resultados:

- Con 10 Variables: Al seleccionar las primeras 10 componentes principales, se logra explicar aproximadamente el 66 % de la varianza total de los datos. Los resultados se muestran en la Figura **3-21**.
- Con 20 Variables: Al aumentar el número de componentes a 20, la varianza explicada subió al 85.9 %. Los resultados se muestran en la Figura **3-22**.
- Con 30 Variables: La selección de 30 componentes principales permitió explicar hasta el 94.9 % de la varianza total. Esta opción proporciona una representación completa de los datos originales, con una pérdida de únicamente el 5 % de la varianza. Los resultados se muestran en la Figura **3-23**.

Estos resultados indican cómo el PCA puede ser ajustado para equilibrar entre la simplificación de los datos y la retención de la información clave. En este caso se selecciona el modelo de 30 variables dado que explica aproximadamente el 95 % de la varianza.

3.3.7. Elaboración del conjunto de datos final

En la fase de elaboración del conjunto de datos final, se realiza un procesamiento específico para las imágenes de dinagramas y pruebas de válvula, así como para la consolidación

Figura 3-21: Aplicación de PCA para los datos de series de tiempo numéricas con reducción a 10 variables.




Figura 3-22: Aplicación de PCA para los datos de series de tiempo numéricas con reducción a 20 variables.





Figura 3-23: Aplicación de PCA para los datos de series de tiempo numéricas con reducción a 30 variables.




de los datos numéricos.

Las imágenes de dinagramas y pruebas de válvula se cargan como matrices de un solo canal. Para mejorar la visualización y el análisis de estas imágenes, se invierten los valores de los píxeles: los unos y ceros se intercambiaron de modo que los unos representen la figura. Esta inversión resulta en imágenes donde los dinagramas y las pruebas de válvula se destacan claramente sobre un fondo negro (ver Figura 3-24), facilitando su interpretación y análisis en estudios posteriores que utilicen modelos de procesamiento de imágenes. Para los casos donde no existe la imagen, la entrada del modelo será una matriz de ceros.

Se conforman dos conjuntos de datos distintos, cada uno adaptado a un propósito de análisis específico:

- **Conjunto de Datos con Granularidad Completa:** Este conjunto incluye todas las mediciones disponibles, manteniendo la granularidad original de los datos. La Figura 3-25 muestra una serie de tiempo final con todos los tipos de datos normalizados y sin normalizar.
- **Conjunto de Datos de Periodicidad Mensual:** Para este conjunto, se realiza un promedio de las variables numéricas existentes en cada mes. Además, se selecciona

Figura 3-24: Representación final de un dinagrama a la izquierda y una prueba de válvula a la derecha.



la primera imagen de dinagrama y la primera imagen de prueba de válvula disponibles para cada mes. Este enfoque reduce la granularidad de los datos a una escala mensual. La Figura 3-26 muestra una serie de tiempo mensual con todos los tipos de datos normalizados y sin normalizar.

3.3.8. Construcción de ejemplos con ventanas de tiempo para entrenamiento de redes neuronales

Para todos los ejemplos se establecen y almacenan las variables independientes:

- Variables numéricas resultado del preprocesamiento normalizadas, sin normalizar, y resultado de PCA.
- Imágenes de dinagramas para cada medición
- Imágenes de pruebas de válvula para cada medición

En el caso de las variables a predecir, para el caso de predicción de fallas relacionado con el área de clasificación de series de tiempo, se tiene que la clase positiva será para aquellos ejemplos donde en el siguiente paso del tiempo se presente una falla, y negativo para todos los demás. Para los pronósticos, se toma la producción de petróleo como la variable a predecir, y se normaliza con el normalizador estándar ajustado a la serie de

Figura 3-25: Ejemplo de serie de tiempo con granularidad completa y todas las fuentes de datos cargadas.

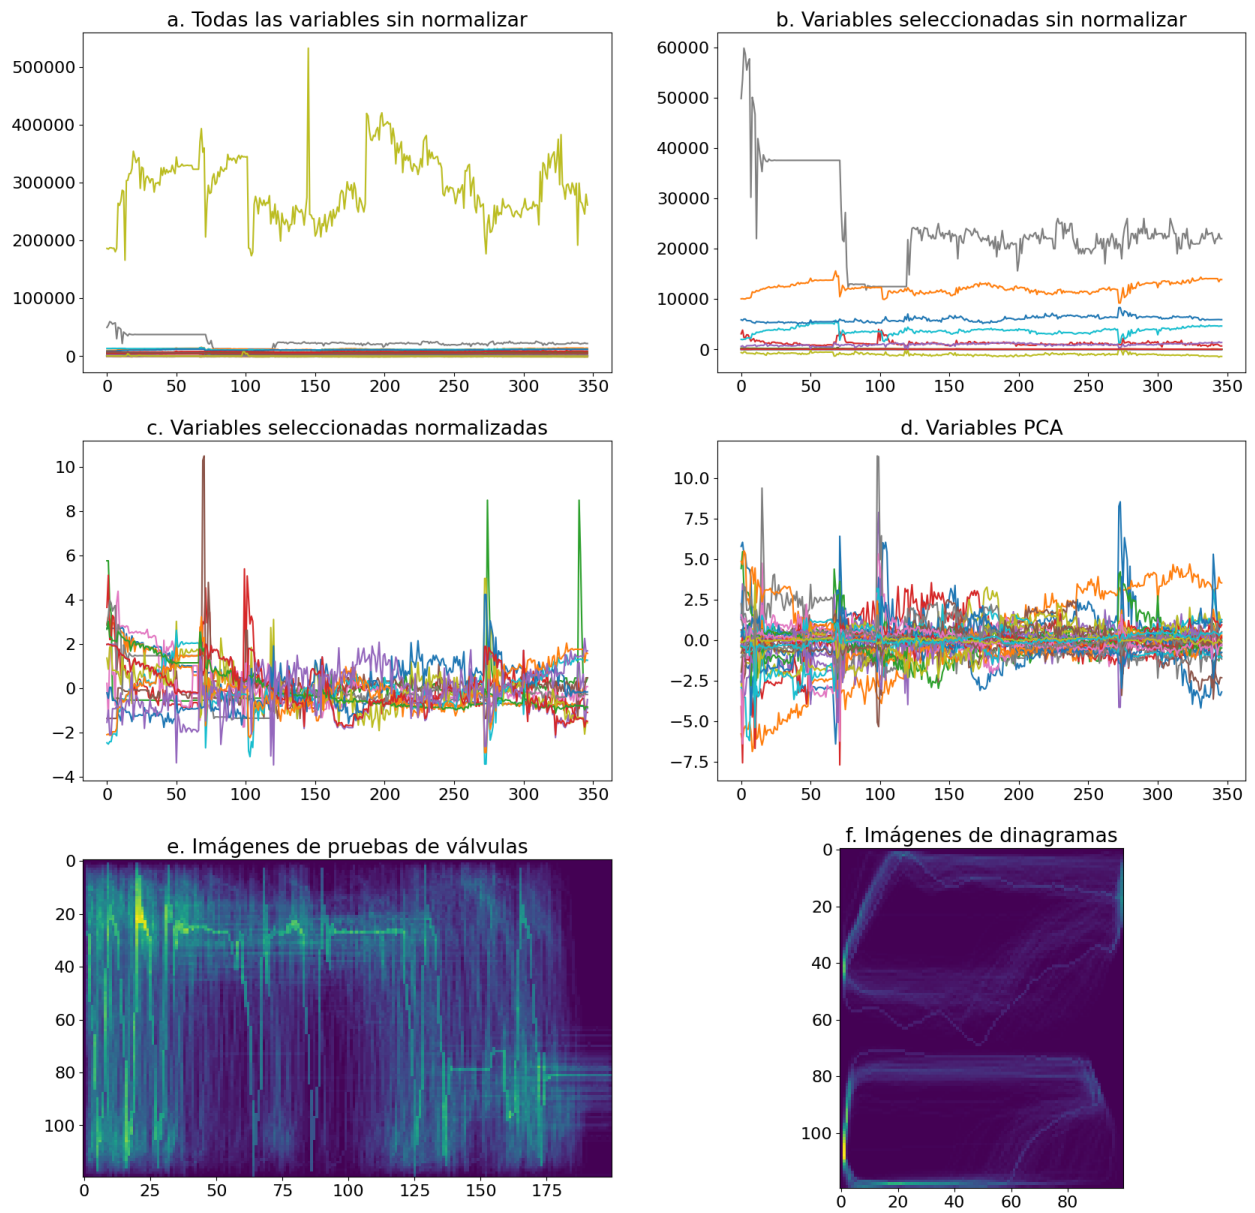
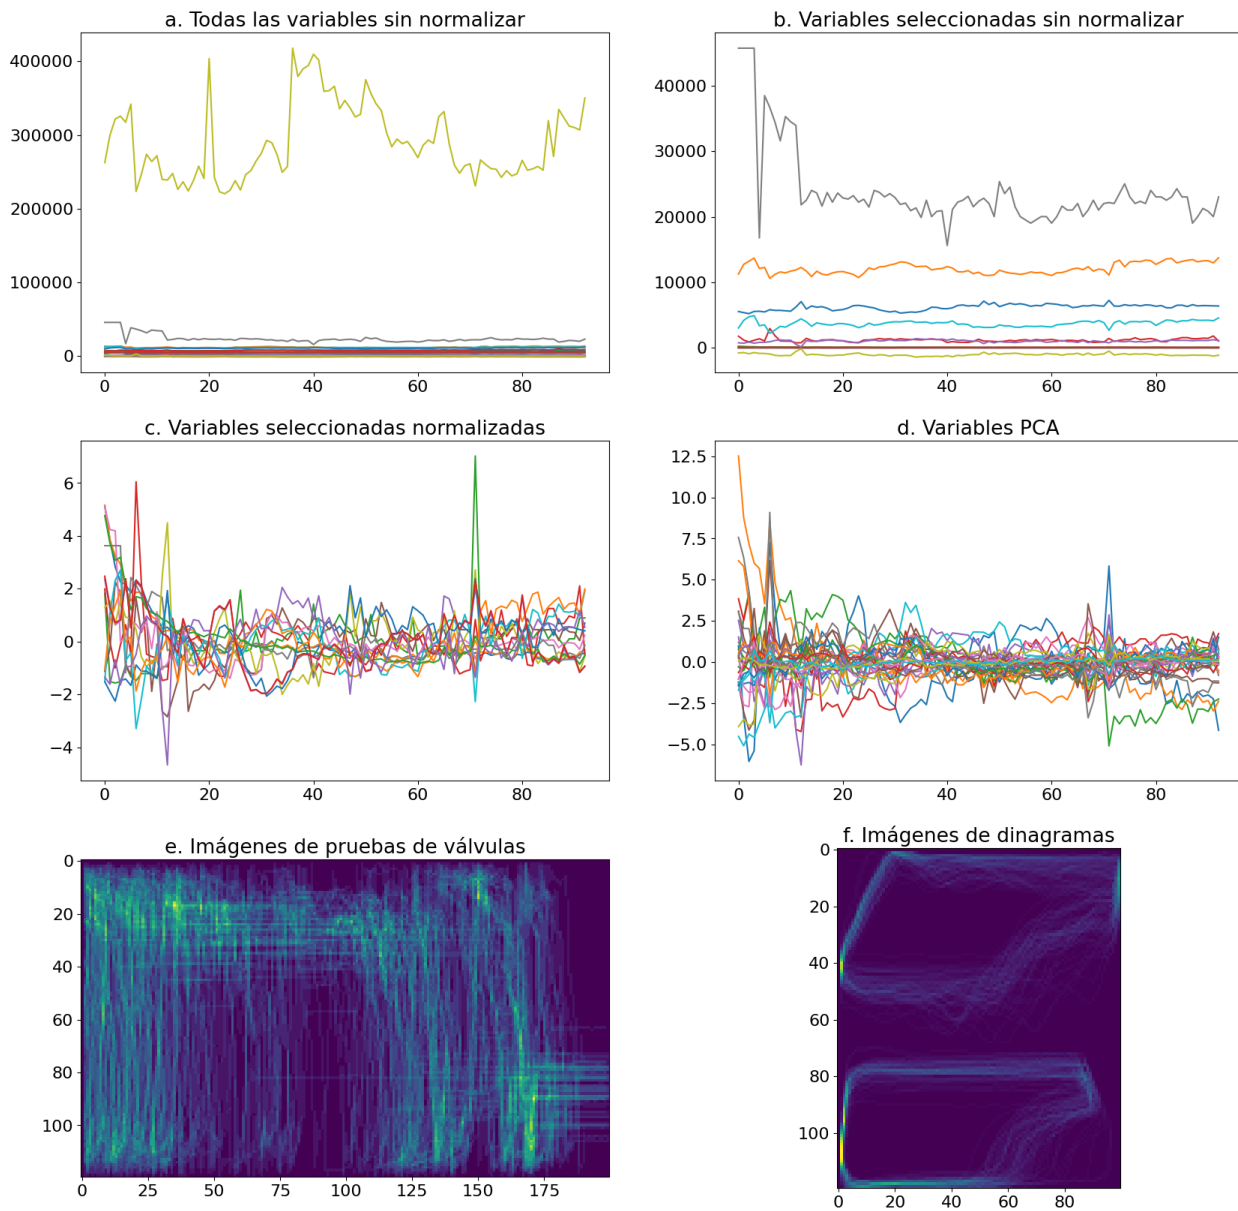


Figura 3-26: Ejemplo de serie de tiempo con granularidad mensual y todas las fuentes de datos cargadas.



tiempo.

Se establece una malla de ejemplos en cuanto a ventana de pasos de tiempo a revisar para pronosticar, y pasos en el futuro de la variable a predecir que se muestra en la Tabla 3-2

Tabla 3-2: Número de ejemplos realizados para la serie con granularidad original

Ventana	Pasos a predecir	Número ejemplos serie completa	Numero de ejemplos serie mensual
6	3	56872	10484
12	6	54560	9136
24	6	51508	7372
36	6	48634	5837
24	12	50051	6555
36	12	47259	5267
36	24	44598	4322

Los ejemplos finales para entrenamiento de los modelos se almacenan con las variables sin normalizar, normalizadas, las variables de PCA, y también se incluyen imágenes superpuestas de los dinagramas y pruebas de válvula. La Figura 3-27 muestra un ejemplo para la serie de tiempo con la máxima granularidad, y la Figura 3-28 muestra un ejemplo para la serie de tiempo mensual.

3.4. Estrategia de fusión de datos multimodales

En cuanto a la estrategia de fusión de datos multimodales, se adopta una metodología híbrida entre la fusión temprana y la fusión tardía, donde los datos multimodales entran al modelo por separado, y se procesan en capas independientes dependiendo del tipo de dato de entrada, y luego se concatenan las salidas para ser procesadas conjuntamente por las siguientes capas del modelo, con lo que la fusión de datos se da al interior del modelo. Esta metodología será ampliada en los siguientes capítulos.

3.5. Discusión de resultados

En este capítulo se presenta el proceso detallado de preprocesamiento de las distintas fuentes de información relacionadas con la producción de petróleo, dando como resultado

Figura 3-27: Ejemplo para entrenamiento de modelos con granularidad original con un tamaño de ventana 36 para predecir 12 pasos de tiempo en el futuro.

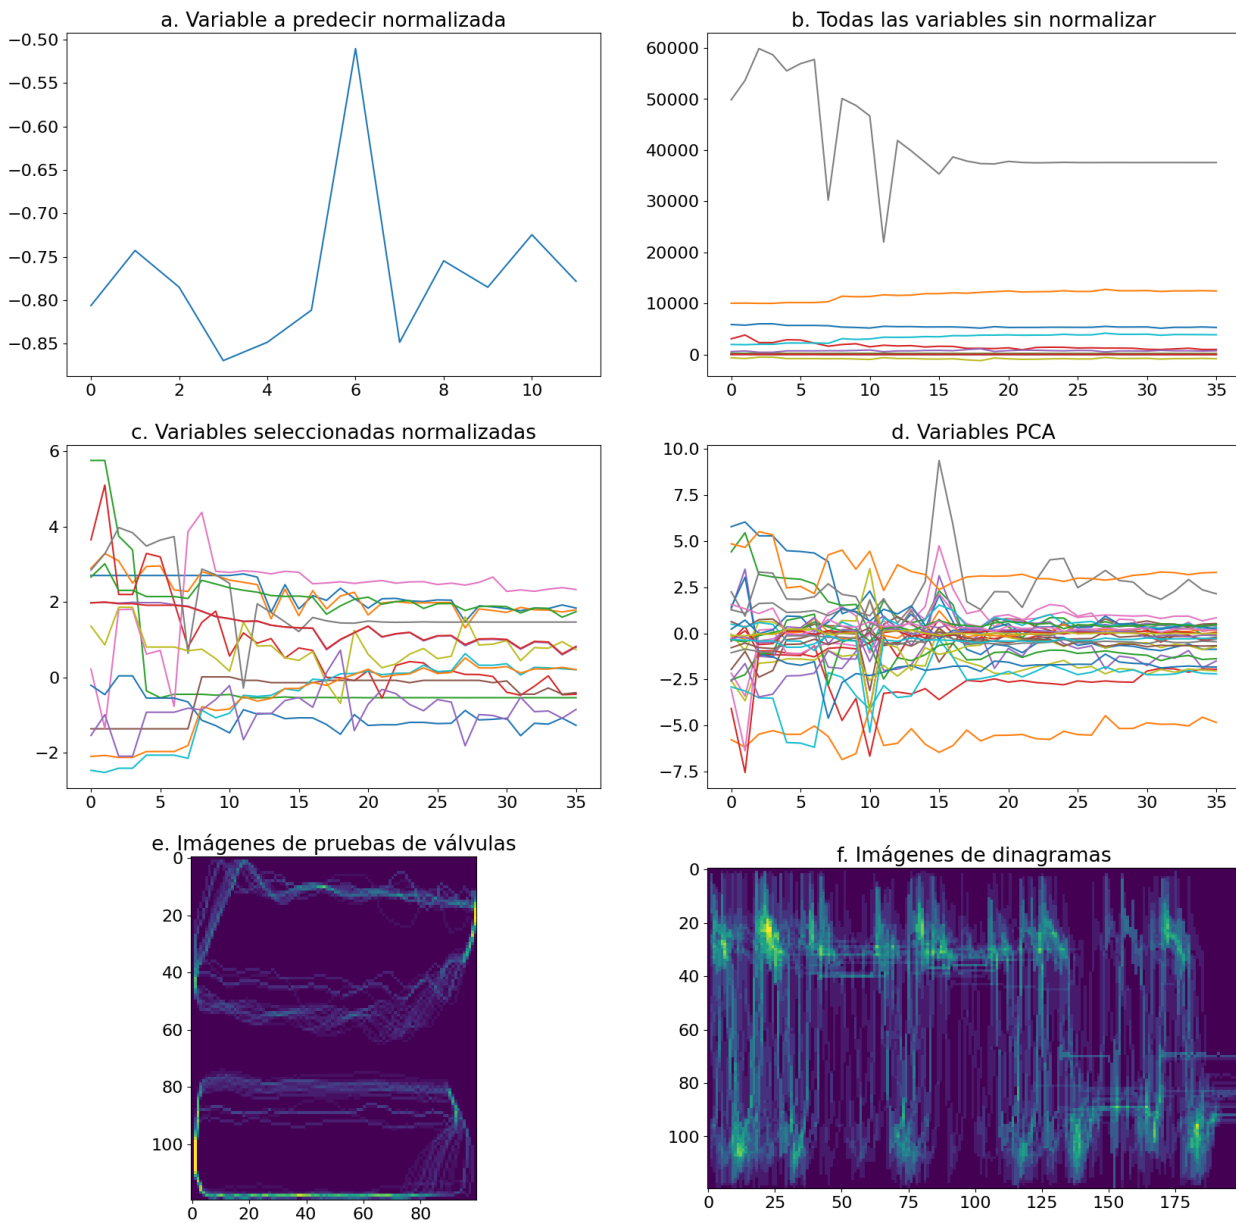
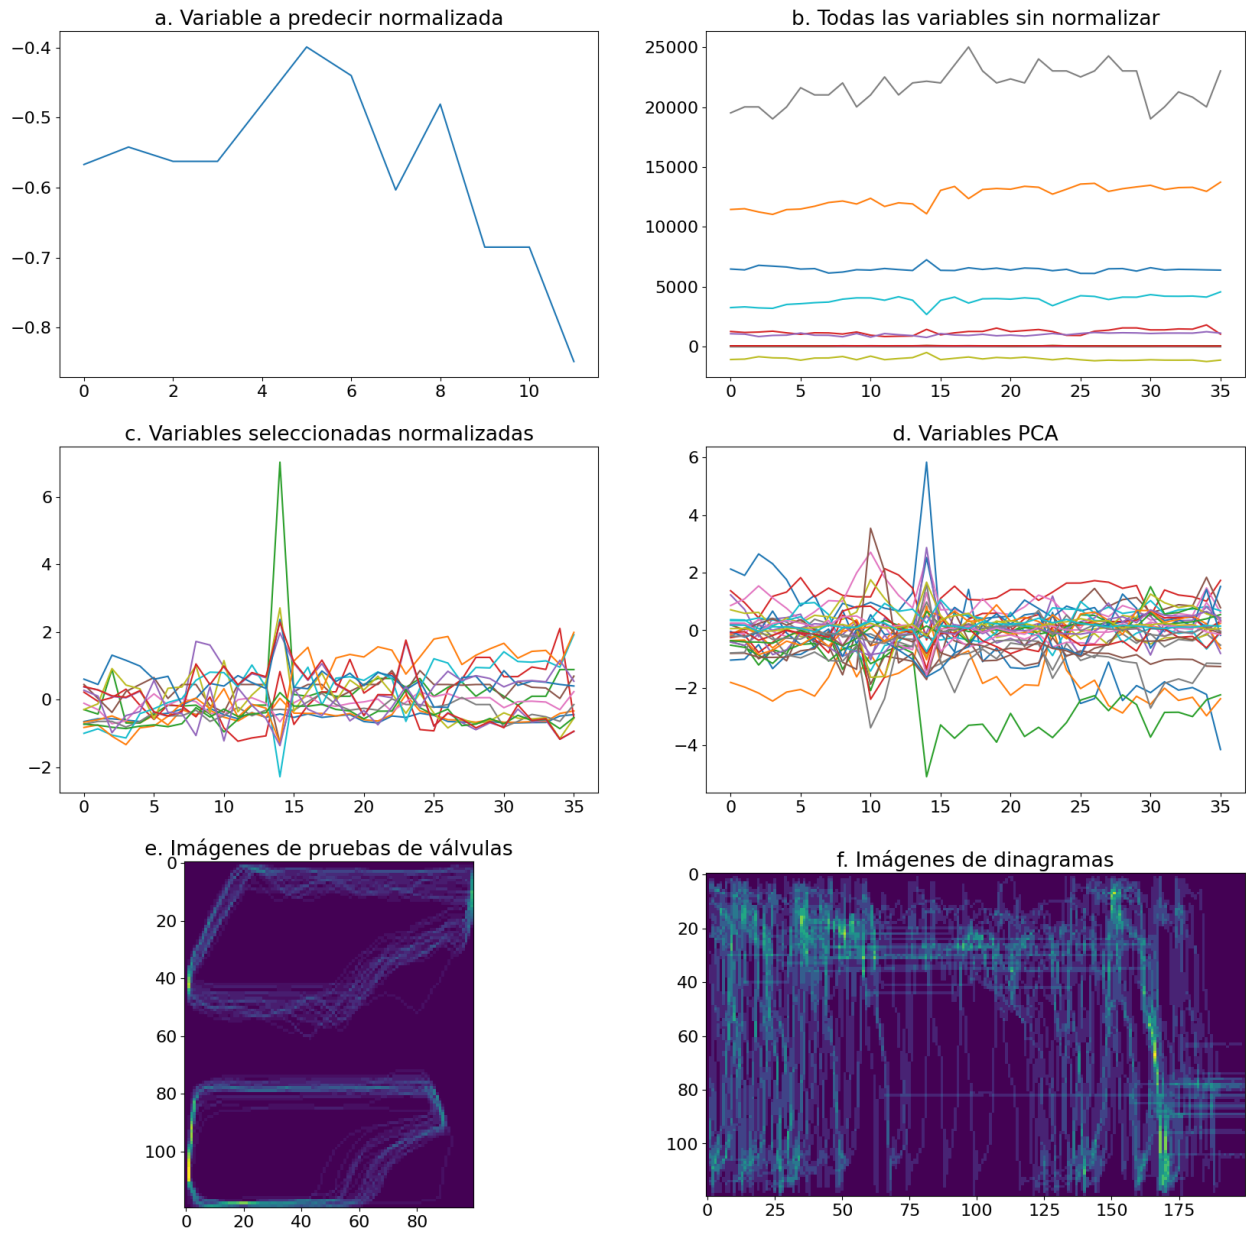


Figura 3-28: Ejemplo para entrenamiento de modelos con granularidad mensual con un tamaño de ventana 36 para predecir 12 pasos de tiempo en el futuro.



un conjunto de series de tiempo multimodales que es útil para predecir las fallas en el siguiente paso del tiempo, lo que constituye un problema de clasificación de series de tiempo multimodales (MMTSC) y para elaborar pronósticos de producción, que se clasifica como un problema de pronóstico de series de tiempo multimodales (MMTSF).

4 Modelo de predicción de fallas mediante clasificación de series de tiempo multimodales

El problema que se aborda en este capítulo es la predicción de fallas en pozos petroleros con bombeo mecánico, que se engloba dentro del área de clasificación de series de tiempo, incluyendo la multimodalidad dentro de la serie de tiempo. Para esto se elaboran algunos modelos con un *encoder* multimodal distribuido en el tiempo que permite llevar cada paso del tiempo a una representación conjunta para luego pasar por una serie de tiempo recurrente y finalmente realizar la predicción.

Los modelos presentados se encuentran implementados en TensorFlow [1], y son entrenados en una estación de trabajo con las siguientes especificaciones:

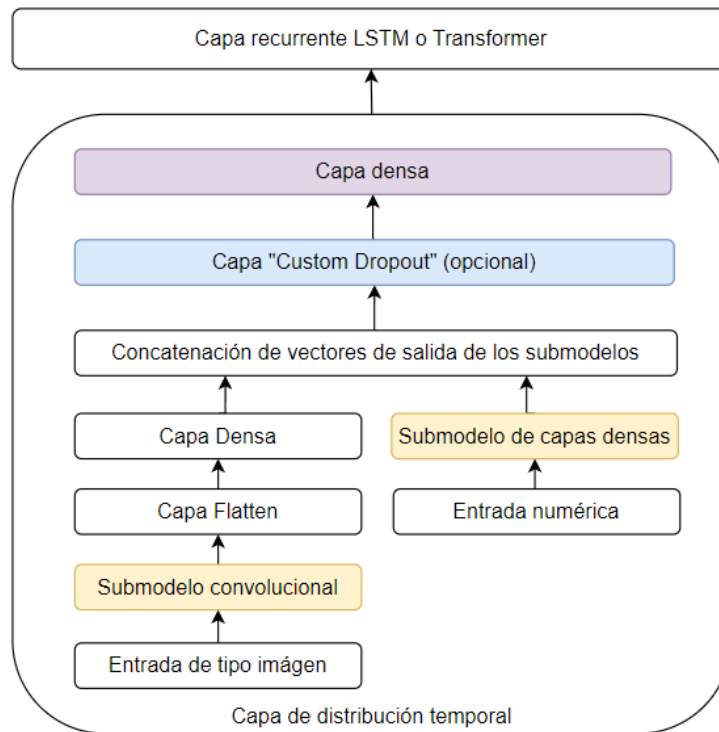
- CPU: Dual Intel XEON E263v3 con 16 núcleos físicos, y 32 virtuales.
- RAM: 40 GB DDR4 Memoria física, 80 GB Memoria virtual (paginación en disco)
- GPU: Nvidia 980 TI con 6 GB de vRAM
- Sistema operativo: Windows 10
- versión de Python: 3.10.11

4.1. Arquitectura de encoder propuesta para procesar los datos secuenciales multimodales

Con el objetivo de realizar un modelo completo que reciba como entradas los datos de series de tiempo multimodales y pueda aprender tanto características específicas de cada

entrada, como las relaciones entre ellas, se propone una arquitectura de *encoder* multimodal distribuido en el tiempo que recibe los datos mediante múltiples capas de entrada, y procesa cada entrada por separado mediante capas intermedias del tipo adecuado para la fuente de datos, esto es, capas densas para datos numéricos, capas convolucionales para imágenes, capas de atención o basadas en *Transformers* para el texto. La salida de cada submodelo debe ser igual a la de las otras modalidades para evitar que una entrada pese más que otra.

Figura 4-1: Modelo multimodal para procesar información de distintas fuentes en cada paso del tiempo.



Las salidas de cada submodelo se concatenan en un vector unidimensional que ingresa a una capa densa que es responsable de realizar una transformación no lineal adicional que permita la integración de las características derivadas de cada modalidad. Desempeña un papel fundamental en permitir que el modelo aprenda patrones complejos de cada fuente de datos para resolver el problema específico para el que se está entrenando. La Figura 4-1 muestra la arquitectura de este submodelo multimodal. De esta manera se completa una estrategia de fusión de datos híbrida, donde si bien los datos de cada modalidad ingresan al modelo de forma independiente y son procesados en capas espe-

cializadas para cada tipo de dato, al ser concatenadas y procesadas por la capa densa, ingresan a las siguientes capas del modelo como una representación conjunta, es decir, la fusión de datos ocurre al interior del modelo.

Dado que las entradas contienen datos con componente temporal, con el objetivo de capturar la información de cada fuente sin perder esta componente, el submodelo multimodal se encuentra dentro de una capa de distribución temporal que permite procesar los datos multimodales un paso de tiempo a la vez, y conservar el componente temporal para ser utilizado por una capa recurrente como se muestra en la Figura 4-2. En el modelo propuesto, la capa recurrente es una capa LSTM pero es reemplazable por cualquier capa que analice datos secuenciales como en el caso del presente trabajo donde se incluye un *transformer encoder*. La importancia de que la capa final sea reemplazable por un *transformer* consiste en que para trabajos futuros donde se cuente con una mayor cantidad de datos, el entrenamiento sobre una arquitectura de redes neuronales con *transformers* puede ser más rápido, y los resultados pueden ser mejores de acuerdo con el potencial que se observa en el estado del arte.

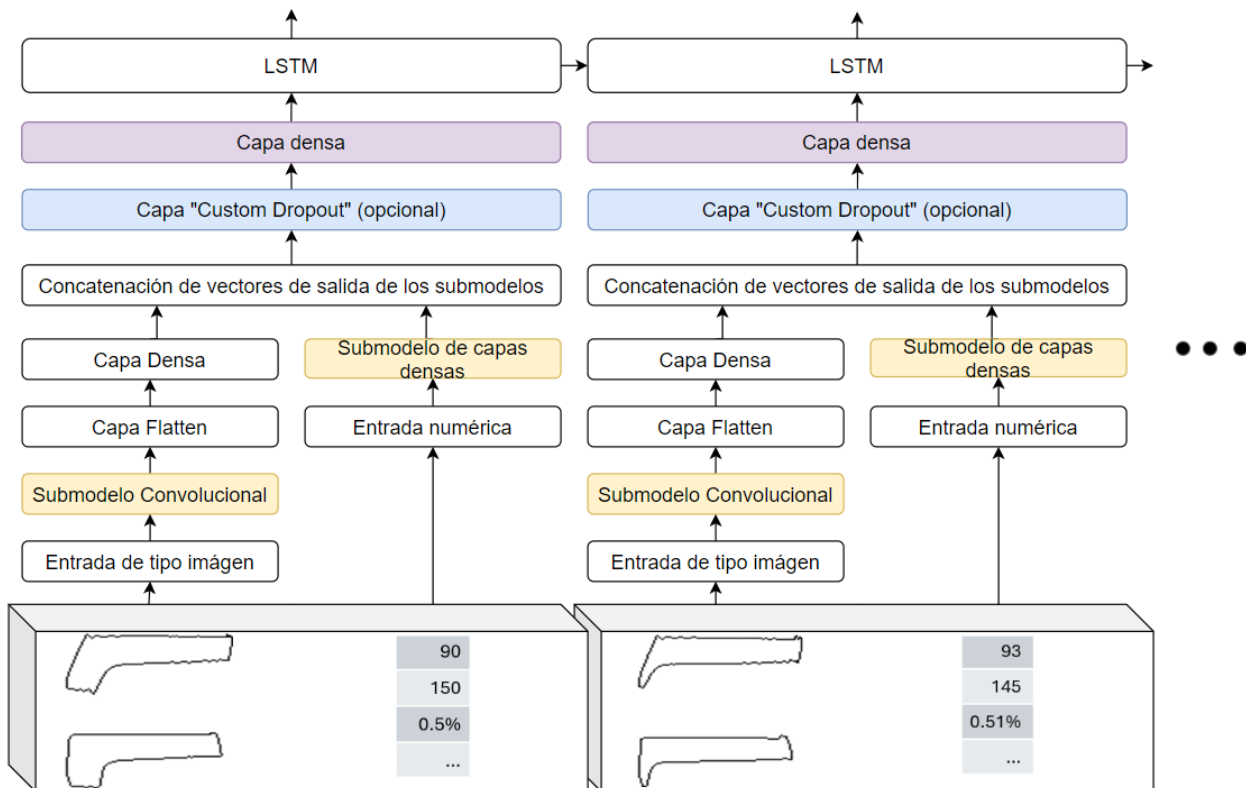
De manera alternativa se propone una capa llamada "*Custom dropout*" que recibe una entrada que le indica qué modalidad existe para ese paso de tiempo, y permite apagar las capas de salida de los submodelos asociados a las modalidades no existentes multiplicando la salida de los submodelos correspondientes por cero, lo cual desactiva el submodelo en el momento de *Feed forward*, y también en el *Backpropagation* como se muestra en la Ecuación 4-1 para el caso de la función de activación sigmoide. Esta capa requiere que las funciones de activación de las capas inmediatamente anteriores sean sigmoide o ReLu, puesto que para estas dos funciones cuando $a(z) = 0$, $a'(z) = 0$

$$\frac{dE}{da} = -(y - a) \quad \frac{dE}{dz} = \frac{dE}{da} \cdot \frac{da}{dz} \quad \frac{da}{dz} = a(1 - a) \quad (4-1)$$

4.2. Modelos de clasificación sobre datos balanceados

La primera aproximación para la predicción de fallas mediante clasificación de series de tiempo se realiza sobre los datos balanceados preprocesados en la sección 3.3.5 con una subdivisión de los datos en proporción 70:20:10 (70 % para entrenamiento, 20 % para validación y 10 % para pruebas), realizando el entrenamiento sobre 858 ejemplos, la

Figura 4-2: Modelo multimodal distribuido temporalmente para procesar información de series de tiempo multimodales.



validación sobre 244 ejemplos y las pruebas (*test*) sobre 124 ejemplos, todos ellos balanceados.

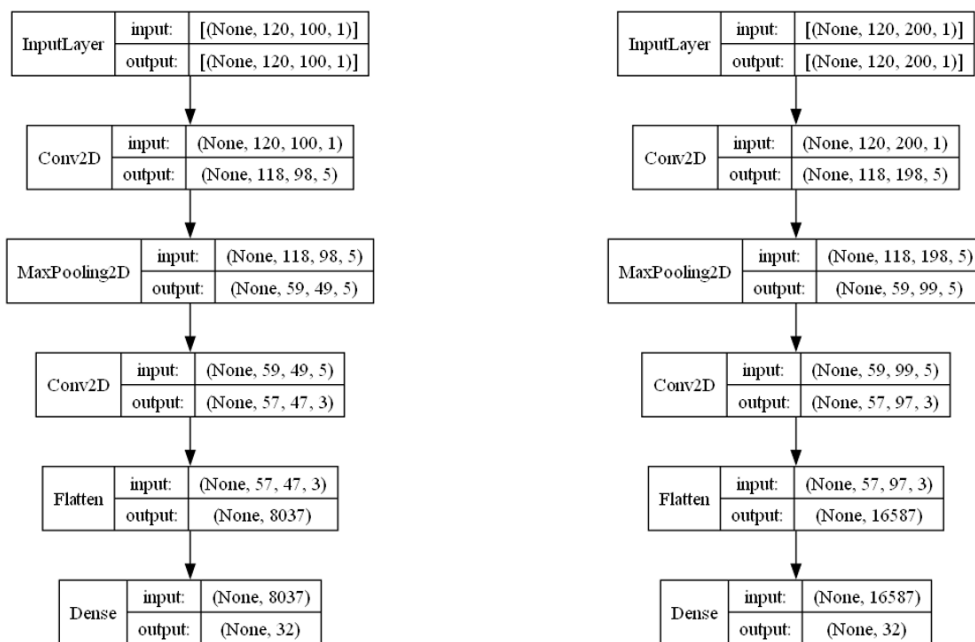
4.2.1. Mododelo multimodal

Para los datos de series temporales estructurados, contenidos en los conjuntos de datos de pruebas de producción y datos de sensores, se emplean capas densas. Cada submodelo se compone de una capa de entrada *InputLayer*, seguido de una capa densa *DenseLayer* con función de activación sigmoide de 4 unidades. Estos submodelos están diseñados para llevar los datos de entrada de alta dimensión en un espacio de características de menor dimensión que retiene patrones críticos relevantes para la predicción. Para pruebas de producción, el modelo tiene 56 parámetros entrenables con una entrada de 13 posiciones, mientras que para datos de sensores tiene 148 parámetros entrenables dada su entrada de 36 posiciones.

Para los datos de imágenes de dinagramas y pruebas de válvula se utilizan Redes Neuronales Convolucionales (CNN). Cada CNN consta de una capa de entrada *InputLayer* con las dimensiones del tipo de imagen que va a procesar, una serie de dos capas convolucionales *Conv2d* con activaciones ReLU para la extracción de características, emparejadas con una capa de *MaxPooling* seguido de una capa *Flatten* para convertir la salida de la red en un vector de una dimensión y una capa densa *DenseLayer* al final. Estas CNN transforman los píxeles de la imagen en una representación compacta e informativa extrayendo características visuales. El modelo tiene 112 parámetros entrenables para dinagramas y 120 para pruebas de válvula. La salida de cada submodelo es un vector unidimensional de 4 posiciones. La Figura muestra los submodelos convolucionales empleados.

Para sintetizar la información de todas las modalidades, las salidas de los submodelos se concatenan en un vector de características unificado de 16 posiciones. Este vector contiene la información para un paso de tiempo. Esta salida concatenada se dirige luego a una capa *DenseLayer* con 8 unidades que captura las relaciones entre cada una de las secciones del vector concatenado, sirviendo como un paso crucial en la arquitectura del modelo. Esta capa densa *DenseLayer* es responsable de una transformación no lineal adicional e integración de las características derivadas de cada modalidad. Desempeña un papel fundamental en permitir que el modelo aprenda patrones complejos y relaciones entre las modalidades que son predictivas del resultado objetivo. Este submodelo multi-

Figura 4-3: Submodelos convolucionales para procesar las entradas de datos de tipo imagen.



modal se presenta en la Figura 4-4. De manera adicional, la arquitectura que incluye la capa "custom dropout" se encuentra en la Figura 4-5, sin embargo, para este caso específico la capa *custom dropout* no generó cambios en el comportamiento del modelo.

Figura 4-4: Submodelo multimodal que procesa los datos para cada paso de tiempo. Las capas *Sequential* corresponden a los submodelos convolucionales usados para procesar los datos de tipo imagen

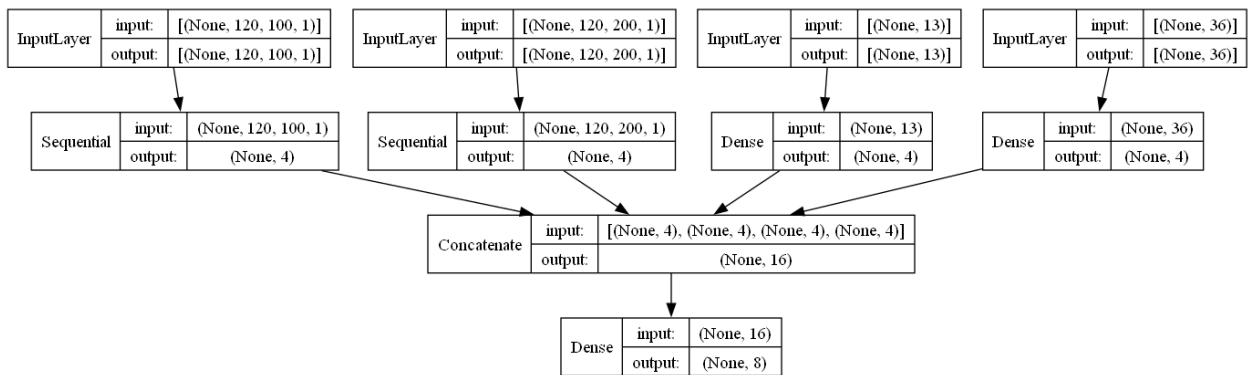
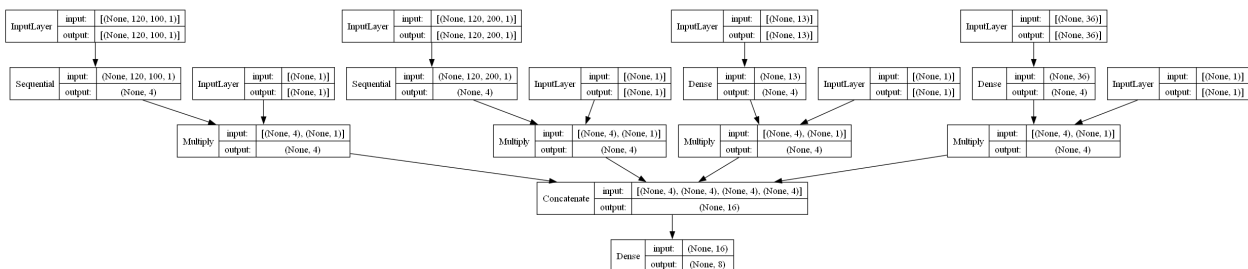


Figura 4-5: Submodelo multimodal que procesa los datos para cada paso de tiempo con capa *custom dropout*

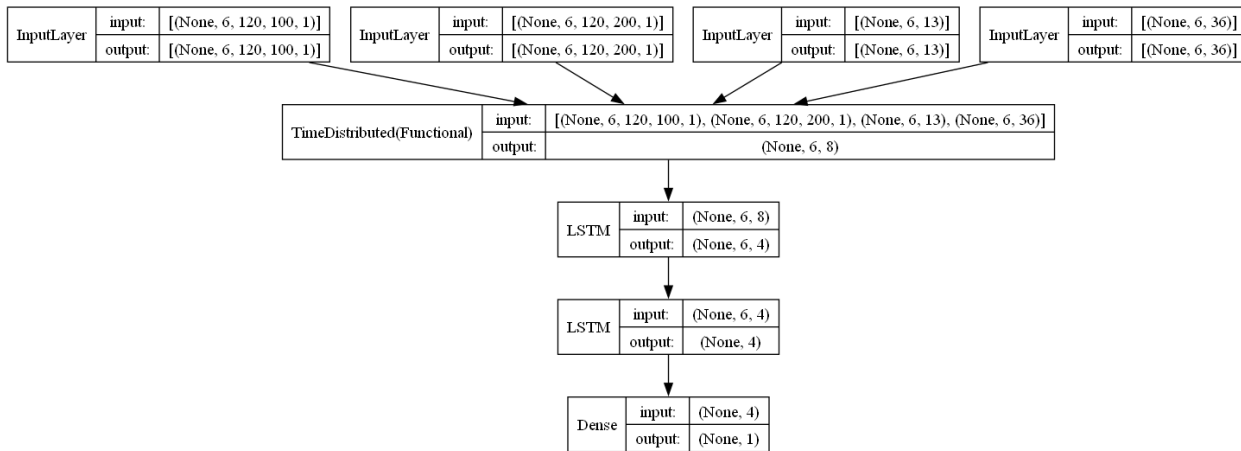


Dado que las secciones anteriores capturan la información multimodal para un paso del tiempo, los datos se ingresan por medio de una capa de distribución temporal *TimeDistributed* que permite iterar estos submodelos sobre los pasos del tiempo, y obtener un resultado final con componente temporal que puede ser procesado por una capa recurrente.

El análisis temporal se lleva a cabo a través de una capa LSTM, que es particularmente

adecuada para procesar secuencias de datos. El vector de características unificado para cada paso de tiempo se alimenta en la LSTM, permitiéndole aprender y retener información a lo largo de la ventana de tiempo completa. El modelo para clasificación de series de tiempo multimodales se presenta en la Figura 4-6

Figura 4-6: Modelo multimodal para clasificación de series de tiempo. La capa *TimeDistributed* contiene internamente el modelo multimodal que se ejecuta para cada paso del tiempo



Después de la capa LSTM, una capa *DenseLayer* sirve como el penúltimo paso en la red, ajustando la integración de características temporales y multimodales. La capa de salida final utiliza una función de activación sigmoide para lograr una clasificación binaria, indicando la probabilidad de que ocurra una falla en el próximo mes.

En la búsqueda de optimizar el modelo para la clasificación, también se realizan experimentos con *Transformers*, específicamente con la sección del *Encoder*, conocidos por su capacidad para manejar datos secuenciales en dominios como el procesamiento del lenguaje natural. A pesar del potencial de la arquitectura de *Transformers* para capturar dependencias sin considerar la distancia en la secuencia, los experimentos revelan que para este caso de estudio los modelos con capas LSTM superan a los *Transformers* utilizados. Trabajos futuros podrían explorar la incorporación de la codificación de posición relativa eficiente (eRPE) para mejorar la capacidad de los *Transformers* para procesar datos de series temporales en este contexto.

4.2.2. Comparación del modelo multimodal contra otros modelos

Con el objetivo de determinar la eficacia del enfoque multimodal propuesto en comparación con modelos individuales diseñados para cada modalidad. La principal métrica utilizada es la exactitud o *accuracy*, junto con el número de parámetros entrenables como medida de la complejidad del modelo. La Tabla 4-1 muestra los resultados de cada modelo probado.

Tabla 4-1: Resultados de los modelos utilizados para predicción de fallas

Modelo	Parámetros entrenables	Exactitud	Tiempo de entrenamiento	Tiempo de predicción
Modelo con datos de TWM	545	54.0 %	56.5s	1.3s
Modelo Conv-LSTM para dinagramas	509	58.1 %	71.4s	1.5s
Modelo Conv-LSTM para pruebas de válvula	517	55.6 %	55.5s	1.6s
Modelo con datos de libro de pruebas	453	58.9 %	60.5s	0.3s
Modelo con datos de libro de pruebas	1465	58.8 %	60.9s	1.4s
Modelo multimodal LSTM	929	61.3 %	103.4s	1.9s
Modelo multimodal Transformer	1493	57.2 %	100.5S	1.1s

Los modelos probados son los siguientes:

- Modelo de Series Temporales para los datos numéricos de TWM: Una red densa seguida de una capa LSTM con 545 parámetros entrenables. Este modelo tiene una exactitud del 54 %.
- Modelo de Series Temporales de Imágenes de dinagramas: El modelo para imágenes de dinagramas consiste en un modelo Conv-LSTM con un total de 509 parámetros entrenables. Este modelo presenta una exactitud del 58.1 %.
- Modelo de Series Temporales de Imágenes de Pruebas de Válvula: Las imágenes de pruebas de válvula se procesaron usando un modelo Conv-LSTM con 517 parámetros entrenables. la exactitud resultante es del 55.6 %.
- Modelo de Series Temporales de libro de pruebas: Para los datos de pruebas de producción se utiliza una arquitectura de una capa *DenseLayer* dentro de una capa *TimeDistributed* conectada a una capa LSTM con dos tamaños distintos:
 - Una versión 453 parámetros entrenables y una exactitud del 58.9 %.


- Una versión 1465 parámetros entrenables, que presenta una exactitud del 58.9%. El ligero decremento en el rendimiento, a pesar del aumento en el tamaño del modelo, sugiere que los modelos con más parámetros tienden a sobreajustarse a los datos.
- Modelo de Todas las Modalidades (*DenseLayer + Conv2D + TransformerEncoder*): En un intento por aprovechar las capacidades de la arquitectura de *Transformers*, el modelo se escaló a 1493 parámetros entrenables, sin embargo, la exactitud fue del 57.2%, estando por debajo del enfoque multimodal basado en LSTM.
- Modelo de Todas las Modalidades (*DenseLayer + Conv2D + LSTM*): El modelo multimodal con capa LSTM presenta 929 parámetros entrenables, alcanzando una exactitud del 61.3%. Este incremento confirma la ventaja de combinar diversos flujos de datos para predecir de una manera integral las fallas asociadas a los pozos. La matriz de confusión para este modelo se presenta en la Figura 4-7.

Los resultados muestran que el enfoque multimodal no solo aprovecha las fortalezas de cada modalidad individual, sino que también encuentra patrones y relaciones entre estas para mejorar la capacidad predictiva general. Mientras que el rendimiento de los modelos independientes varía, el modelo combinado con LSTM se presenta como el más hábil para integrar características temporales y espaciales para la predicción de fallas en pozos petroleros con sistema de bombeo mecánico. La matriz de confusión para este modelo se presenta en la Figura 4-7

4.3. Modelo de Boosting con datos desbalanceados

Dado que la naturaleza del problema de predicción de fallas no es balanceada, se realizan pruebas sobre datos desbalanceados que tienen relación aproximada de 24 ejemplos negativos por cada ejemplo positivo. Con el objetivo de mejorar el comportamiento del modelo para este problema específico, se realiza un modelo de *boosting*, donde se entrenan 24 modelos multimodales con capas LSTM para realizar las predicciones, para al final tomar tanto una votación que indique la predicción final para la clasificación (votación de 24 modelos Multimodales LSTM) como el promedio de la probabilidad de las predicciones (promedio de las probabilidades de 24 modelos Multimodales LSTM). Para el caso de votación se toman como positivos los ejemplos que tengan más del 50% de

Figura 4-7: Matriz de confusión del modelo multimodal para clasificación de series de tiempo con capa recurrente LSTM



los votos, y para el caso de promedio de la probabilidad de predicción, se toman como positivos los casos en que el resultado del promedio sea superior a 0.5.

Este modelo se comparó con el modelo multimodal con capa LSTM entrenado sobre datos balanceados. Los resultados de dicha comparación se encuentran en la Tabla 4-2.

La curva ROC del modelo de *boosting* con promedio de las probabilidades de los 24 modelos se muestra en la Figura 4-8, y la curva ROC del modelo de *boosting* con votación se muestra en la Figura 4-9. Se puede observar en los resultados que el modelo de *boosting* con votación tiene un mejor comportamiento general en cuanto a exactitud, mientras que el modelo de *boosting* con promedio de probabilidades presenta mejor área bajo la curva ROC, y los dos modelos de *boosting* se comportan mejor en estos dos aspectos que el modelo entrenado con datos balanceados (ver Figura 4-10), sin embargo, este último tiene un mejor *recall* para la clase positiva (ver Figura 4-13) que los modelos de *boosting* (ver Figuras 4-12 y 4-11)

Figura 4-8: Curva ROC para el modelo de *boosting* con promedio de probabilidades




Figura 4-9: Curva ROC para el modelo de *boosting* con votación






Figura 4-10: Curva ROC para el modelo multimodal entrenado sobre datos balanceados**Figura 4-11:** Matriz de confusión para el modelo de *boosting* con promedio de probabilidades

Figura 4-12: Matriz de confusión para el modelo de *boosting* con votación




Figura 4-13: Matriz de confusión para el modelo multimodal entrenado sobre datos balanceados




Tabla 4-2: Resultados de los modelos utilizados para predicción de fallas sobre datos no balanceados

Modelo	Parametros entrena- bles	Exactitud	Exactitud balancea- da	Recall cla- se positiva	Recall cla- se negati- va	Tiempo de entrena- miento	Tiempo de pre- dicción
Modelo de <i>boosting</i> (votación de 24 modelos Multimodales LSTM)	22296	67.06 %	60.43 %	53.23 %	67.63 %	9421.4s	257.5s
Modelo de <i>boosting</i> (promedio de las probabilidades de 24 modelos Multimodales LSTM)	22296	64.08 %	61.19 %	58.06 %	64.32 %	9421.4s	257.5s
Modelo multimodal LSTM (entrenado sobre datos balanceados)	929	53.1 %	57.05 %	61.29 %	52.81 %	103.4s	7.5s

4.4. Discusión de resultados

Finalmente en este capítulo se presentan algunos modelos para clasificación de series de tiempo multimodales, donde la arquitectura utilizada permite la integración de las distintas fuentes de datos con modalidades distintas para cada paso del tiempo en un modelo de clasificación que permite predecir las fallas en el siguiente paso del tiempo con una exactitud del 61.3 % que si bien es un porcentaje bajo para un modelo de clasificación binaria, muestra resultados superiores a los demás modelos utilizados, y constituye un resultado aceptable dado que son datos de fuentes reales, y no se cuenta con una gran cantidad de ejemplos para entrenar el modelo. Adicionalmente, se presenta un modelo de *boosting* para abordar el problema sin balancear previamente mediante el entrenamiento de 24 modelos multimodales para realizar un proceso de votación, el cual, si bien requiere un mayor tiempo de entrenamiento y de predicción, presenta una mejora en exactitud frente al modelo entrenado con datos balanceados.

5 Modelo de predicción de la producción con series de tiempo multimodales

En este capítulo se elabora un modelo para realizar pronósticos de series de tiempo basado en datos multimodales para predecir la producción de petróleo. Para este fin se utiliza la misma arquitectura expuesta en la sección 4.1 como *encoder*, adaptando la capa de salida para que funcione en la elaboración de pronósticos de determinados pasos en el tiempo.

Los modelos presentados se encuentran implementados en TensorFlow [1], y son entrenados en una estación de trabajo con las siguientes especificaciones:

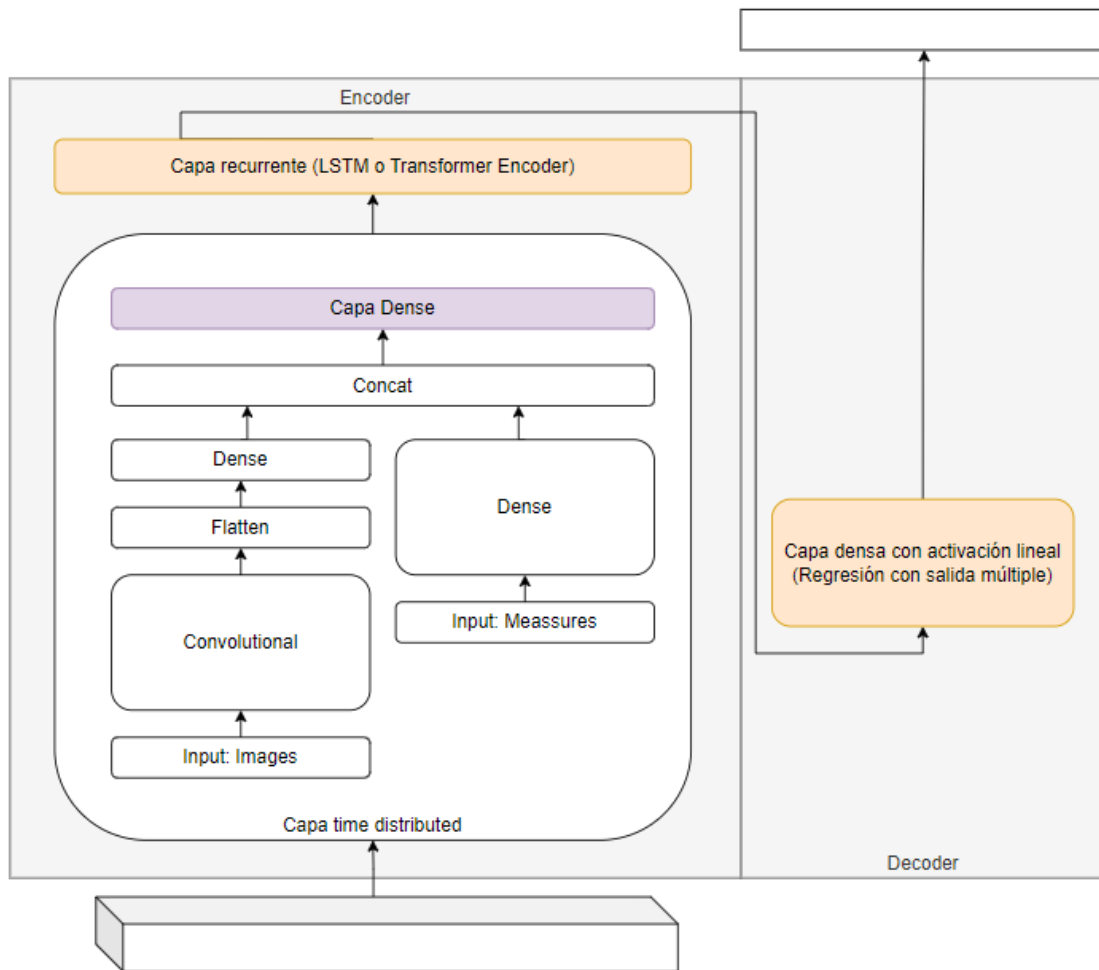
- CPU: Dual Intel XEON E263v3 con 16 núcleos físicos, y 32 virtuales.
- RAM: 40 GB DDR4 Memoria física, 80 GB Memoria virtual (paginación en disco)
- GPU: Nvidia 980 TI con 6 GB de vRAM
- Sistema operativo: Windows 10
- versión de Python: 3.10.11

5.1. Arquitectura de modelos multimodales

Para lograr predecir la producción en un intervalo de tiempo determinado, se conecta el *encoder* del modelo multimodal dentro de una capa de distribución temporal *TimeDistributed* con una capa densa (*DenseLayer*) con un número de unidades igual a las variables a predecir y activación lineal (ver Figura 5-1).

Se presentan distintas variaciones en las dimensiones de los modelos en la experimentación de acuerdo con la ventana de pasos de tiempo que se utilizan como datos de entrada

Figura 5-1: Modelo multimodal con salida múltiple para realizar pronósticos de series de tiempo.



(w_{size}), y la cantidad de pasos en el futuro a predecir para la variable independiente (y_{steps}). Las ventanas utilizadas fueron de 6, 12, 24 y 36 pasos en el pasado para predecir los próximos 3, 6, 12, y 24 pasos para la variable dependiente. Para ingresar la información al modelo se tienen las siguientes tres capas de entrada (*InputLayers*):

- Entrada de dinagramas: Es una entrada de dimensiones [w_{size} , 120, 100]. La fuente de datos de esta entrada son las imágenes de dinagramas.
- Entrada de pruebas de válvula: Es una entrada de dimensiones [w_{size} , 120, 200]. La fuente de datos de esta entrada son las imágenes de pruebas de válvula.
- Entrada de mediciones: Es la entrada de variables numéricas de la serie de tiempo, con dimensiones [w_{size} , n], donde n corresponde a la cantidad de variables ingresadas al modelo. Para la experimentación se realizan dos tipos de modelos, utilizando en uno de ellos las 15 variables resultado de la selección de variables por juicio de experto, y en el otro las 30 variables resultado del proceso de PCA.

En cuanto al *encoder*, se tienen dos variantes, una con dos capas recurrentes LSTM con tantas unidades como pasos a predecir y_{steps} se tengan, y modelos basados en *transformers* donde se utiliza una capa de *transformer encoder* variando el número de capas *Feed Forward* de acuerdo con el número de pasos y_{steps} a predecir. El número de parámetros también varía dependiendo de la entrada utilizada, bien sea variables seleccionadas por juicio de experto, o resultado de PCA. La Figura 5-2 muestra un ejemplo de modelo multimodal basado en capas recurrentes LSTM, y la Figura 5-3 muestra el caso del modelo basado en *transformers*; en los dos casos la entrada numérica tiene 15 posiciones, la ventana w_{size} seleccionada es 36, y el número de pasos a predecir y_{steps} es 24

El *decoder* es directamente una capa densa *DenseLayer* de salida con función de activación lineal con tantas unidades como pasos a predecir haya, debido a que por la diferencia de dimensionalidad entre las variables dependientes e independientes, que inviabiliza el uso de un modelo secuencia a secuencia, se requiere realizar una capa de salida múltiple, esto es, predecir múltiples pasos de tiempo en una sola iteración. Las combinaciones utilizadas entre pasos de entrada y salida del modelo, y su relación con el número de parámetros del modelo se encuentra en la Tabla 5-1.

Figura 5-2: Modelo multimodal basado en LSTM con w_{size} de 36 y y_{steps} de 24.

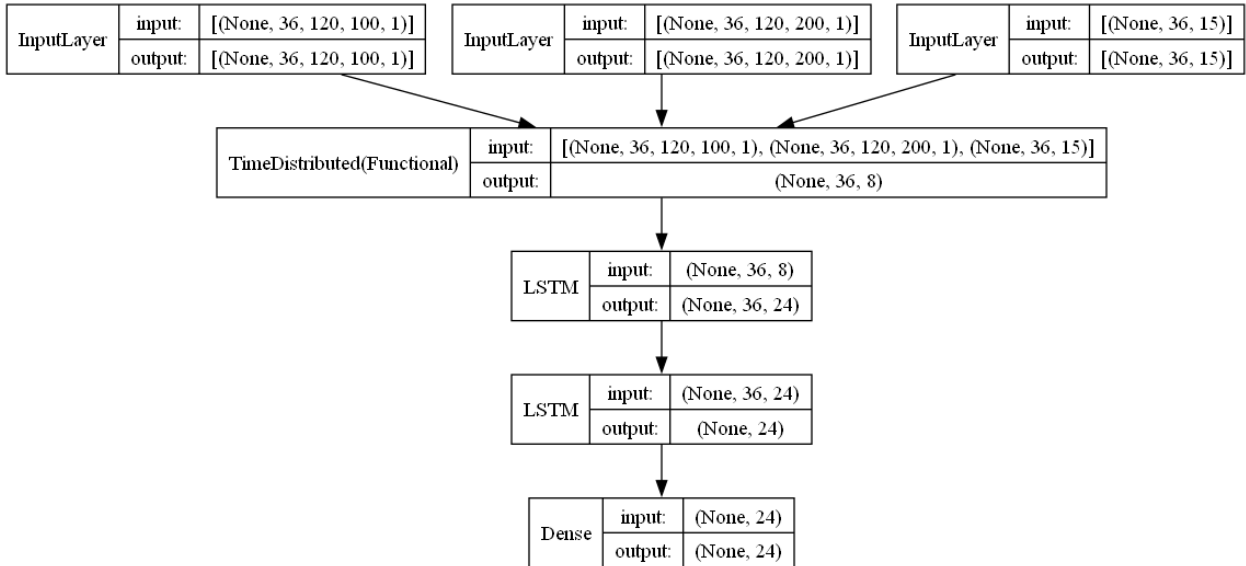


Figura 5-3: Modelo multimodal basado en transformers con w_{size} de 36 y y_{steps} de 24.

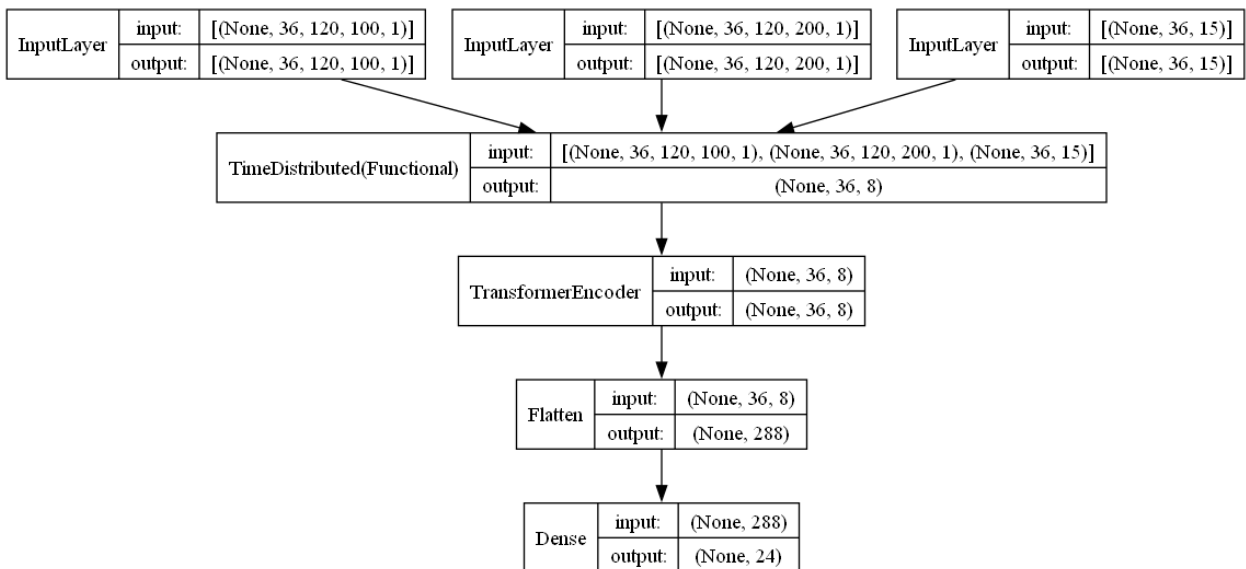


Tabla 5-1: Número de parámetros de los modelos multimodales de acuerdo con el tamaño de la ventana w_{size} y pasos a predecir y_{steps}

Tipo de modelo	Tamaño ventana	Pasos a predecir	Número de parámetros	
			Basado en LSTM	Basado en Transformers
Selección de experto	6	3	640	926
Selección de experto	12	6	1114	1412
Selección de experto	24	6	1114	1988
Selección de experto	24	12	2764	3248
Selección de experto	36	6	1114	2564
Selección de experto	36	12	2764	4400
Selección de experto	36	24	8872	8072
PCA	6	3	700	986
PCA	12	6	1174	1472
PCA	24	6	1174	2048
PCA	24	12	2824	3308
PCA	36	6	1174	2624
PCA	36	12	2824	4460
PCA	36	24	8932	8132

5.2. Entrenamiento y validación de modelos multimodales

Para evaluar cada uno de los modelos de pronóstico de series de tiempo multimodales desarrollados, se establecen criterios de evaluación específicos que permiten medir de manera efectiva su rendimiento y precisión. Los aspectos clave evaluados incluyen el tiempo de entrenamiento, el error cuadrático medio (MSE) y el error absoluto medio (MAE) presentados en las Ecuaciones 5-1 y 5-2 donde Y_i son los valores reales, \hat{Y}_i son los valores predichos por el modelo y n es el número total de observaciones.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (5-1)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (5-2)$$

Para una evaluación efectiva, se utiliza un conjunto de datos de prueba que consiste en los últimos 24 pasos de tiempo de cada serie, los cuales no son incluidos en el entrenamiento del modelo. Este enfoque asegura que la evaluación del modelo se realice en condiciones

no vistas anteriormente, lo que proporciona una medida realista de su capacidad predictiva. Los resultados de estas evaluaciones, incluyendo el tiempo de entrenamiento, MSE y MAE para cada modelo, se presentan en la Tabla 5-2.

Tabla 5-2: Resultado del entrenamiento de los modelos multimodales

Tipo de modelo	VARIABLES numéricas	w_{size}	y_{steps}	Tiempo de entrenamiento (s)	MAE Test	MSE Test	Ejemplos entrenamiento	Ejemplos test
Transformer	Experto	6	3	1154.38	5.44	61.26	10479	214
Transformer	Experto	12	6	1487.14	5.80	69.16	9138	214
Transformer	Experto	24	6	2595.33	6.50	91.95	7374	214
Transformer	Experto	36	6	2425.01	6.25	77.87	5877	185
Transformer	Experto	24	12	2288.45	8.33	166.81	6562	214
Transformer	Experto	36	12	2221.04	8.14	152.23	5272	185
Transformer	Experto	36	24	1832.22	10.94	289.44	4322	185
Transformer	PCA	6	3	1124.96	5.19	56.16	10479	214
Transformer	PCA	12	6	1455.15	6.23	77.80	9138	214
Transformer	PCA	24	6	2484.13	6.79	115.09	7374	214
Transformer	PCA	36	6	2352.74	6.99	96.96	5877	185
Transformer	PCA	24	12	2232.82	8.29	153.17	6562	214
Transformer	PCA	36	12	2139.48	8.90	175.57	5272	185
Transformer	PCA	36	24	1757.97	10.34	245.68	4322	185
LSTM	Experto	6	3	1150.85	4.99	53.78	10479	214
LSTM	Experto	12	6	1476.29	5.99	71.77	9138	214
LSTM	Experto	24	6	2607.20	5.97	72.16	7374	214
LSTM	Experto	36	6	2498.51	6.44	100.78	5877	185
LSTM	Experto	24	12	2307.08	8.39	227.37	6562	214
LSTM	Experto	36	12	2230.02	7.96	157.12	5272	185
LSTM	Experto	36	24	1858.07	12.09	414.46	4322	185
LSTM	PCA	6	3	1143.99	5.14	54.90	10479	214
LSTM	PCA	12	6	1484.83	6.51	80.96	9138	214
LSTM	PCA	24	6	2532.66	6.72	101.07	7374	214
LSTM	PCA	36	6	2401.67	5.89	71.18	5877	185
LSTM	PCA	24	12	2262.99	8.14	133.84	6562	214
LSTM	PCA	36	12	2149.92	8.55	205.30	5272	185
LSTM	PCA	36	24	1898.74	9.91	193.15	4322	185

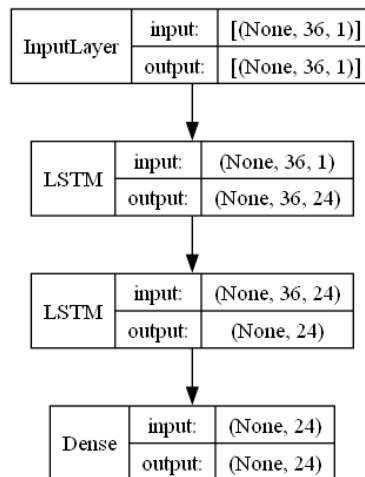
5.3. Comparación de modelos multimodales con modelos de línea base

5.3.1. Entrenamiento de modelos de línea base

Para establecer una línea base con la que comparar el desempeño de los modelos multimodales de pronóstico, se implementan los modelos de una sola modalidad mostrados en la Tabla 5-3, lo que permite evaluar la efectividad de los modelos multimodales contra modelos no multimodales. Los modelos de una sola modalidad implementados se dividen en:

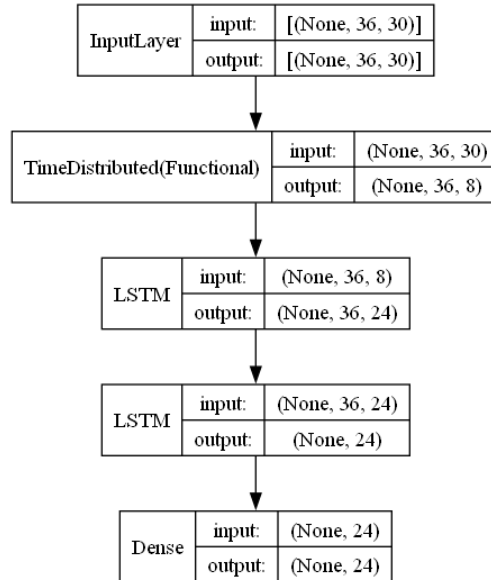
- **Modelo Univariado:** Este modelo considera exclusivamente la producción de petróleo como variable. Su enfoque Univariado sirve para analizar cómo la predicción de la producción se comporta cuando se basa únicamente en los datos históricos de la producción de petróleo, sin tener en cuenta otras variables o modalidades (ver Figura 5-4).
- **Modelo Multivariado:** En contraste con el modelo Univariado, el modelo multivariado se centra en las variables numéricas. Este modelo utiliza múltiples variables para realizar las predicciones. Se diferencia del modelo multimodal en que no incluye las imágenes de dinagramas ni pruebas de válvula (ver Figura 5-5).

Figura 5-4: Modelo univariado basado en LSTM con w_{size} de 36 y y_{steps} de 24.



El resultado del entrenamiento realizado para el modelo univariado y el multivariado se encuentra en la Tabla 5-4.

Figura 5-5: Modelo multivariado basado en LSTM con w_{size} de 36 y y_{steps} de 24.



5.3.2. Comparación de modelos

Con el objetivo de comparar los modelos presentados con otros modelos que se entrenen únicamente para la serie de tiempo del pozo específico que se quiere predecir, se elaboran líneas base con un modelo ARIMA según la implementación `auto_arima` [47], el modelo ARIMA con menor valor en el criterio de información de Akaike (AIC) según la implementación de [6] y un modelo recurrente con dos capas LSTM. De manera adicional, y dado que los modelos multimodales, univariado y multivariado fueron entrenados en la totalidad de las series de tiempo correspondientes a todos los pozos del campo para aprender las características y patrones asociados a cada fuente de datos, se realizó un proceso de *fine-tuning* buscando mejorar el comportamiento de dichos modelos para la serie de tiempo específica que se quiere pronosticar.

Las Tablas 5-5 , 5-6, 5-7 y 5-8 presentan los resultados obtenidos para las pruebas realizadas sobre 10 pozos en todas las ventanas de tiempo a predecir. Los resultados se expresan en términos de MAPE (Error Porcentual Absoluto Medio, ver Ecuación 5-3). En las tablas se puede observar que para el plazo más corto (un trimestre), y para el plazo más largo (2 años), el modelo multimodal basado en LSTM presenta el mejor comportamiento, mientras que para los periodos intermedios el modelo ARIMA es el que mejor se adapta. Sin embargo, entre los modelos de redes neuronales, el modelo multimodal basado en LSTM presenta los mejores resultados, seguido por el modelo multivariado.

Tabla 5-3: Número de parámetros de los modelos no multimodales de acuerdo con el tamaño de la ventana w_{size} y pasos a predecir y_{steps}

Modelo	Fuente de datos	Tamaño ventana	Pasos a predecir	Número de parámetros
Univariado	Solo producción	6	3	156
Univariado	Solo producción	12	6	546
Univariado	Solo producción	24	6	546
Univariado	Solo producción	24	12	2028
Univariado	Solo producción	36	6	546
Univariado	Solo producción	36	12	2028
Univariado	Solo producción	36	24	7800
Multivariado	PCA	6	3	404
Multivariado	PCA	12	6	878
Multivariado	PCA	24	6	878
Multivariado	PCA	24	12	2528
Multivariado	PCA	36	6	878
Multivariado	PCA	36	12	2528
Multivariado	PCA	36	24	8636
Multivariado	Experto	6	3	344
Multivariado	Experto	12	6	818
Multivariado	Experto	24	6	818
Multivariado	Experto	24	12	2468
Multivariado	Experto	36	6	818
Multivariado	Experto	36	12	2468
Multivariado	Experto	36	24	8576

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \tag{5-3}$$

Dada la existencia de casos en los que el modelo ARIMA presenta resultados superiores a los modelos multimodales, un análisis exhaustivo muestra que el modelo ARIMA se comporta mejor en series donde los datos históricos de producción presentan poca variación respecto de la media, como se muestra en la Figura 5-6.

Con la intención de comparar los modelos en términos de tiempos, MAE, MSE y MAPE, se presentan las predicciones de todos los modelos sobre un pozo determinado. los resultados se encuentran estructurados en tablas de la siguiente manera:

- Para el caso de predicción de un trimestre (3 pasos de tiempo) los resultados se en-

5.3 Comparación de modelos multimodales con modelos de línea base

Tabla 5-4: Resultado del entrenamiento de los modelos no multimodales

Tipo de modelo	Variables numéricas	wsize	ySteps	Tiempo de entrenamiento (s)	MAE Test	MSE Test	Ejemplos entrenamiento	Ejemplos test
Univariable	Solo producción	6	3	292.50	4.74	49.55	10479	214
Univariable	Solo producción	12	6	381.85	5.38	67.32	9138	214
Univariable	Solo producción	24	6	523.77	5.39	69.59	7374	214
Univariable	Solo producción	36	6	566.55	5.75	86.36	5877	185
Univariable	Solo producción	24	12	452.16	7.54	150.30	6562	214
Univariable	Solo producción	36	12	506.61	8.56	232.60	5272	185
Univariable	Solo producción	36	24	463.09	10.80	315.93	4322	185
Multivariado	Experto	6	3	313.51	4.77	48.06	10479	214
Multivariado	Experto	12	6	412.60	5.62	66.05	9138	214
Multivariado	Experto	24	6	550.16	5.67	68.23	7374	214
Multivariado	Experto	36	6	633.23	5.50	66.30	5877	185
Multivariado	Experto	24	12	517.29	6.94	106.40	6562	214
Multivariado	Experto	36	12	568.20	8.26	168.49	5272	185
Multivariado	Experto	36	24	493.77	11.49	329.68	4322	185
Multivariado	PCA	6	3	332.52	5.10	54.09	10479	214
Multivariado	PCA	12	6	424.09	5.95	70.72	9138	214
Multivariado	PCA	24	6	566.39	6.22	75.77	7374	214
Multivariado	PCA	36	6	637.84	6.17	78.87	5877	185
Multivariado	PCA	24	12	491.60	8.25	153.48	6562	214
Multivariado	PCA	36	12	575.42	8.58	178.03	5272	185
Multivariado	PCA	36	24	470.25	11.66	319.91	4322	185

cuentran en la Tabla **5-9** donde el mejor comportamiento es obtenido por el modelo multimodal con capa LSTM.

- Para el caso de predicción de un semestre (6 pasos de tiempo) los resultados se encuentran en las Tabla **5-10**, **5-11** y **5-12** donde los modelos multimodales basados en LSTM, multivariado, y ARIMA presentan un comportamiento similar.
- Para el caso de predicción de un año (12 pasos de tiempo) los resultados se encuentran en las Tabla **5-13** y **5-14** donde los modelos multimodales basados en LSTM, multivariado, y ARIMA presentan un comportamiento similar.
- Para el caso de predicción de dos años (24 pasos de tiempo) los resultados se

Tabla 5-5: Comparación de casos específicos contra la línea base de modelos ARIMA para 3 pasos de tiempo (trimestre)

Modelo	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	Promedio
ARIMA con menor AIC	10.4 %	3.9 %	5.6 %	4.4 %	3.9 %	5.4 %	8.4 %	3.2 %	7.8 %	5.3 %	5.8 %
Auto ARIMA	6.9 %	4.7 %	4.2 %	7.2 %	4.3 %	4.8 %	8.4 %	6.5 %	4.8 %	7.5 %	5.9 %
Modelo LSTM un solo pozo	6.4 %	5.4 %	7.6 %	18.3 %	7.9 %	5.5 %	9.0 %	2.5 %	16.5 %	6.9 %	8.6 %
Multimodal LSTM	8.5 %	0.8 %	5.1 %	1.8 %	6.4 %	8.8 %	13.0 %	3.4 %	7.9 %	4.1 %	6.0 %
Multimodal LSTM - Fine Tuning	1.5 %	2.2 %	9.7 %	2.3 %	8.1 %	6.5 %	13.4 %	3.1 %	5.2 %	4.1 %	5.6 %
Multimodal LSTM - PCA	3.0 %	5.3 %	4.7 %	6.5 %	6.6 %	9.7 %	8.7 %	5.5 %	13.9 %	10.4 %	7.4 %
Multimodal LSTM - PCA - Fine Tuning	10.3 %	2.8 %	3.4 %	7.5 %	6.2 %	10.3 %	9.6 %	3.1 %	13.1 %	9.7 %	7.6 %
Multimodal Transformer Encoder	7.6 %	3.2 %	4.3 %	1.2 %	11.8 %	9.5 %	13.1 %	4.5 %	13.4 %	7.0 %	7.6 %
Multimodal Transformer Encoder - Fine Tuning	10.4 %	3.9 %	12.0 %	3.2 %	11.9 %	5.8 %	12.3 %	4.4 %	12.5 %	5.8 %	8.2 %
Multimodal Transformer Encoder - PCA	4.6 %	7.9 %	2.8 %	7.7 %	6.7 %	13.6 %	10.9 %	7.2 %	11.6 %	12.8 %	8.6 %
Multimodal Transformer Encoder - PCA - Fine Tuning	5.8 %	3.7 %	2.7 %	10.1 %	4.8 %	12.7 %	8.1 %	2.3 %	8.8 %	6.0 %	6.5 %
Univariado	106.0 %	46.7 %	68.3 %	75.4 %	57.2 %	48.4 %	88.3 %	57.1 %	69.7 %	41.7 %	65.9 %
Univariado - Fine Tuning	88.9 %	38.9 %	56.9 %	64.2 %	50.3 %	40.0 %	78.8 %	51.1 %	65.3 %	36.2 %	57.1 %
Multivariado	6.9 %	6.0 %	8.7 %	2.5 %	6.4 %	7.6 %	8.4 %	3.1 %	5.7 %	7.4 %	6.3 %
Multivariado - Fine Tuning	2.6 %	4.7 %	10.2 %	2.6 %	8.3 %	7.3 %	9.1 %	3.2 %	4.0 %	7.6 %	6.0 %
Multivariado - PCA	3.9 %	1.5 %	5.3 %	5.5 %	5.8 %	8.8 %	11.1 %	5.3 %	14.1 %	14.1 %	7.5 %
Multivariado - PCA - Fine Tuning	10.9 %	3.9 %	3.1 %	7.7 %	5.6 %	7.8 %	9.3 %	3.4 %	8.5 %	12.1 %	7.2 %

5.3 Comparación de modelos multimodales con modelos de línea base

Tabla 5-6: Comparación de casos específicos contra la línea base de modelos ARIMA para 6 pasos de tiempo (semestre)

Modelo	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	Promedio
ARIMA con menor AIC	9.3 %	5.6 %	4.5 %	5.5 %	4.1 %	9.2 %	19.0 %	3.4 %	7.5 %	4.5 %	7.3 %
Auto ARIMA	5.9 %	5.3 %	5.2 %	10.0 %	2.8 %	6.5 %	19.0 %	8.4 %	6.0 %	7.2 %	7.6 %
Modelo LSTM un solo pozo	22.2 %	13.7 %	17.2 %	58.4 %	13.1 %	7.8 %	22.5 %	4.1 %	58.5 %	3.8 %	22.1 %
Multimodal LSTM	8.5 %	5.0 %	5.8 %	3.9 %	9.0 %	10.8 %	24.8 %	2.7 %	11.4 %	3.5 %	8.5 %
Multimodal LSTM - Fine Tuning	7.9 %	7.0 %	9.6 %	9.7 %	7.2 %	11.4 %	24.1 %	2.9 %	7.3 %	3.3 %	9.0 %
Multimodal LSTM - PCA	4.9 %	14.5 %	6.1 %	1.2 %	9.8 %	8.7 %	23.0 %	8.5 %	8.4 %	3.5 %	8.9 %
Multimodal LSTM - PCA - Fine Tuning	9.8 %	8.6 %	5.9 %	13.7 %	8.1 %	15.2 %	24.3 %	5.7 %	5.1 %	3.3 %	10.0 %
Multivariado - PCA - Fine Tuning	14.7 %	16.1 %	5.2 %	3.5 %	10.8 %	9.4 %	24.9 %	2.8 %	5.7 %	6.1 %	9.9 %
Multimodal Transformer Encoder	12.0 %	15.1 %	5.0 %	2.8 %	9.2 %	12.6 %	34.3 %	5.5 %	13.0 %	11.8 %	12.1 %
Multimodal Transformer Encoder - Fine Tuning	16.6 %	10.6 %	15.6 %	2.4 %	2.6 %	13.8 %	31.1 %	7.8 %	14.6 %	11.5 %	12.7 %
Multimodal Transformer Encoder - PCA	7.1 %	13.4 %	5.7 %	7.2 %	14.8 %	23.1 %	29.3 %	2.6 %	10.0 %	7.2 %	12.0 %
Multimodal Transformer Encoder - PCA - Fine Tuning	16.1 %	12.4 %	8.5 %	11.6 %	10.2 %	23.0 %	20.8 %	6.6 %	5.3 %	6.8 %	12.1 %
Univariado	145.3 %	72.9 %	103.8 %	97.2 %	75.2 %	69.2 %	150.1 %	71.9 %	79.4 %	51.1 %	91.6 %
Univariado - Fine Tuning	117.6 %	59.6 %	75.8 %	75.6 %	61.8 %	51.6 %	135.9 %	56.8 %	75.1 %	41.2 %	75.1 %
Multivariado	5.5 %	4.8 %	7.7 %	3.1 %	9.3 %	9.0 %	19.3 %	2.8 %	4.9 %	5.3 %	7.2 %
Multivariado - Fine Tuning	8.7 %	5.2 %	10.0 %	9.3 %	7.8 %	8.6 %	22.2 %	2.8 %	5.4 %	5.6 %	8.5 %
Multivariado - PCA	4.4 %	16.3 %	6.2 %	4.7 %	19.3 %	13.0 %	22.9 %	2.9 %	6.6 %	9.0 %	10.5 %

Tabla 5-7: Comparación de casos específicos contra la línea base de modelos ARIMA para 12 pasos de tiempo (1 año)

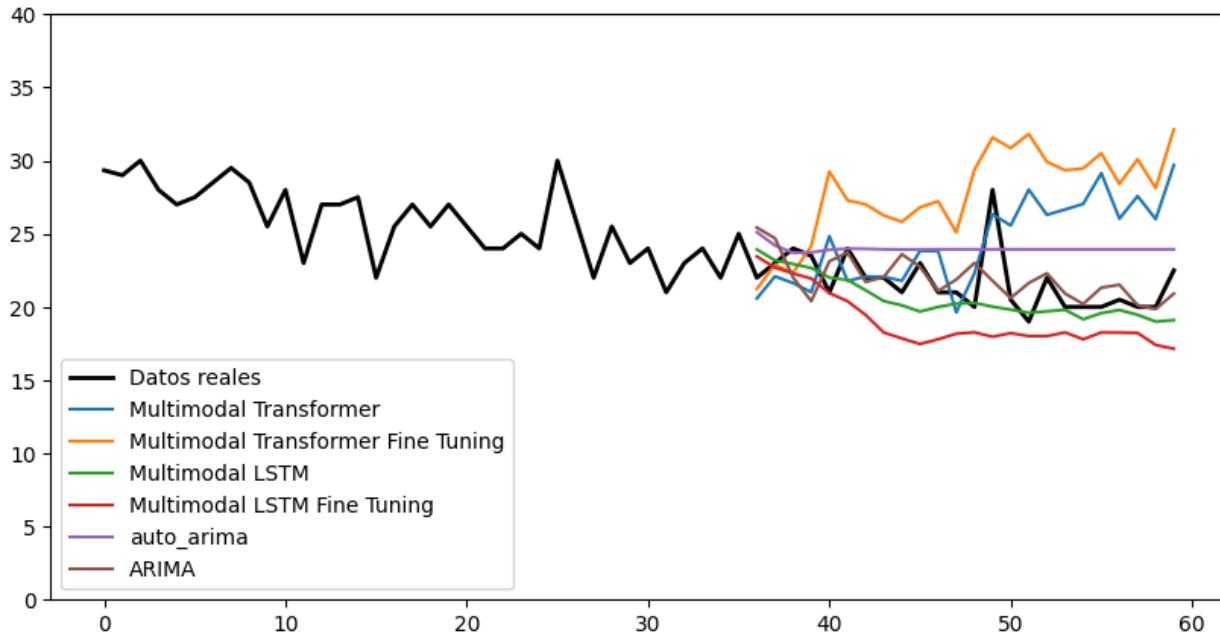
Modelo	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	Promedio
ARIMA con menor AIC	6.3%	6.7%	6.8%	5.4%	3.2%	9.7%	13.3%	5.0%	6.7%	3.8%	6.7%
Auto ARIMA	8.3%	5.6%	7.0%	10.6%	2.9%	5.7%	13.3%	12.3%	7.5%	6.7%	8.0%
Modelo LSTM un solo pozo	65.2%	11.0%	18.2%	4.1%	17.1%	60.7%	31.2%	14.9%	11.8%	11.3%	24.5%
Multimodal LSTM	7.5%	4.4%	6.3%	4.2%	13.4%	6.0%	15.1%	3.8%	12.7%	4.3%	7.8%
Multimodal LSTM - Fine Tuning	9.1%	12.8%	5.8%	3.5%	9.4%	20.2%	15.3%	3.8%	9.6%	4.4%	9.4%
Multimodal LSTM - PCA	5.1%	8.3%	12.5%	17.2%	13.3%	6.0%	18.1%	4.4%	7.6%	4.4%	9.7%
Multimodal LSTM - PCA - Fine Tuning	16.8%	8.2%	10.6%	18.2%	8.4%	14.2%	25.3%	4.0%	6.3%	8.5%	12.1%
Multimodal Transformer Encoder	9.8%	7.4%	5.7%	3.7%	13.4%	9.2%	12.3%	5.8%	32.7%	3.9%	10.4%
Multimodal Transformer Encoder - Fine Tuning	8.4%	11.6%	5.8%	3.9%	5.4%	6.4%	14.5%	4.4%	27.3%	3.7%	9.1%
Multimodal Transformer Encoder - PCA	7.8%	17.6%	8.8%	5.8%	8.1%	15.9%	32.4%	6.2%	7.6%	4.3%	11.5%
Multimodal Transformer Encoder - PCA - Fine Tuning	12.1%	14.4%	6.3%	10.1%	8.8%	13.6%	23.9%	4.4%	14.3%	6.2%	11.4%
Univariado	76.2%	39.6%	52.8%	47.6%	50.8%	30.9%	104.3%	41.2%	53.1%	25.0%	52.1%
Univariado - Fine Tuning	43.2%	22.1%	11.1%	14.3%	25.0%	15.2%	47.8%	19.0%	30.4%	13.0%	24.1%
Multivariado	4.6%	5.5%	7.7%	3.7%	16.4%	9.0%	28.4%	5.0%	7.9%	4.8%	9.3%
Multivariado - Fine Tuning	8.4%	7.1%	7.9%	2.2%	9.0%	6.1%	28.0%	3.9%	8.7%	4.7%	8.6%
Multivariado - PCA	4.1%	11.6%	6.7%	13.1%	8.2%	11.6%	22.4%	7.2%	9.6%	5.0%	10.0%
Multivariado - PCA - Fine Tuning	5.3%	15.6%	6.2%	10.0%	9.8%	10.9%	20.4%	6.0%	7.6%	5.6%	9.7%

5.3 Comparación de modelos multimodales con modelos de línea base

Tabla 5-8: Comparación de casos específicos contra la línea base de modelos ARIMA para 24 pasos de tiempo (2 años)

Modelo	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	Promedio
ARIMA con menor AIC	6.4 %	7.1 %	7.9 %	6.2 %	2.5 %	15.9 %	17.4 %	9.2 %	12.6 %	5.0 %	9.0 %
Auto ARIMA	12.8 %	5.2 %	7.4 %	18.4 %	2.3 %	7.5 %	17.4 %	18.5 %	17.2 %	5.7 %	11.2 %
Modelo LSTM un solo pozo	78.6 %	22.3 %	26.5 %	45.3 %	59.3 %	11.2 %	41.4 %	39.9 %	46.6 %	7.6 %	37.9 %
Multimodal LSTM	6.2 %	2.7 %	8.1 %	6.6 %	5.3 %	9.3 %	13.4 %	5.1 %	18.0 %	7.8 %	8.2 %
Multimodal LSTM - Fine Tuning	12.4 %	4.3 %	7.9 %	5.0 %	8.8 %	3.9 %	17.4 %	5.7 %	19.4 %	8.8 %	9.4 %
Multimodal LSTM - PCA	5.6 %	3.3 %	13.0 %	6.0 %	24.4 %	7.6 %	17.7 %	8.6 %	21.2 %	6.6 %	11.4 %
Multimodal LSTM - PCA - Fine Tuning	10.7 %	15.7 %	6.1 %	10.6 %	12.3 %	28.5 %	18.3 %	8.2 %	20.5 %	6.4 %	13.7 %
Multimodal Transformer Encoder	18.2 %	19.2 %	11.0 %	16.0 %	17.7 %	7.4 %	25.9 %	7.5 %	41.1 %	12.4 %	17.6 %
Multimodal Transformer Encoder - Fine Tuning	30.4 %	24.8 %	8.5 %	16.2 %	17.7 %	11.4 %	34.1 %	7.7 %	39.1 %	15.2 %	20.5 %
Multimodal Transformer Encoder - PCA	17.1 %	22.3 %	9.3 %	8.7 %	31.4 %	9.4 %	18.5 %	9.3 %	32.2 %	4.6 %	16.3 %
Multimodal Transformer Encoder - PCA - Fine Tuning	13.6 %	24.1 %	12.3 %	19.3 %	41.1 %	8.4 %	19.7 %	11.4 %	23.0 %	5.8 %	17.9 %
Univariado	68.5 %	34.1 %	46.1 %	43.8 %	47.6 %	28.9 %	55.1 %	39.2 %	56.5 %	15.0 %	43.5 %
Univariado - Fine Tuning	60.3 %	29.0 %	15.9 %	25.9 %	17.7 %	20.2 %	38.3 %	29.2 %	35.9 %	12.4 %	28.5 %
Multivariado	6.8 %	8.9 %	8.3 %	5.3 %	73.9 %	19.6 %	34.9 %	6.9 %	27.9 %	7.0 %	20.0 %
Multivariado - Fine Tuning	6.1 %	7.4 %	8.5 %	8.8 %	68.2 %	29.0 %	27.0 %	5.8 %	31.0 %	5.8 %	19.8 %
Multivariado - PCA	5.9 %	24.8 %	6.3 %	3.6 %	20.5 %	9.5 %	26.1 %	9.2 %	25.7 %	6.2 %	13.8 %
Multivariado - PCA - Fine Tuning	16.1 %	41.9 %	6.7 %	3.3 %	20.5 %	16.1 %	26.7 %	7.0 %	24.8 %	6.8 %	17.0 %

Figura 5-6: Análisis de casos donde el modelo ARIMA presentó resultados superiores a los modelos multimodales.



encuentran en la Tabla 5-15 donde el mejor comportamiento es obtenido por modelo multimodal con capa LSTM.

Para una fácil visualización de los resultados, se representan gráficamente las predicciones para el pozo utilizado en el caso de predicción de 24 pasos de tiempo. La Figura 5-7 presenta los resultados directamente obtenidos de los modelos generales, y de manera adicional presenta las líneas base de ARIMA y LSTM entrenado únicamente con la serie de tiempo. La Figura 5-8 muestra el resultado del proceso de fine-tuning para los modelos multimodales, y la Figura 5-9 muestra los resultados finales para los modelos multimodales y para el modelo multivariado.

5.4. Discusión de resultados

En este capítulo se presentan algunos modelos multimodales para pronósticos de series de tiempo, donde se utilizan series de tiempo multimodales que tienen distintas fuentes con diferente modalidad para cada paso del tiempo, para predecir el comportamiento de la producción en intervalos trimestrales, semestrales, anuales y bi-anuales, comparán-

Figura 5-7: Resultados para un pozo determinado en la ventana de predicción de $w_{size} = 36$ y $y_{steps} = 24$.




Figura 5-8: Resultados antes y después del proceso de fine-tuning.




Tabla 5-9: Resultado de predicción de 3 pasos de tiempo con una ventana de 6 para un pozo específico

Tipo de modelo	Variables numéricas	wsize	ySteps	Tiempo de entrenamiento (s)	MAE Test	MSE Test	MAPE Test
ARIMA con menor AIC	Solo producción		3	268.45	1.10	1.61	4 %
Auto ARIMA	Solo producción		3	1.66	1.32	2.10	5 %
Modelo LSTM un solo pozo	Solo producción	6	3	10.33	1.51	2.95	5 %
Multimodal LSTM	PCA	6	3		1.47	2.25	5 %
Multimodal LSTM	Experto	6	3		0.23	0.09	1 %
Multimodal LSTM - Fine Tunning	PCA	6	3	5.58	0.78	0.78	3 %
Multimodal LSTM - Fine Tunning	Experto	6	3	5.58	0.61	0.43	2 %
Multimodal Transformer Encoder	PCA	6	3		2.20	4.95	8 %
Multimodal Transformer Encoder	Experto	6	3		0.90	0.87	3 %
Multimodal Transformer Encoder - Fine Tunning	Experto	6	3	3.57	1.09	1.23	4 %
Multimodal Transformer Encoder - Fine Tunning	PCA	6	3	3.41	1.04	1.27	4 %
Multivariado	Experto	6	3		1.67	2.96	6 %
Multivariado	PCA	6	3		0.41	0.23	1 %
Multivariado - Fine Tunning	Experto	6	3	4.57	1.32	1.94	5 %
Multivariado - Fine Tunning	PCA	6	3	4.58	1.07	1.26	4 %
Univariado	Experto	6	3		13.01	170.13	47 %
Univariado - Fine Tunning	Experto	6	3	4.19	10.84	118.11	39 %

dolos con modelos de una sola modalidad, tanto univariados como multivariados, y finalmente, para 10 pozos específicos se realiza un proceso de *fine-tuning* y se compara el comportamiento de todos los modelos elaborados con las líneas base de los pronósticos elaborados con la metodología ARIMA. En los casos revisados, los modelos multimodales presentan un mejor comportamiento que los demás modelos de redes neuronales utilizados, exceptuando la predicción anual donde el modelo multivariado se comportó mejor. En cuanto a la comparación con ARIMA, el análisis revela que el modelo multimodal pre-

Tabla 5-10: Resultado de predicción de 6 pasos de tiempo con una ventana de 12 para un pozo específico

Tipo de modelo	Variables numéricas	wsize	ySteps	Tiempo de entrenamiento (s)	MAE Test	MSE Test	MAPE Test
ARIMA con menor AIC	Solo producción		6	268.45	1.44	2.98	6 %
Auto ARIMA	Solo producción		6	1.66	1.39	2.65	5 %
Modelo LSTM un solo pozo	Solo producción	12	6	10.92	1.33	2.76	5 %
Multimodal LSTM	PCA	12	6		5.82	34.86	22 %
Multimodal LSTM	Experto	12	6		1.45	3.78	6 %
Multimodal LSTM - Fine Tunning	PCA	12	6	5.55	4.31	20.10	16 %
Multimodal LSTM - Fine Tunning	Experto	12	6	5.26	1.87	5.61	7 %
Multimodal Transformer Encoder	PCA	12	6		2.47	6.58	9 %
Multimodal Transformer Encoder	Experto	12	6		1.49	3.92	6 %
Multimodal Transformer Encoder - Fine Tunning	PCA	12	6	3.01	2.68	8.81	10 %
Multimodal Transformer Encoder - Fine Tunning	Experto	12	6	3.26	2.01	6.10	8 %
Multivariado	PCA	12	6		3.10	10.61	12 %
Multivariado	Experto	12	6		1.28	3.11	5 %
Multivariado - Fine Tunning	PCA	12	6	4.38	3.24	12.20	12 %
Multivariado - Fine Tunning	Experto	12	6	4.39	1.62	4.40	6 %
Univariado	Experto	12	6		13.06	170.88	49 %
Univariado - Fine Tunning	Experto	12	6	4.13	10.14	103.50	38 %

senta un mejor comportamiento en la predicción trimestral y bi-anual, sin embargo, en la semestral y anual, el modelo ARIMA presenta mejores resultados. Un análisis detallado mostró que el modelo ARIMA muestra comportamiento superior al modelo multimodal cuando los datos de la serie de tiempo de producción son cercanos a la media, y no presentan tanta dispersión.

Tabla 5-11: Resultado de predicción de 6 pasos de tiempo con una ventana de 24 para un pozo específico

Tipo de modelo	Variables numéricas	wsize	ySteps	Tiempo de entrenamiento (s)	MAE Test	MSE Test	MAPE Test
ARIMA con menor AIC	Solo producción		6	268.45	1.44	2.98	6 %
Auto ARIMA	Solo producción		6	1.66	1.39	2.65	5 %
Modelo LSTM un solo pozo	Solo producción	24	6	12.75	8.07	85.69	31 %
Multimodal LSTM	PCA	24	6		3.42	12.58	13 %
Multimodal LSTM	Experto	24	6		2.09	5.27	8 %
Multimodal LSTM - Fine Tunning	PCA	24	6	5.68	2.79	9.29	11 %
Multimodal LSTM - Fine Tunning	Experto	24	6	5.73	1.20	2.63	5 %
Multimodal Transformer Encoder	PCA	24	6		5.22	29.37	20 %
Multimodal Transformer Encoder	Experto	24	6		4.33	26.11	17 %
Multimodal Transformer Encoder - Fine Tunning	Experto	24	6	3.48	3.99	22.96	16 %
Multimodal Transformer Encoder - Fine Tunning	PCA	24	6	3.44	3.94	19.79	15 %
Multivariado	PCA	24	6		2.33	6.09	9 %
Multivariado	Experto	24	6		1.39	3.54	6 %
Multivariado - Fine Tunning	PCA	24	6	4.53	3.70	16.80	14 %
Multivariado - Fine Tunning	Experto	24	6	4.46	1.91	6.37	8 %
Univariado	Experto	24	6		14.17	201.07	53 %
Univariado - Fine Tunning	Experto	24	6	4.10	7.56	58.40	28 %

Tabla 5-12: Resultado de predicción de 6 pasos de tiempo con una ventana de 36 para un pozo específico

Tipo de modelo	Variables numéricas	wsize	ySteps	Tiempo de entrenamiento (s)	MAE Test	MSE Test	MAPE Test
ARIMA con menor AIC	Solo producción		6	268.45	1.44	2.98	6 %
Auto ARIMA	Solo producción		6	1.66	1.39	2.65	5 %
Multimodal LSTM	PCA	36	6		3.77	16.33	14 %
Multimodal LSTM	Experto	36	6		1.26	2.79	5 %
Multimodal LSTM - Fine Tunning	PCA	36	6	5.69	2.19	7.45	9 %
Multimodal LSTM - Fine Tunning	Experto	36	6	5.69	1.76	5.51	7 %
Multimodal Transformer Encoder	Experto	36	6		3.92	20.03	15 %
Multimodal Transformer Encoder	PCA	36	6		3.49	14.18	13 %
Multimodal Transformer Encoder - Fine Tunning	PCA	36	6	3.39	3.21	13.05	12 %
Multimodal Transformer Encoder - Fine Tunning	Experto	36	6	3.56	2.77	10.14	11 %
Multivariado	PCA	36	6		4.27	19.40	16 %
Multivariado	Experto	36	6		1.24	2.32	5 %
Multivariado - Fine Tunning	PCA	36	6	4.45	4.19	20.07	16 %
Multivariado - Fine Tunning	Experto	36	6	4.57	1.30	3.33	5 %
Univariado	Experto	36	6		19.32	374.80	73 %
Univariado - Fine Tunning	Experto	36	6	4.23	15.73	253.45	60 %

Tabla 5-13: Resultado de predicción de 12 pasos de tiempo con una ventana de 24 para un pozo específico

Tipo de modelo	Variables numéricas	wsize	ySteps	Tiempo de entrenamiento (s)	MAE Test	MSE Test	MAPE Test
ARIMA con menor AIC	Solo producción		12	268.45	1.70	3.75	7 %
Auto ARIMA	Solo producción		12	1.66	1.44	2.75	6 %
Modelo LSTM un solo pozo	Solo producción	24	12	12.80	2.82	12.23	11 %
Multimodal LSTM	PCA	24	12		2.15	5.44	8 %
Multimodal LSTM	Experto	24	12		1.09	2.06	4 %
Multimodal LSTM - Fine Tunning	Experto	24	12	5.48	3.24	13.79	13 %
Multimodal LSTM - Fine Tunning	PCA	24	12	5.65	2.11	5.03	8 %
Multimodal Transformer Encoder	PCA	24	12		4.55	23.08	18 %
Multimodal Transformer Encoder	Experto	24	12		1.88	5.03	7 %
Multimodal Transformer Encoder - Fine Tunning	PCA	24	12	3.34	3.68	16.65	14 %
Multimodal Transformer Encoder - Fine Tunning	Experto	24	12	3.44	2.93	11.64	12 %
Multivariado	PCA	24	12		2.96	9.66	12 %
Multivariado	Experto	24	12		1.38	2.91	6 %
Multivariado - Fine Tunning	PCA	24	12	4.52	4.00	17.36	16 %
Multivariado - Fine Tunning	Experto	24	12	4.62	1.79	4.25	7 %
Univariado	Experto	24	12		10.32	111.03	40 %
Univariado - Fine Tunning	Experto	24	12	4.16	5.71	33.70	22 %

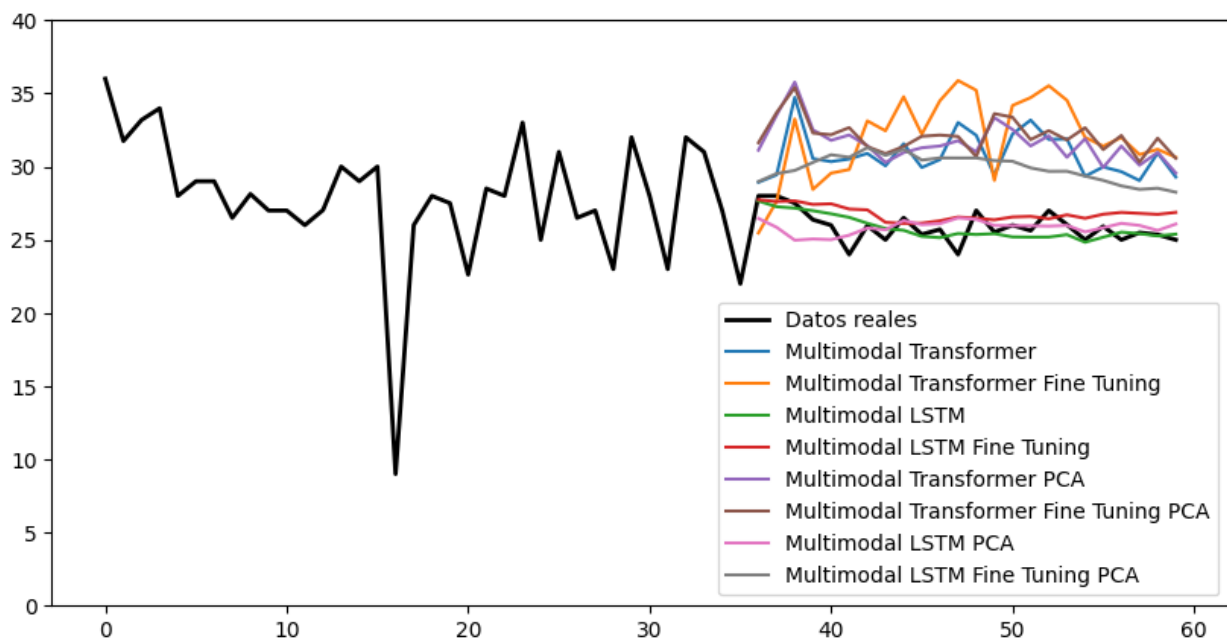
Tabla 5-14: Resultado de predicción de 12 pasos de tiempo con una ventana de 36 para un pozo específico

Tipo de modelo	Variables numéricas	wsize	ySteps	Tiempo de entrenamiento (s)	MAE Test	MSE Test	MAPE Test
ARIMA con menor AIC	Solo producción		12	268.45	1.70	3.75	7 %
Auto ARIMA	Solo producción		12	1.66	1.44	2.75	6 %
Modelo LSTM un solo pozo	Solo producción	36	12	15.18	11.37	181.64	45 %
Multimodal LSTM	PCA	36	12		4.57	21.69	18 %
Multimodal LSTM	Experto	36	12		1.90	4.62	8 %
Multimodal LSTM - Fine Tunning	PCA	36	12	5.74	5.39	30.98	21 %
Multimodal LSTM - Fine Tunning	Experto	36	12	5.78	1.84	4.48	7 %
Multimodal Transformer Encoder	Experto	36	12		2.76	10.46	11 %
Multimodal Transformer Encoder	PCA	36	12		2.87	12.65	11 %
Multimodal Transformer Encoder - Fine Tunning	PCA	36	12	3.38	2.69	10.35	10 %
Multimodal Transformer Encoder - Fine Tunning	Experto	36	12	3.66	2.32	8.42	9 %
Multivariado	Experto	36	12		1.58	3.66	6 %
Multivariado	PCA	36	12		0.95	1.56	4 %
Multivariado - Fine Tunning	Experto	36	12	4.29	2.44	7.14	10 %
Multivariado - Fine Tunning	PCA	36	12	4.56	1.94	4.51	8 %
Univariado	Experto	36	12		4.39	25.67	17 %
Univariado - Fine Tunning	Experto	36	12	4.12	5.75	34.21	22 %

Tabla 5-15: Resultado de predicción de 24 pasos de tiempo con una ventana de 36 para un pozo específico

Tipo de modelo	Variables numéricas	wsize	ySteps	Tiempo de entrenamiento (s)	MAE Test	MSE Test	MAPE Test
ARIMA con menor AIC	Solo producción		24	268.45	1.81	3.96	7 %
Auto ARIMA	Solo producción		24	1.66	1.32	2.28	5 %
Modelo LSTM un solo pozo	Solo producción	36	24	14.87	5.72	38.15	22 %
Multimodal LSTM	Experto	36	24		0.70	0.84	3 %
Multimodal LSTM	PCA	36	24		0.86	1.25	3 %
Multimodal LSTM - Fine Tunning	Experto	36	24	5.57	1.08	1.66	4 %
Multimodal LSTM - Fine Tunning	PCA	36	24	5.84	4.02	18.07	16 %
Multimodal Transformer Encoder	Experto	36	24		4.92	27.02	19 %
Multimodal Transformer Encoder	PCA	36	24		5.73	34.63	22 %
Multimodal Transformer Encoder - Fine Tunning	PCA	36	24	3.23	6.21	40.22	24 %
Multimodal Transformer Encoder - Fine Tunning	Experto	36	24	3.45	6.37	46.95	25 %
Multivariado	Experto	36	24		2.31	7.26	9 %
Multivariado	PCA	36	24		6.42	55.32	25 %
Multivariado - Fine Tunning	Experto	36	24	4.64	1.88	6.94	7 %
Multivariado - Fine Tunning	PCA	36	24	4.96	10.78	122.07	42 %
Univariado	Experto	36	24		8.88	91.53	34 %
Univariado - Fine Tunning	Experto	36	24	4.26	7.52	59.32	29 %

Figura 5-9: Resultados para un pozo determinado después del proceso de fine-tuning para todos los modelos.



6 Conclusiones y trabajo futuro

6.1. Conclusiones

El presente trabajo de investigación aporta modelos para pronósticos y clasificación de series de tiempo donde cada paso del tiempo cuenta con información multimodal de fuentes numéricas y de imágenes. Los modelos multimodales presentados mostraron buenos resultados frente a los modelos del estado del arte que son elaborados únicamente con información numérica.

Esta investigación presenta nuevos aportes en las áreas de clasificación y pronósticos de series de tiempo (TSC y TSF) que son principalmente abordadas con series de tiempo univariadas y multivariadas, proponiendo modelos de *deep learning* que permiten realizar clasificación y pronósticos de series de tiempo utilizando toda la información disponible cuando las series de tiempo son multimodales, esto es, cuando cada paso del tiempo contiene fuentes de distintas modalidades como datos numéricos e imágenes.

La arquitectura de *encoder* multimodal propuesto para las series de tiempo permite incorporar la información disponible acerca de fenómenos multimodales con distribución temporal a un modelo capaz de aprender no solo el comportamiento del fenómeno de acuerdo con cada fuente de datos por separado, sino también las relaciones complejas que existen entre las distintas fuentes y su impacto combinado en el fenómeno objeto de estudio, que para el caso presentado, corresponde a la predicción de la producción y las fallas asociadas a los pozos petroleros con bombeo mecánico.

En el área de clasificación de series de tiempo multimodales, enfocado en la predicción de fallas en pozos petroleros, el presente trabajo propone modelos multimodales y los compara con modelos de una sola modalidad encontrando los siguientes resultados:

- El modelo multimodal de clasificación de series de tiempo con capa LSTM para predicción de fallas en los pozos petroleros muestra una exactitud del 61.3 % su-

perando a los modelos de una sola modalidad que presentan una exactitud de entre el 54 % y 59 % que, si bien es un porcentaje bajo para un modelo de clasificación binaria, muestra resultados superiores a los demás modelos utilizados, y constituye un resultado aceptable dado que los datos utilizados son de fuentes reales. Sin embargo, el modelo multimodal basado en *transformers* no logra superar el ajuste obtenido por el modelo multimodal con capa LSTM, lo cual puede deberse a que no hay suficientes ejemplos de entrenamiento para que esta arquitectura de red neuronal aprenda los patrones asociados a los fenómenos estudiados.

- Dado que los datos existentes del fenómeno estudiado son desbalanceados en una proporción aproximada de 24 ejemplos negativos por cada ejemplo positivo, se presenta un modelo de *boosting* mediante el entrenamiento de 24 submodelos multimodales con capa LSTM entrenados cada uno con la totalidad de los ejemplos positivos y un muestreo aleatorio sin reemplazo de los ejemplos negativos. Este modelo si bien requiere un mayor tiempo de entrenamiento y de predicción, presenta una mejora sobre un conjunto de pruebas desbalanceado, mostrando para el caso de la metodología donde se promedian los resultados de cada submodelo un 67.6 % de exactitud frente al 53.1 % modelo entrenado con datos balanceados, y un 60.43 % de exactitud balanceada (*balanced accuracy*) frente al 57.05 % obtenido por el modelo entrenado con datos balanceados.
- Para el caso de la metodología donde se obtiene la predicción por votación de los submodelos, el modelo de *boosting* presenta un 64.08 % de exactitud que si bien es inferior a la metodología donde se promedia el resultado de los submodelos, sigue siendo superior al modelo entrenado con datos balanceados, y un 61.19 % de exactitud balanceada que es superior tanto a la metodología de promedio como al modelo entrenado con datos balanceados.

En la sección de pronósticos de producción, que corresponde al área de pronósticos de series de tiempo multimodales se entrenaron modelos multimodales que fueron comparados con modelos univariados, multivariados basados en redes neuronales, y con el modelo ARIMA. Para este caso se presentan los siguientes resultados:

- Dado que para el caso de estudio se deben realizar pronósticos donde los datos de entrada son multimodales y la salida es una única variable, se proponen modelos multimodales capaces de realizar la predicción de una cantidad de pasos de tiempo definida en una sola iteración (*one-shot multi-step forecasting*). Para este objetivo

se utilizan ejemplos que toman ventanas de tiempo con periodicidad mensual de 6, 12 y 24 pasos de tiempo en el pasado para pronosticar 3, 6, 12 y 24 pasos futuros. Las arquitecturas utilizadas en los modelos multimodales son el modelo multimodal con capa LSTM y el modelo multimodal con *transformer encoder*.

- Para los casos revisados, los modelos multimodales con capa LSTM presentan un mejor comportamiento que los demás modelos de redes neuronales utilizados, exceptuando la predicción anual donde el modelo multivariado se comportó mejor. En cuanto a la comparación con la línea base de las implementaciones realizadas de la metodología ARIMA, el análisis muestra que el modelo multimodal con capa LSTM presenta un mejor comportamiento en la predicción trimestral y bi-anual, donde presenta un error porcentual absoluto medio de 8 % llegando a 2 % en casos específicos, sin embargo, en la semestral y anual, el modelo ARIMA presenta mejores resultados. Un análisis detallado mostró que el modelo ARIMA muestra comportamiento superior al modelo multimodal cuando los datos de la serie de tiempo de producción son cercanos a la media, y no presentan una alta dispersión.

Los modelos multimodales basados en *transformers* no presentan buenos resultados para los casos de uso estudiados, esto puede deberse a que no hay suficientes ejemplos de entrenamiento para que esta arquitectura de red neuronal aprenda los patrones asociados a los fenómenos estudiados, ya que en la literatura se muestra que los transformers presentan mejores resultados que otras arquitecturas cuando son entrenados sobre grandes volúmenes de datos.

Los modelos presentados para pronósticos de producción y predicción de fallas en pozos petroleros con bombeo mecánico contribuyen de manera significativa a la industria petrolera creando una línea de investigación donde se utilice información multimodal de todas las fuentes disponibles para mejorar los resultados, permitiendo una planeación presupuestal y de mantenimientos que se ajuste de mejor manera a la realidad de cada pozo.

6.2. Trabajo futuro

El presente trabajo se elaboró con los datos de un campo petrolero en Colombia. Dado el potencial de la arquitectura multimodal propuesta, se recomienda recopilar datos de

otros campos para obtener un modelo más generalizado y con mayor cantidad información que le permita aprender otros patrones asociados al fenómeno de producción de petróleo, para que de esta manera pueda ser utilizado en análisis de cualquier campo petrolero, incluyendo aquellos que por su tamaño o por ser desarrollados recientemente no cuenten con suficientes datos para entrenar un modelo con la arquitectura presentada.

Dada la calidad de los datos se podría intentar implementar otros métodos de preprocesamiento, especialmente en el caso de la imputación de imágenes faltantes, generando así otros conjuntos de datos para los modelos que permitan analizar el impacto del preprocesamiento en el resultado final de los modelos. De manera adicional, se debe continuar evaluando para cada caso de uso el tamaño de la ventana de tiempo a utilizar para la clasificación y pronóstico de la serie de tiempo

Se debe continuar investigando sobre la implementación de la arquitectura de modelo multimodal basado en *transformers*, evaluando los diferentes *encodings* posicionales propuestos en la literatura con el fin de explotar de mejor manera el potencial mostrado por esta arquitectura en las áreas de pronósticos y clasificación de series de tiempo multivariadas, y extenderlo al área de series de tiempo multimodales.

Una línea de investigación distinta al modelo presentado que puede ser explorada para las series de tiempo multimodales, es el procesamiento y fusión de datos multimodales mediante el uso de *autoencoders* para luego utilizarlos en los modelos de clasificación y pronósticos de series de tiempo multimodales. Sin embargo, se debe tener en cuenta que para un correcto entrenamiento de este tipo de modelos se debe contar con una cantidad de datos suficiente para que el modelo se entrene y logre representarlos adecuadamente.

Se recomienda implementar los modelos propuestos en el estudio de otros fenómenos con fuentes de información multimodal distribuida en el tiempo para validar el comportamiento de la arquitectura propuesta en distintas industrias y aplicaciones tales como detección temprana de anomalías en el desarrollo prenatal en el área de la medicina, o el seguimiento y modelado de crecimiento de cultivos en el área agroindustrial.

La arquitectura propuesta está siendo implementada como servicio en una aplicación de manejo de información con modelo de datos flexible para permitir a usuarios de cualquier industria entrenar y utilizar sus propios modelos de clasificación y pronósticos de

manera sencilla bien sea que las fuentes de datos presenten o no información multimodal.

Bibliografía

- [1] Abadi, Martín ; Agarwal, Ashish ; Barham, Paul ; Brevdo, Eugene ; Chen, Zhifeng ; Citro, Craig ; Corrado, Greg S. ; Davis, Andy ; Dean, Jeffrey ; Devin, Matthieu ; Ghemawat, Sanjay ; Goodfellow, Ian ; Harp, Andrew ; Irving, Geoffrey ; Isard, Michael ; Jia, Yangqing ; Jozefowicz, Rafal ; Kaiser, Lukasz ; Kudlur, Manjunath ; Levenberg, Josh ; Mané, Dandelion ; Monga, Rajat ; Moore, Sherry ; Murray, Derek ; Olah, Chris ; Schuster, Mike ; Shlens, Jonathon ; Steiner, Benoit ; Sutskever, Ilya ; Talwar, Kunal ; Tucker, Paul ; Vanhoucke, Vincent ; Vasudevan, Vijay ; Viégas, Fernanda ; Vinyals, Oriol ; Warden, Pete ; Wattenberg, Martin ; Wicke, Martin ; Yu, Yuan ; Zheng, Xiaoqiang: *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. – Software available from tensorflow.org
- [2] Aizenberg, Igor ; Sheremetov, Leonid ; Villa-Vargas, Luis ; Martinez-Muñoz, Jorge: Multilayer Neural Network with Multi-Valued Neurons in time series forecasting of oil production. En: *Neurocomputing* 175 (2016), jan, p. 980–989. – ISSN 0925–2312
- [3] Anderson, Roger N. ; Xie, Boyi ; Wu, Leon ; Kressner, Arthur A. ; Frantz Jr., Joseph H. ; Ockree, Matthew A. ; Brown, Kenneth G.: Petroleum Analytics Learning Machine to Forecast Production in the Wet Gas Marcellus Shale. En: *Proceedings of the 4th Unconventional Resources Technology Conference*. Tulsa, OK, USA : American Association of Petroleum Geologists, aug 2016. – ISBN 978–0–9912144–3–3
- [4] Arps, J.J.: *Analysis of Decline Curves*, Society of Petroleum Engineers, dec 2013. – ISBN 0081–1696–01
- [5] Bello-Angulo, David ; León-Guzmán, Elizabeth: Multi-Modal Recurrent Model for Timeseries Classification: A Use Case on Failure Prediction in Oil Wells with Rod Lift System. En: *10th International conference on Time Series and Forecasting (2023)*, 12. – ISSN in press
- [6] Bello-Angulo, David ; Mantilla-Duarte, Carlos ; Montes-Paez, Erik ; Guerrero-Martin, Camilo: Box–Jenkins Methodology Application to Improve Crude Oil Production Fo-

- recasting: Case Study in a Colombian Field. En: *Arabian Journal for Science and Engineering* 47 (2022), 9, p. 11269–11278. – ISSN 21914281
- [7] Cao, Q. ; Banerjee, R. ; Gupta, S. ; Li, J. ; Zhou, W. ; Jeyachandra, B.: Data Driven Production Forecasting Using Machine Learning. En: *SPE Argentina Exploration and Production of Unconventional Resources Symposium*, Society of Petroleum Engineers, jun 2016. – ISBN 978–1–61399–474–0
- [8] Chen, Chaohui ; Gao, Guohua ; Honorio, Jean ; Gelderblom, Paul ; Jimenez, Eduardo ; Jaakkola, Tommi: Integration of Principal-Component-Analysis and Streamline Information for the History Matching of Channelized Reservoirs. En: *SPE Annual Technical Conference and Exhibition*, Society of Petroleum Engineers, oct 2014
- [9] Collins, Patrick ; Ilk, Dilhan ; Blasingame, Thomas A.: Practical Considerations for Forecasting Production Data in Unconventional Reservoirs — Variable Pressure Drop Case. En: *SPE Annual Technical Conference and Exhibition*, Society of Petroleum Engineers, oct 2014
- [10] Dana Lahat, Christian J.: Multimodal Data Fusion: An Overview of Methods, Challenges and Prospects, Institute of Electrical and Electronics Engineers, jul 2015
- [11] Deng, Houtao ; Runger, George ; Tuv, Eugene ; Vladimir, Martyanov: A Time Series Forest for Classification and Feature Extraction. En: *Information Sciences* 239 (2013), 2, p. 142–153. – ISSN 00200255
- [12] Duffer, Philipp ; Schmitt, Martin ; Schütze, Hinrich: Position Information in Transformers: An Overview. En: *Computational Linguistics* 48 (2022), 9, p. 733–763. – ISSN 15309312
- [13] Dursun, Serkan ; Rangarajan, Keshava ; Singh, Amit: A Framework-Oriented Approach for Determining Attribute Importance When Building Effective Predictive Models for Oil and Gas Data Analytics. En: *SPE Annual Technical Conference and Exhibition*, Society of Petroleum Engineers, sep 2013. – ISBN 978–1–61399–240–1
- [14] Dzurman, Peter J. ; Leung, Juliana Yuk W. ; Zanon, Stefan David J. ; Amirian, Ehsan: Data-Driven Modeling Approach for Recovery Performance Prediction in SAGD Operations. En: *SPE Heavy Oil Conference-Canada*, Society of Petroleum Engineers, jun 2013. – ISBN 978–1–61399–262–3
- [15] Echometer. *Total Well Management (TWM)*. 2012

- [16] Echometer. *Total Asset Monitor (TAM)*. 2022
- [17] Fawaz, Hassan I. ; Lucas, Benjamin ; Forestier, Germain ; Pelletier, Charlotte ; Schmidt, Daniel F. ; Weber, Jonathan ; Webb, Geoffrey I. ; Idoumghar, Lhassane ; Muller, Pierre A. ; Petitjean, François: InceptionTime: Finding AlexNet for Time Series Classification. En: *Data Mining and Knowledge Discovery* 34 (2019), 9, p. 1936–1962. – ISBN 1061802000710
- [18] Fetkovich, M.J.: *Decline Curve Analysis Using Type Curves*, Society of Petroleum Engineers, jun 1980
- [19] Foumani, Navid M. ; Miller, Lynn ; Tan, Chang W. ; Webb, Geoffrey I. ; Forestier, Germain ; Salehi, Mahsa: Deep Learning for Time Series Classification and Extrinsic Regression: A Current Survey. (2023), 2
- [20] Foumani, Navid M. ; Tan, Chang W. ; Webb, Geoffrey I. ; Salehi, Mahsa: Improving position encoding of transformers for multivariate time series classification. En: *Data Mining and Knowledge Discovery* (2023), 9, p. 1–27. – ISSN 1573756X
- [21] Goldsmith, Jeff ; Scheipl, Fabian: Estimator selection and combination in scalar-on-function regression. En: *Computational Statistics and Data Analysis* 70 (2014), 2, p. 362–372. – ISSN 0167–9473
- [22] Gupta, Siddhartha ; Fuehrer, Franz ; Jeyachandra, Benin C.: Production Forecasting in Unconventional Resources using Data Mining and Time Series Analysis. En: *SPE/CSUR Unconventional Resources Conference – Canada*, Society of Petroleum Engineers, sep 2014. – ISBN 978–1–61399–363–7
- [23] Huang, Zhiheng ; Liang, Davis ; Xu, Peng ; Xiang, Bing: Improve Transformer Models with Better Relative Position Embeddings. En: *Findings of the Association for Computational Linguistics Findings of ACL: EMNLP 2020* (2020), 9, p. 3327–3335. ISBN 9781952148903
- [24] Jia, Xinli ; Zhang, Feifei: Applying Data-Driven Method to Production Decline Analysis and Forecasting. En: *SPE Annual Technical Conference and Exhibition*, Society of Petroleum Engineers, sep 2016. – ISBN 978–1–61399–463–4
- [25] Jiang, Hao ; Liu, Lianguang ; Lian, Cheng: Multi-Modal Fusion Transformer for Multivariate Time Series Classification. En: *2022 14th International Conference*

on Advanced Computational Intelligence, ICACI 2022 (2022), p. 284–288. ISBN 9781665470452

- [26] Kingma, Diederik P. ; Ba, Jimmy L.: Adam: A Method for Stochastic Optimization. En: *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings* (2014), 12
- [27] Kostas, Demetres ; Aroca-Ouellette, Stéphane ; Rudzicz, Frank: BENDR: using transformers and a contrastive self-supervised learning task to learn from massive amounts of EEG data. En: *Frontiers in Human Neuroscience* 15 (2021), 1. – ISSN 16625161
- [28] Li, X. ; Chan, C.W. ; Nguyen, H.H.: Application of the Neural Decision Tree approach for prediction of petroleum production. En: *Journal of Petroleum Science and Engineering* 104 (2013), apr, p. 11–16. – ISSN 0920–4105
- [29] Li, Yunan ; Han, Yifu: Decline Curve Analysis for Production Forecasting Based on Machine Learning. En: *SPE Symposium: Production Enhancement and Cost Optimisation*, Society of Petroleum Engineers, nov 2017. – ISBN 978–1–61399–561–7
- [30] Lin, Jessica ; Khade, Rohan ; Li, Yuan: Rotation-invariant similarity in time series using bag-of-patterns representation. En: *Journal of Intelligent Information Systems* 39 (2012), 10, p. 287–315. – ISSN 09259902
- [31] Liu, Jeremy ; Jaiswal, Ayush ; Yao, Ke-Thia ; Raghavendra, Cauligi S.: Autoencoder-derived Features as Inputs to Classification Algorithms for Predicting Well Failures. En: *SPE Western Regional Meeting*, Society of Petroleum Engineers, apr 2015. – ISBN 978–1–61399–404–7
- [32] Liu, Y. ; Yao, Ke-Thia ; Liu, Shuping ; Raghavendra, Cauligi S. ; Lenz, Tracy L. ; Olabinjo, Lanre ; Seren, F. B. ; Seddighrad, Sanaz ; Dinesh Babu, C.G.: Failure Prediction for Artificial Lift Systems. En: *SPE Western Regional Meeting*, Society of Petroleum Engineers, apr 2010. – ISBN 978–1–55563–294–6
- [33] Lolon, E. ; Hamidieh, K. ; Weijers, L. ; Mayerhofer, M. ; Melcher, H. ; Oduba, O.: Evaluating the Relationship Between Well Parameters and Production Using Multivariate Statistical Models: A Middle Bakken and Three Forks Case History. En: *SPE Hydraulic Fracturing Technology Conference*, Society of Petroleum Engineers, feb 2016. – ISBN 978–1–61399–438–2

- [34] Ma, Zhiwei ; Liu, Yaqi ; Leung, Juliana Y. ; Zanon, Stefan: Practical Data Mining and Artificial Neural Network Modeling for SAGD Production Analysis. En: *SPE Canada Heavy Oil Technical Conference*, Society of Petroleum Engineers, jun 2015. – ISBN 978–1–61399–402–3
- [35] Malhotra, Pankaj ; Vishnu, T. V. ; Vig, Lovekesh ; Agarwal, Puneet ; Shroff, Gautam: TimeNet: Pre-trained deep recurrent neural network for time series classification. En: *ESANN 2017 - Proceedings, 25th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (2017)*, 6, p. 607–612. ISBN 9782875870391
- [36] Martin, Eileen ; Wills, Peter ; Hohl, Detlef ; Lopez, Jorge L.: Using Machine Learning to Predict Production at a Peace River Thermal EOR Site. En: *SPE Reservoir Simulation Conference*, Society of Petroleum Engineers, feb 2017. – ISBN 978–1–61399–483–2
- [37] Montes, Erik G. ; Delgadillo, Claudia L. ; Calvete, Fernando E.: APLICACIÓN DE LA SIMULACIÓN NUMÉRICA DE YACIMIENTOS EN EL ANÁLISIS DE LOS FACTORES QUE AFECTAN LOS PRONÓSTICOS DE PRODUCCIÓN DE PETRÓLEO, 2015. – ISSN 2346–0466
- [38] Montes, Erik G. ; Mantilla, Carlos A. ; Bello, David E.: Herramienta software DeclineR para la elaboración automatizada de pronósticos de producción, mediante análisis de series de tiempo, Ingepet, oct 2018
- [39] Montes Páez, Erik G. ; Calvete González, Fernando E. ; Mantilla Duarte, Carlos A.: APLICACIÓN DE SERIES DE TIEMPO EN LA REALIZACIÓN DE PRONÓSTICOS DE PRODUCCIÓN, 2016. – ISSN 16576527, p. 79–88
- [40] Mutegeki, Ronald ; Han, Dong S.: A CNN-LSTM Approach to Human Activity Recognition. En: *2020 International Conference on Artificial Intelligence in Information and Communication, ICAIIC 2020 (2020)*, 2, p. 362–366. ISBN 9781728149851
- [41] Olominu, Oluwafemi ; Sulaimon, Aliyu A.: Application of Time Series Analysis to Predict Reservoir Production Performance. En: *SPE Nigeria Annual International Conference and Exhibition*, Society of Petroleum Engineers, aug 2014. – ISBN 978–1–61399–358–3

- [42] Pennington, Jeffrey ; Socher, Richard ; Manning, Christopher D.: GloVe: Global Vectors for Word Representation. En: *Conference on Empirical Methods in Natural Language Processing*, 2014
- [43] Popa, Andrei S. ; Patel, Anil N.: Neural Networks for Production Curve Pattern Recognition Applied to Cyclic Steam Optimization in Diatomite Reservoirs. En: *SPE Western Regional Meeting*, Society of Petroleum Engineers, apr 2012
- [44] Raghavenda, Cauligi S. ; Liu, Yintao ; Wu, Anqi ; Olabinjo, Lanre ; Balogun, Oluwafemi ; Ershaghi, Iraj ; Zheng, Jingwen ; Guo, Dong ; Yao, Ke-Thia: Global Model for Failure Prediction for Rod Pump Artificial Lift Systems. En: *SPE Western Regional & AAPG Pacific Section Meeting 2013 Joint Technical Conference*, Society of Petroleum Engineers, apr 2013. – ISBN 978–1–61399–264–7
- [45] Rebeschini, J. ; Querales, M. ; Carvajal, G. A. ; Villamizar, M. ; Md Adnan, F. ; Rodriguez, J. ; Knabe, S. ; Rivas, F. ; Saputelli, L. ; Al-Jasmi, A. ; Nasr, H. ; Goel, H. K.: Building Neural-Network-Based Models Using Nodal and Time-Series Analysis for Short-Term Production Forecasting. En: *SPE Middle East Intelligent Energy Conference and Exhibition*, Society of Petroleum Engineers, oct 2013. – ISBN 978–1–61399–276–0
- [46] Schuetter, Jared ; Mishra, Srikanta ; Zhong, Ming ; LaFollette, Randy: A Data-Analytics Tutorial: Building Predictive Models for Oil Production in an Unconventional Shale Reservoir. En: *SPE Journal* (2018), mar. – ISSN 1086–055X
- [47] Smith, Taylor G. [u. a.]: *pmdarima: ARIMA estimators for Python*. 2017–. – [Online; accessed 2023-12-13]
- [48] Suhag, Anuj ; Ranjith, Rahul ; Aminzadeh, Fred: Comparison of Shale Oil Production Forecasting using Empirical Methods and Artificial Neural Networks. En: *SPE Annual Technical Conference and Exhibition*, Society of Petroleum Engineers, oct 2017. – ISBN 978–1–61399–542–6
- [49] Tan, Chang W. ; Bergmeir, Christoph ; Petitjean, Francois ; Webb, Geoffrey I.: Time Series Extrinsic Regression. En: *Data Mining and Knowledge Discovery* 35 (2020), 6, p. 1032–1060. – ISSN 1384–5810
- [50] Tang, Yujin ; Xu, Jianfeng ; Matsumoto, Kazunori ; Ono, Chihiro: Sequence-To-Sequence Model with Attention for Time Series Classification. En: *IEEE International*

- Conference on Data Mining Workshops, ICDMW 0* (2016), 7, p. 503–510. – ISBN 9781509054725
- [51] Valko, Peter P. ; Lee, W. J.: A Better Way To Forecast Production From Unconventional Gas Wells. En: *SPE Annual Technical Conference and Exhibition*, Society of Petroleum Engineers, apr 2010
- [52] Vaswani, Ashish ; Shazeer, Noam ; Parmar, Niki ; Uszkoreit, Jakob ; Jones, Llion ; Gomez, Aidan N. ; Łukasz Kaiser ; Polosukhin, Illia: Attention Is All You Need. En: *Advances in Neural Information Processing Systems 2017-December* (2017), 6, p. 5999–6009. – ISBN 1706.03762v7
- [53] Vyas, Aditya ; Datta-Gupta, Akhil ; Mishra, Srikanta: Modeling Early Time Rate Decline in Unconventional Reservoirs Using Machine Learning Techniques. En: *Abu Dhabi International Petroleum Exhibition & Conference*, Society of Petroleum Engineers, nov 2017. – ISBN 978–1–61399–563–1
- [54] Wang, Zhiguang ; Yan, Weizhong ; Oates, Tim: Time Series Classification from Scratch with Deep Neural Networks: A Strong Baseline. En: *Proceedings of the International Joint Conference on Neural Networks 2017-May* (2016), 11, p. 1578–1585. ISBN 9781509061815
- [55] Wu, Kan ; Peng, Houwen ; Chen, Minghao ; Fu, Jianlong ; Chao, Hongyang: Rethinking and Improving Relative Position Encoding for Vision Transformer. En: *Proceedings of the IEEE International Conference on Computer Vision* (2021), 7, p. 10013–10021. – ISBN 9781665428125
- [56] Xian, Qingyu ; Liang, Wenxuan: A Multi-modal Time Series Intelligent Prediction Model. En: *Lecture Notes in Electrical Engineering 942 LNEE* (2022), p. 1150–1157. – ISBN 9789811924552
- [57] Xue, Wang ; Zhou, Tian ; Wen, Qingsong ; Gao, Jinyang ; Ding, Bolin ; Jin, Rong: Make Transformer Great Again for Time Series Forecasting: Channel Aligned Robust Dual Transformer. (2023), 5
- [58] Zerveas, George ; Jayaraman, Srideepika ; Patel, Dhaval ; Bhamidipaty, Anuradha ; Eickhoff, Carsten: A Transformer-based Framework for Multivariate Time Series Representation Learning. En: *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining 11* (2021), 8, p. 2114–2124. ISBN 9781450383325

- [59] Zheng, Jingwen ; Leung, Juliana Y. ; Sawatzky, Ronald P. ; Alvarez, Jose M.: A Proxy Model for Predicting SAGD Production from Reservoirs Containing Shale Barriers. En: *SPE Canada Heavy Oil Technical Conference*, Society of Petroleum Engineers, jun 2016. – ISBN 978–1–61399–471–9
- [60] Zhou, Peng ; Sang, Huiyan ; Jin, Liuyi ; Lee, W. J.: Application of Statistical Methods to Predict Production From Liquid-Rich Shale Reservoirs. En: *Proceedings of the 5th Unconventional Resources Technology Conference*. Tulsa, OK, USA : American Association of Petroleum Geologists, jul 2017. – ISBN 978–0–9912144–4–0
- [61] Zhu, Qiding ; Zhang, Shukui ; Zhang, Yang ; Yu, Chunqing ; Dang, Mengli ; Zhang, Li: Multimodal time series data fusion based on SSAE and LSTM. En: *IEEE Wireless Communications and Networking Conference, WCNC 2021-March (2021)*. – ISBN 9781728195056