

Study of Oil Urban Fragmentation in the Vaca Muerta Region using Data Mining and Machine Learning

María Laura Langhoff¹[0000-0002-1534-9534] and Juan Pons²[0009-0000-8455-6898]

¹ CONICET. Instituto Argentino de Oceanografía. Bahía Blanca, Argentina.

² CONICET, Universidad Nacional del Sur. Bahía Blanca, Argentina
marialauralanghoff@gmail.com juan_pons@yahoo.com

Abstract. The aim of this paper is to contribute to the studies of the urban fragmentation process by means of Oil&Gas activity in the Añelo region, center of Vaca Muerta (Neuquén). For this purpose, the data mining technique and model training were used to analyze the evolution of real estate prices. A time range was taken from June 2020 to June 2021, which allowed us to establish a model to predict the evolution of values for subsequent periods. The predictive model incorporated the investments made by more than ten companies engaged in exploration and production activities in Vaca Muerta. In this work we start from the premise that Añelo is an urban center that in the last 15 years has undergone urban transformations due to the increase of oil&gas activity associated with the exploitation of the Vaca Muerta geological formation, by non-conventional method. One of the objectives of this work is to present the possibility of incorporating Artificial Intelligence (AI) as a predictive tool to complement geographic works on spatial transformations caused by hydrocarbon extraction. Two results were obtained: on the one hand, the model developed is presented as a tool for individuals as well as public and private agents linked to urban planning and the real estate market. On the other hand, it is highlighted how the incorporation of AI to the analysis of urban alterations from geography allows the elaboration of predictive models for localities within areas of exploitation of strategic resources such as oil&gas

Keywords: urban fragmentation; machine learning; Vaca Muerta; housing; real estate market.

Estudio de la Fragmentación Urbana Petrolera en la Región de Vaca Muerta mediante Minería de Datos y Aprendizaje Automático

Resumen. El trabajo se propone brindar una contribución a los estudios del proceso de fragmentación urbana por medio de la actividad hidrocarburífera en la región de Añelo, centro de Vaca Muerta (Neuquén). Para ello se utilizó la técnica de minería de datos y el entrenamiento de modelos para analizar la evolución de los precios de propiedades inmuebles. Se tomó un rango temporal de junio de 2020 a junio de 2021, lo que permitió establecer un modelo para predecir la evolución de valores para períodos siguientes. Se incorporó al modelo predictivo las inversiones realizadas por más de diez empresas que desarrollan su actividad de exploración y explotación en Vaca Muerta. En este trabajo partimos de la premisa que Añelo es un centro urbano que en los últimos 15 años ha sufrido transformaciones de índole urbanística por el incremento de la actividad petrolera asociada a la explotación de la formación geológica Vaca Muerta, por método no convencional. Uno de los objetivos del trabajo es presentar la posibilidad de incorporar la Inteligencia Artificial (IA) como una herramienta de carácter predictivo para complementar trabajos geográficos sobre transformaciones espaciales originadas por la extracción de hidrocarburos. Se obtuvieron dos resultados, por un lado, el modelo elaborado se presenta como una herramienta tanto para particulares como agentes públicos y privados vinculados a la proyección urbanística y al mercado inmobiliario. Por otro, se destaca cómo la incorporación de la IA al análisis de las alteraciones urbanas desde la geografía permite la elaboración de modelos de carácter predictivo para localidades dentro de áreas de explotación de recursos estratégicos como los hidrocarburos.

Palabras clave: fragmentación urbana; aprendizaje de máquina; Vaca Muerta; viviendas; mercado inmobiliario.

1 Introducción

El área de estudio se caracteriza por ser una de las más dinámicas económica y poblacionalmente dentro de la región patagónica argentina debido al boom hidrocarburífero de Vaca Muerta. Esta región se ubica sobre la cuenca sedimentaria neuquina, una de las más productivas del país. En 2010 se definió el potencial productivo de la formación geológica Vaca Muerta, con lo cual se generó un nuevo capítulo dentro de la extracción de combustibles fósiles en el país. Por entonces Repsol YPF anunció el hallazgo de reservas que superaban ampliamente las de otras formaciones, estimándose en unos 29 mil millones de barriles equivalentes de petróleo. De allí en adelante las

expectativas en el ámbito petrolero y las finanzas asociadas, se expandieron y se territorializaron.

En el año 2013 se aprobó en la legislatura neuquina el acuerdo entre la multinacional Chevron y Repsol YPF. La primera sería el socio financiero y la segunda la operadora. Todo el debate se dio bajo una fuerte represión a quienes se oponían a la intensificación de la explotación no convencional. Ese fue un hito en la territorialización progresiva de los no convencionales. En cierta forma Vaca Muerta emergió por medio de multiplicación de locaciones, caminos, basureros petroleros, aumento de los consumos de agua dulce y de tránsito de camiones para transporte de arenas de sílice y químicos para las perforaciones. En resumen, se fortaleció la territorialización petrolera neuquina desarrollada a lo largo del siglo XX (Favaro, 2021)

Paralelamente, las ciudades y localidades cercanas a los centros operativos transformaron rápidamente su estructura urbana y, también, comenzó a aumentar la población que llegó para trabajar temporariamente en las locaciones. Estos nuevos procesos territoriales son ampliamente estudiados desde la línea de estudios sociales del petróleo (ESP) llevados adelante en Argentina, los cuales buscan analizar y visibilizar las dinámicas socioambientales, espaciales y políticas que se despliegan junto con la extracción hidrocarburífera. El eje es Vaca Muerta, como elemento ya no solo geológico, sino también aquí lo planteamos como tecnopolítico y sociopolítico (Folchi, Blanco Wells, & Meier, 2019). Como antecedentes aquí destacamos los trabajos de Pérez Roig et al. (Pérez Roig, Scandizzo, & di Risio, 2016) donde se aborda ampliamente tanto los aspectos históricos de la explotación de hidrocarburos en Argentina, las interacciones entre empresas y el Estado y los devenires de la petrolera estatal y su nuevo rol en el escenario no convencional. Los estudios de Acacio y Wyczykier vinculados al análisis de los hidrocarburos como energías extremas con la aplicación de la fractura hidráulica y cómo interfiere en los territorios y los actores que se expresan, también marcan un camino para comprender las dimensiones que cubre Vaca Muerta (Acacio & Wyczykier, 2019; Wyczykier & Acacio, 2021).

2 Marco de Referencia: fragmentación urbana e inteligencia artificial

Aquí usamos el concepto de fragmentación urbana puesto que entendemos que es el proceso que se da en una localidad pequeña como Añelo, que pasó de un perfil rural a petrolero en muy poco tiempo. Este proceso se manifiesta cuando se producen desconexiones, rupturas o separaciones de la estructura preexistente urbana, sin que necesariamente se produzcan luego integraciones entre los nuevos espacios resultantes (Pérez Peñuelas, 2021). Dentro de esta fragmentación, y siguiendo a la misma autora, rescatamos la fragmentación territorial, donde se delinean nuevas funciones urbanas e infraestructura.

Precisamente en este caso seleccionamos este concepto como guía dado que es debatible si en la zona se produce un proceso de gentrificación. Para el caso de la capital neuquina Perren y Cabezas han estudiado el proceso gentrificador con características locales y, en parte, influido por el auge hidrocarburífero en las últimas décadas (Perren

& Cabezas, 2020). En su análisis resaltan la necesidad de profundizar los estudios a nivel regional para determinar en qué medida se da esta transformación. Para el caso de Añelo podemos advertir un proceso posible de gentrificación con el aumento del valor del suelo y propiedades ante la demanda habitacional para los trabajadores petroleros e, incluso, para instalaciones en el sector periurbano. No obstante, en primer término, observamos una desestructuración de la trama urbana que se fue consolidando en los últimos veinte años.

En esta línea, siguiendo a Kozak, la dimensión de análisis espacial se desagrega en barreras físicas, obstáculos y límites que crean la fragmentación socio-espacial (Kozak, 2012). Dentro de los elementos que en cierta forma definen esta fragmentación, se encuentran las redes y avances tecnológicos aplicados a un sector urbano para conectar facilitar determinadas actividades y la conexión de un tipo de usuarios (Graham y Marvin, citados por Kozak, 2018). A esta situación contribuyen las actividades extractivas que acaban apropiándose de centros de centros urbanos dentro de su área y restructurandolos de forma directa e indirecta.

Para analizar el proceso de fragmentación urbana tomando las variables de aumento del valor del suelo por demanda, consideramos integrar el uso de herramientas de la IA como machine learning para el trabajo con datos de valores en el mercado inmobiliario. Utilizamos como insumo de los modelos entrenados mediante machine learning, los valores de casas, departamentos y PH en la región de Añelo. También incorporamos al aprendizaje los datos de inversiones realizadas por las empresas operadoras en Vaca Muerta. Estos dataset describen de forma directa y significativa la intervención económica en la región. Este cruce disciplinario entre las ciencias sociales y la informática promete posibilidades de ampliación de conocimiento en casos puntuales como el aquí propuesto, dado que permite el proceso de grandes volúmenes de información, identificación de patrones y facilitar análisis complejos (Hernández-Lugo, 2024). Así mismo es un instrumento que utilizado de manera positiva contribuye a la toma de decisiones y una mayor eficiencia en el campo de aplicación (Jimenez Pérez & Hernandez de la Cruz, 2023).

3 Metodología

Mediante técnicas de Machine Learning (ML) modelizamos la dinámica interna del referido proceso y predecimos tendencias del mercado inmobiliario, ya no solo para la localidad sino en la región. A los fines de estandarizar las variables que deseamos predecir, se utilizó un indicador conformado por el cociente del valor de la propiedad medido en dólares y la unidad de superficie medida en metros cuadrados. Decidimos utilizar este indicador porque garantiza cierto grado de perdurabilidad, para extrapolar el modelo predictivo y obtener valores comparables en el futuro. Se consideró la evolución de los valores de inmuebles para venta registrados durante el período junio -2020 a junio-2021, con el fin de entrenar mediante ML varios modelos de ensamble (EM), entre ellos AdaBoost, Random Forest y Gradient Boosting.

También utilizamos como insumo para entrenar el modelo predictivo, las series temporales que presentan las inversiones realizadas por todas las empresas que exploran y

explotan Vaca Muerta. Consideramos YPF, EXXON, TECPETROL, CHEVRON, TOTAL AUSTRAL, VISTA ENERGY y demás operadores. Los dataset de inversiones se obtuvieron en repositorios públicos de la Secretaría de Energía de la Nación Argentina. Incluimos estos datos porque consideramos que tienen una fuerte correlación con el valor de la vivienda. De esta manera asociamos el proceso de fragmentación urbana, que tiende a desplazar geográficamente a la población urbana según la capacidad económica que posee cada uno para adquirir una vivienda, con la intervención económica de las empresas operadoras que inyectan en la región importantes inversiones de capital.

En las secciones siguientes se muestra el desempeño de los modelos elegidos. Se comparan entre sí mediante el coeficiente de determinación (R^2). Considerando este valor, se seleccionó el modelo AdaBoost (Freund & Schapire, 1996) para predecir la variable objetivo “precio por metro cuadrado”. Finalmente, se presentan los resultados del modelo en producción, que pueden compararse con los valores históricos.

También mostramos la correlación entre el valor de metro cuadrado de vivienda y la inversión realizada por las empresas operadoras en la Región Vaca Muerta.

4 Desarrollo del experimento

4.1 Recolección de los datos

Los datos de valores inmobiliarios se obtuvieron mediante web scraping, una técnica que consiste en extraer información de sitios web de forma automatizada. Para ello, se implementaron scrapers en Python utilizando las librerías BeautifulSoup y Requests. Se analizaron los sitios web de Zonaprop, Properati y Mercado Libre Inmuebles, con el objetivo de recolectar datos actuales de inmuebles en la localidad de Añelo, provincia de Neuquén. Los datos históricos se obtuvieron de una base publicada por Inmobiliaria Properati. Corresponden al período junio 2020- junio 2021. Las propiedades del dataset se muestran en la tabla 1.

Tabla 1. Features del dataset

Nombre	Descripción
end_date	Fecha de finalización del aviso
Created_on	Fecha de publicación del aviso
Lat, lon	Latitud y longitud del inmueble
L1, L2, L3	Campos para dirección.
Rooms, bedrooms, bathrooms	Cantidad de habitaciones, dormitorios y baños, respectivamente.
surface_total	Superficie total y cubierta en metros cuadrados.
surface_covered	
price	Precio del inmueble
currency	Moneda ARS/USD
title	Descripción del inmueble.
description	

property_type	CASA/Departamento/PH/LOTE/CASA CAMPO/OTROS	DE
operation_type	VENTA/ALQUILER	
valor	Permite tener valores en moneda constante. Valor promedio del dólar en 2020-2021 de \$75 para realizar la conversión de moneda.	
valorM2	Es otra propiedad agregada al dataset. Son valores por metro cuadrado.	

El dataset que refleja las inversiones realizadas por las empresas operadoras en Vaca Muerta durante el período 2020-2022 fueron publicados por la Secretaría de Energía de la Nación Argentina en <https://www.argentina.gob.ar/economia/energia>. Las propiedades más relevantes del dataset se muestran a continuación.

Tabla 2. Inversiones de empresas operadoras 2020-2022

Nombre	Descripción
Fecha de la DDJJ	Fecha de la inversión
Empresa informante	Nombre del operador
Área/Permiso/Concesión	Región donde se realiza la inversión
Yacimiento	Nombre del yacimiento.
Mes de la inversión	Mes de inicio.
Fecha Inicio Tareas	Fecha inicio de obras.
Millones US\$ exploración	Inversión en dólares estadounidense en exploración
Millones u\$ d explotación	Inversión en explotación
Total Millones USD	Inversión total en dólares de la empresa operadora
Total Acumulado	Refleja la suma de inversiones hasta la fecha de todas las empresas operadoras.

4.2 Limpieza y preparación de los datos

Análisis exploratorio de los datos (EDA)

Como paso previo al ajuste de los modelos predictivos, se utilizó la herramienta Orange Data Mining (Demšar et al., 2013) para examinar características y patrones del conjunto de datos como ser distribución de valores, rangos, medias, medianas, valores faltantes, entre otros. El objetivo fue eliminar duplicados, completar o imputar valores faltantes, corregir inconsistencias (formatos de fecha, unidades) y filtrar variables irrelevantes.

En esta etapa se emplearon diversos widgets de Orange, como Data Table, Box Plot, Distributions y Scatter Plot, para visualizar la dispersión de precios, detectar valores atípicos (outliers) y explorar correlaciones.

En base a las correlaciones e importancia relativa de los datos, determinamos las propiedades más relevantes del dataset. Así reducimos la cantidad de dimensiones (features) del problema a las propiedades: created_on, lat, lon, surface_total, price, currency, property_type y valorM2. La distribución geográfica de los inmuebles se muestra en la Fig.1.

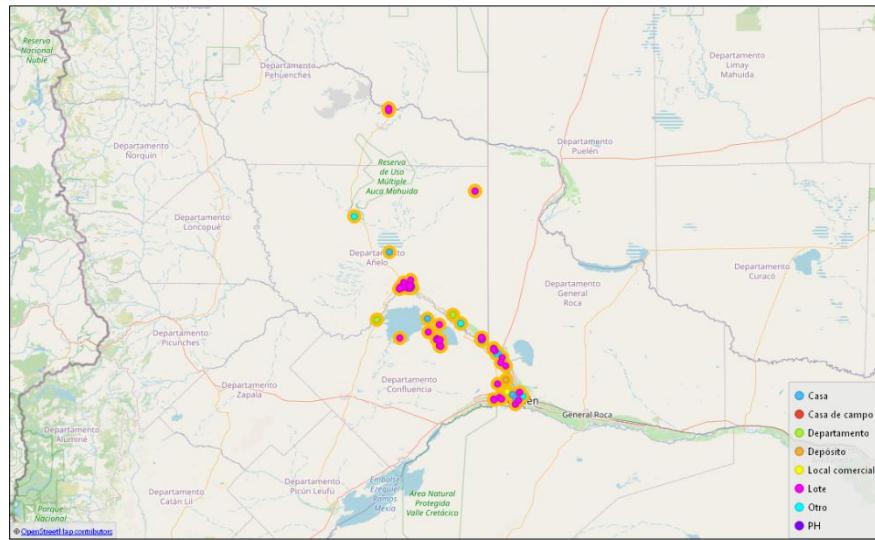


Fig. 1. Distribución geográfica de los inmuebles.

La correlación de los datos, calculada con el método de Spearman (ρ), se presenta en la Tabla 3.

Tabla 3. Correlación de propiedades (Features) mediante método Spearman.

ρ	Propiedad comparada	P	Propiedad comparada		
-0.653	ValorM2	surface_total	-0.132	lat	surface_total
-0.646	lat	lon	-0.120	Valor	lon
+0.468	Valor	surface_total	-0.101	created_on	lat
+0.355	Valor	price	-0.089	ValorM2	lon
+0.223	price	surface_total	-0.085	Valor	ValorM2
-0.210	lat	price	-0.061	lon	price
+0.209	ValorM2	lat	+0.049	created_on	lon
-0.191	ValorM2	price	+0.045	created_on	surface_total
+0.177	Valor	created_on			
-0.156	ValorM2	created_on			

En la Tabla 4, se muestra la distribución estadística para cada una de las propiedades consideradas.

Tabla 4. Tipos de propiedad y medidas.

Name	Mean	Mode	Median	Dispersion	Min.	Max.	Missing
price	1598837.59	72000	123728	1.73	0	10650000	8 (11 %)
Valor	121362		80000	1.08	37333.3	1e+06	9 (12 %)
surfac e_tota l	1470.37	30	64	7.79	30	100000	1 (1 %)
Valor_M2	1226.59	0.00	1250.00	0.71	0.00	2666.22	0 (0 %)
lat	-38.5036	-38.3516	-38.3548	-0.008	-40.65	-37.838	0 (0 %)
lon	-68.6287	-68.7875	-68.7812	-0.0061	-71.39	-68.0522	0 (0 %)
create_d_on	2020-11-12	2020-08-25	2020-11-21	-12 month s	2020-04-07	2021-04-24	0 (0 %)
property_type		Departamento		0.887			0 (0 %)
currency		USD		0.566			9 (12 %)

Los datos de inversiones realizadas por las empresas operadoras en Vaca Muerta, durante 2020-2022 se muestra en Fig. 2. Se agregó una propiedad llamada “Acumulada” que resulta de sumar las inversiones de todas las empresas operadoras en la misma fecha.

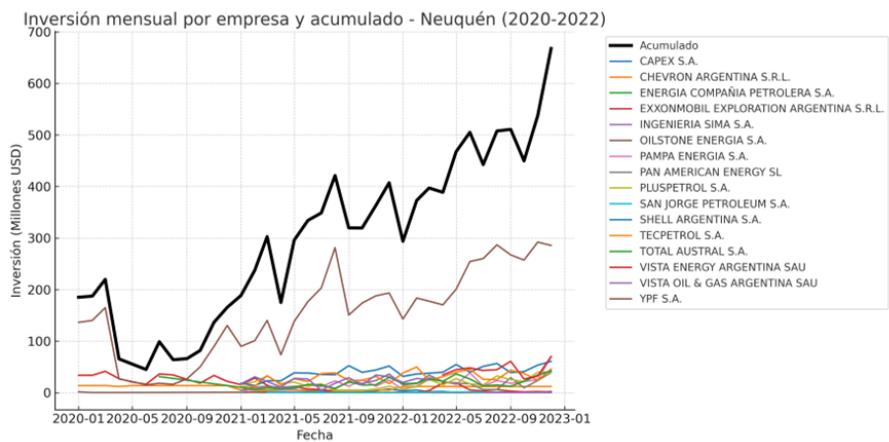


Fig. 2. Evolución temporal de las inversiones realizadas por empresas operadoras en Vaca Muerta, período 2020-2022.

5 DISCUSIÓN

5.1 Selección de modelos y aplicación de técnicas de minería.

En este trabajo, se ensayaron distintas técnicas de regresión (por ejemplo, Random Forest, Gradient Boosting, Redes Neuronales), observándose que AdaBoost arrojó coeficientes de determinación (R^2) superiores, con errores medios aceptables (MAE, MSE). Esto confirmó su conveniencia para modelar la relación entre variables como superficie, ubicación, y precio por metro cuadrado. Descartamos modelos más complejos, como Redes Neuronales. Notamos que el volumen de datos no resultaba suficiente para obtener una calibración aceptable. Por su parte, AdaBoost ofrece un rendimiento sólido con un riesgo relativamente bajo de sobreajuste (overfitting). Como una breve descripción del modelo AdaBoost, se puede decir que combina múltiples modelos débiles (por lo general, árboles de decisión de poca profundidad) para generar un modelo fuerte y preciso. Cada modelo sucesivo se enfoca en los errores cometidos por los anteriores, mejorando iterativamente el rendimiento. En la Fig.3 se muestra el proyecto Orange Data Mining implementado.

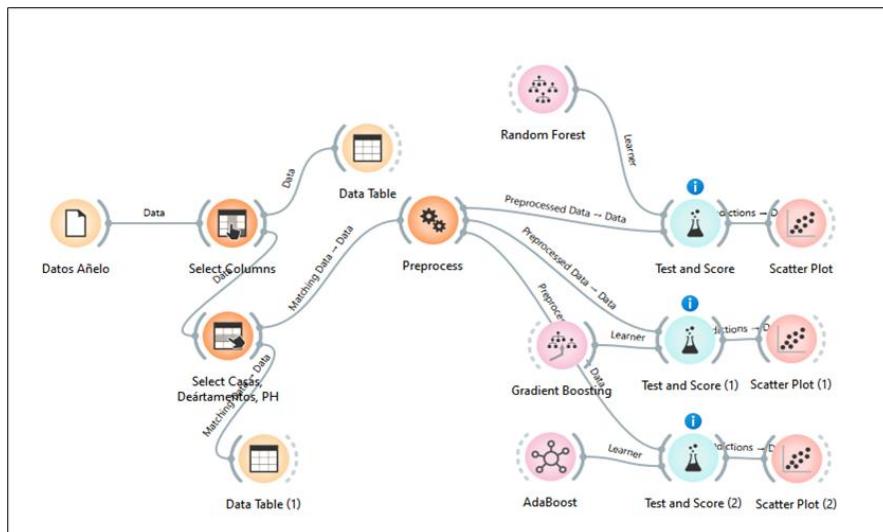


Fig. 3. Orange Data Mining proceso.

5.2 Evaluación de los modelos estudiados

Se evaluaron tres modelos Random forest, Gradient Boosting y AdaBoost obteniendo sus respectivos indicadores Means Square Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE) y Coeficiente de Determinación (R^2) (tabla 5). Los tres primeros son fuertemente sensibles a la presencia de valores atípicos (outliers). El indicador más importante es R^2 . Es una métrica que expresa la proporción de la variabilidad de la clase objetivo (valor del metro cuadrado) explicada por el

modelo. Las figuras 4 a 6 muestran los gráficos de correlación entre los valores reales y los predichos para cada uno de los modelos evaluados.

Tabla 5. Indicadores para cada modelo evaluado.

Modelo	MSE	RMSE	MAE	R ²
Random Forest	234727.7	484.48	265.23	0.697
Gradient Boosting	267393.5	517.10	246.21	0.654
AdaBoost	167749.3	409.57	185.09	0.783

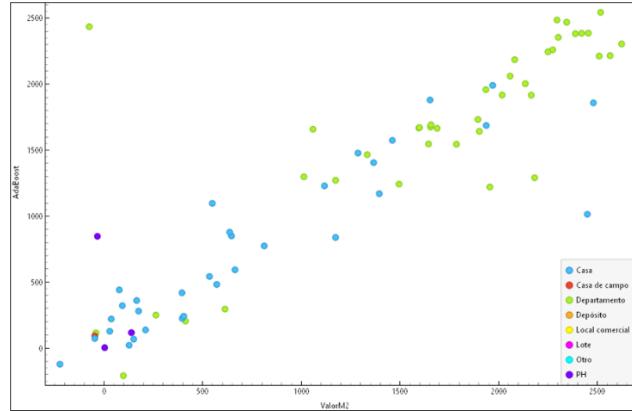


Fig. 4. Modelo AdaBoost.

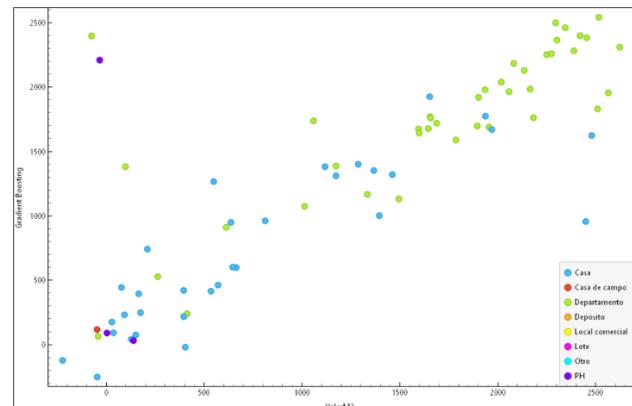


Fig. 5. Modelo Gradient Boosting

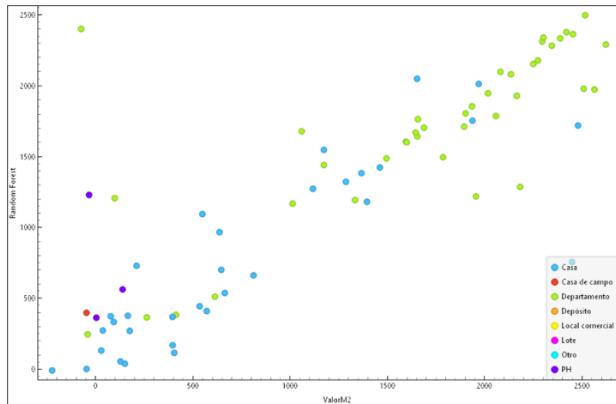


Fig.6. Random Forest

5.3 Implementación y despliegue

Finalmente desarrollamos un script de predicción con AdaBoost Regressor. Está implementado en Python y utiliza un conjunto de librerías robustas para cubrir todo el proceso, desde la limpieza de datos hasta la visualización de resultados. Para esto se utilizaron las siguientes librerías:

- pandas: se emplea para cargar los datos, realizar filtrados, imputar valores faltantes y generar variables derivadas como el valor por metro cuadrado.
- numpy: utilizado para operaciones matemáticas, creación de variables estacionales (seno y coseno de la fecha) y la adición de ruido controlado a las predicciones para simular incertidumbre.
- scikit-learn (sklearn): proporciona el modelo principal, AdaBoostRegressor (módulo ensemble), así como utilidades para la división de datos (train_test_split) y la evaluación del modelo mediante métricas como R^2 , MAE y MSE.
- matplotlib.pyplot: se utiliza para construir los gráficos comparativos entre valores reales y predicciones, además de mostrar líneas de promedio móvil que suavizan las series temporales y permiten visualizar tendencias.
- datetime: se usa para manejar las fechas y extraer componentes necesarios para generar las variables estacionales.

Como resultado, se elaboró un gráfico (Fig.7) donde se superponen:

- Los valores reales del conjunto de entrenamiento y prueba.
- Los valores predichos con ruido agregado para simular la dispersión inicial de los datos reales.
- Las líneas de promedio móvil de ambas series, para una visión más clara de la tendencia general.

De esta manera obtenemos un modelo interpretable y ajustable para monitorear la evolución de los precios inmobiliarios en Añelo, facilitando la toma de decisiones y la proyección de escenarios futuros.

Utilizando los valores predichos por el modelo Adaboost analizamos la correlación de las series temporales comparando los valores predichos para la clase objetivo con las inversiones realizadas por las empresas operadoras. De esta manera vinculamos la

intervención económica de la inversión acumulada con el valor de la vivienda en la región de Añelo. La correlación entre los flujos de inversión en el sector hidrocarburífero y el comportamiento del mercado inmobiliario urbano permite caracterizar la fragmentación urbana como un fenómeno inducido por el modelo productivo, que opera seleccionando qué zonas se valorizan, qué actores acceden a ellas y cuáles quedan relegados. En Fig. 8 mostramos el resultado de correlación de Pearson aplicada a las propiedades mencionadas.

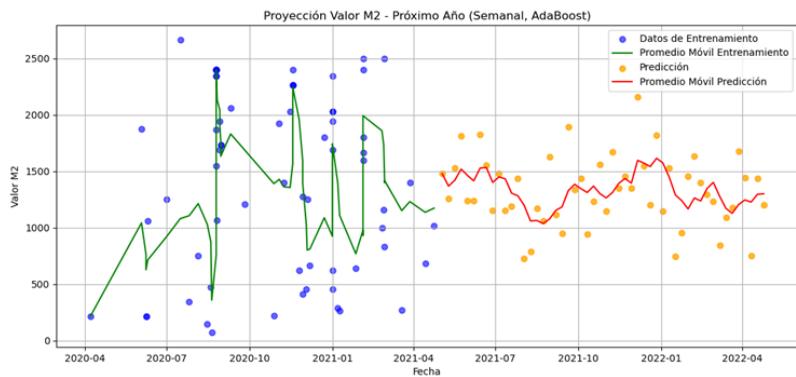


Fig. 7. Resultados de la implementación del Modelo AdaBoost.

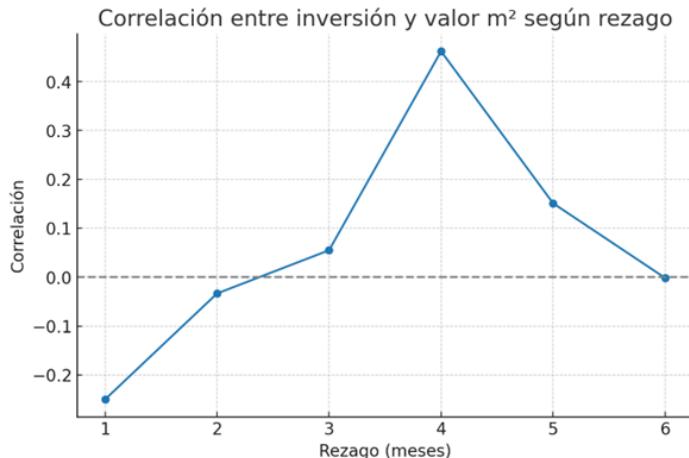


Fig. 8. Correlación por método Pearson de inversiones vs. Valor inmobiliario

En el gráfico observamos que la correlación más alta entre inversiones y valor del metro cuadrado se obtiene cuando el rezago es de 16 semanas. Considerando que la correlación entre las inversiones y el valor inmobiliario mostró una asociación significativa, se ajustó el modelo predictivo incluyendo dicha variable rezagada, con el objetivo de mejorar la capacidad predictiva del modelo

Realizamos dos modificaciones en el dataset de entrenamiento. Incorporamos una propiedad denominada “Inversión acumulada” e introducimos un rezago de 16 semanas en los datos de inversiones. Con el nuevo dataset volvimos a entrenar el modelo AdaBoost. El coeficiente de determinación (R^2) evidenció una mejora significativa en el desempeño del modelo, incrementándose de 0,783 a 0,91. Los resultados se muestran en la Fig.9.

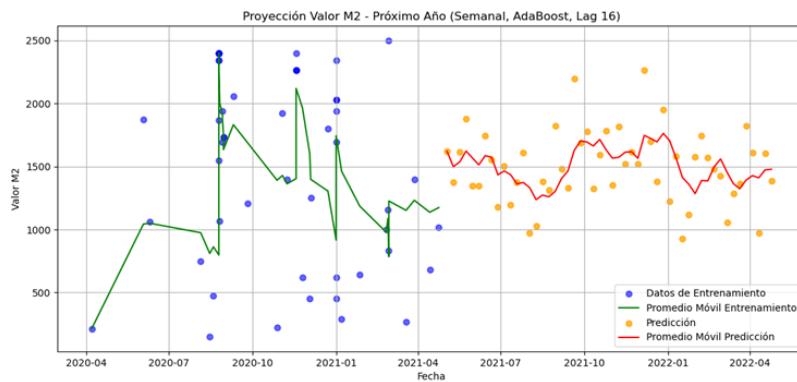


Fig. 9. Resultados del Modelo AdaBoost entrenado con dataset modificado.

6 Conclusiones: monitoreo y mantenimiento

En este trabajo brindamos una contribución a los estudios del proceso de fragmentación urbana por medio de la actividad hidrocarburífera en la región de Añelo, centro de Vaca Muerta (Neuquén). Relacionamos las inversiones realizadas por las empresas operadoras en la región con el precio de los inmuebles en Añelo.

Implementamos un modelo predictivo basado en AdaBoost que constituye una herramienta valiosa para estimar la evolución de los precios inmobiliarios para casas, departamentos, PH y locales comerciales por metro cuadrado. Sin embargo, su utilidad práctica requiere supervisión y actualización periódica.

Aplicamos nuestro estudio a un dataset del período junio 2020- Junio 2021 para predecir los valores inmobiliarios del período junio 2021 – junio 2022. También utilizamos datos de inversión de las empresas operadoras en Vaca Muerta para vincularlos con la evolución de los valores inmobiliarios. Encontramos una correlación entre ambas propiedades con un rezago de 4 meses, lo que nos permitió ajustar el modelo predictivo. El coeficiente de determinación (R^2) evidenció una mejora significativa en el desempeño del modelo, incrementándose de 0,783 a 0,91

Dado que el mercado inmobiliario está influenciado por factores económicos, políticos y sociales en constante cambio, se recomienda evaluar el rendimiento del modelo incorporando valores actuales, readjustar los hiperparámetros cuando se detecten cambios significativos en la dinámica del mercado y documentar las actualizaciones para garantizar la trazabilidad y reproducibilidad del análisis.

En resumen, el modelo debe considerarse como un sistema dinámico que evoluciona junto al mercado inmobiliario de Añelo, requiriendo mantenimiento continuo, supervisión de su rendimiento y ajustes estratégicos para conservar su confiabilidad como herramienta para evaluar el impacto del valor inmobiliario en el proceso de fragmentación urbana de la región Vaca Muerta.

Referencias

- Acacio, J., & Wyczykier, G. Expectativas públicas y conflictos sociales en torno a los hidrocarburos no convencionales en Argentina: algunos apuntes sobre Vaca Muerta. *Izquierdas*, 2019, 49 (26), 457-477.
- Demšar, J., Curk, T., Erjavec, A., Gorup, Č., Hočevat, T., Milutinovič, M., Možina, M., Polajnar, M., Toplak, M., Starič, A., Stajdohar, M., Umek, L., Žagar, L., Žbontar, J., Žitnik, M., & Zupan, B. (2013). Orange: Data mining toolbox in Python. *Journal of Machine Learning Research*, 14(August), 2349–2353.
- Favarro, O. Territorio-Estado. La explotación del petróleo en un espacio nacional. Neuquén (1918-1955). *Estudios Sociales del Estado*, 2021, 7 (13) 257-292.
- Folchi, M., Blanco Wells, G., & Meier, S. Definiciones tecno-políticas en la configuración de la matriz energética chilena durante el siglo XX. *Historia*, 2019, 52 (2), 373-408.
- Freund, Y., & Schapire, R. E. (1996). Experiments with a new boosting algorithm. In *Machine learning: proceedings of the Thirteenth International Conference* (pp. 148–156).
- Hernández-Lugo, M. d. La Inteligencia Artificial como herramienta de análisis en las Ciencias Sociales: métodos y aplicaciones. *LatIA*, 2024, 2 (11), doi: 10.62486/latia202411.
- Jiménez Pérez, G. A., & Hernández de la Cruz, J. (2023). Aplicaciones de la Inteligencia Artificial en la sociología contemporánea. *LatIA*, 2023, 1 (12), doi: 10.62486/latia202412.
- Kozak, D. (2012). La fragmentación urbana en las ciudades argentinas. *Revista de Arquitectura de la Sociedad Central de Arquitectos*, 2012, 244 (4), 82-85.
- Kozak, D. Revisitando el debate sobre la fragmentación urbana. Una década y media después de "Splintering Urbanism". *Revista Iberoamericana de Urbanismo*, 2018 (14), 15-22.
- Pérez Peñuelas, B. Problemática en la delimitación de la fragmentación urbana por compartir procesos con otros impactos urbanos. *Revista Ciudades, Estados y Política*, 2021, 8 (2), 143-160.
- Pérez Roig, D., Scandizzo, H., & di Risio, D. Vaca Muerta: construcción de una estrategia. Políticas públicas ambiguas, empresas estatales corporatizadas y diversificación productiva a medida. Buenos Aires: Ediciones del Jinete Insomne; 2016
- Perren, J., & Cabezas, S. Gentrificación alla neuquina. Crecimiento en altura, alitización y desplazamiento en una ciudad intermedia de la Patagonia (2001-2010). En: Perren, J.; Casullo, F. & Padín, N. Rompecabezas urbano. Producción de desigualdades en ciudades de la Norpatagonia. Viedma: Editorial UNRN; 2020. pp. 99-134.
- Wyczykier, G., & Acacio, J. Las energías extremas en Vaca Muerta: consensos, disensos y resistencias. *Observatorio Latinoamericano y Caribeño (OLAC)*, 2021, 5 (2), 44-64.