



Tipo de artículo: Artículos originales  
Temática: Inteligencia artificial  
Recibido: 19/05/2023 | Aceptado: 21/08/2023 | Publicado: 30/09/2023

Identificadores persistentes:  
DOI: [10.48168/innosoft.s12.a111](https://doi.org/10.48168/innosoft.s12.a111)  
ARK: [ark:/42411/s12/a111](https://nbn-resolving.org/ark:/42411/s12/a111)  
PURL: [42411/s12/a111](https://nbn-resolving.org/urn:nbn:pe:ulasalle:innosoft-42411-s12-a111)

## Predicción de precios de autos usados

### *Used Car Price Prediction*

Yoset Cozco Mauri <sup>1</sup>[0000-0003-2027-962X]\*, Fiorella Pilar Cayo Cayo <sup>2</sup>[0000-0001-6068-6225], Jordy Pedro Valencia Jara <sup>3</sup>[0000-0001-6336-5419], Henry Uriel Bustinza Torres <sup>4</sup>[0000-0001-7092-1516]

<sup>1</sup> Universidad Nacional de San Agustín. Arequipa, Perú. [ycozco@unsa.edu.pe](mailto:ycozco@unsa.edu.pe)

<sup>2</sup> Universidad Nacional de San Agustín. Arequipa, Perú. [fcayoc@unsa.edu.pe](mailto:fcayoc@unsa.edu.pe)

<sup>3</sup> Universidad Nacional de San Agustín. Arequipa, Perú. [jquispejar@unsa.edu.pe](mailto:jquispejar@unsa.edu.pe)

<sup>4</sup> Universidad Nacional de San Agustín. Arequipa, Perú. [hbustinzat@unsa.edu.pe](mailto:hbustinzat@unsa.edu.pe)

\* Autor para correspondencia: [ycozco@unsa.edu.pe](mailto:ycozco@unsa.edu.pe)

---

#### Resumen

En varias ocasiones cuando se vende un automovil de segunda mano no se sabe el precio exacto por varios factores, con lo cual puede ser vendido a menos o más valor del que en realidad vale, generando pérdidas tanto a los compradores como a los vendedores que intentan calcular el valor por intuición o con su conocimiento en autos, pero está a veces falla.

Entonces con ayuda de organizar los datos en una base de datos, y compararlos con ayuda de un software, así pudimos conseguir un precio mucho más preciso, esto tomando en cuenta diferentes factores que podrian modificar el precio del auto, como el tiempo de uso calidad de las distintas piezas, entre otros, logrando un precio mucho más preciso que al solo usar intuición.

**Palabras clave:** *Automóvil, inteligencia artificial, precio de venta.*

#### Abstract

*On several occasions when a second-hand car is sold, the exact price is not known due to various factors, with which it can be sold at less or more value than it is actually worth, you will lose both buyers and sellers who try to calculate the value by intuition or with his knowledge in cars, but this sometimes fails.*

*Then, with the help of organizing the data in a database, and comparing them with the help of software, we were able to get a much more accurate price, taking into account different factors that could modify the price of the car, such as time of use and quality. of the different parts, among others, achieving a much more accurate price than just using intuition.*

**Keywords:** Car, artificial intelligence, selling Price.

---

## Introducción

Considerando la demanda actual de autos personales o de uso privado, la demanda en el sector automovilístico ha aumentado, y en el mercado de segunda mano la realidad es que ha ido creciendo, creando así una oportunidad de negocio tanto para compradores como vendedores. Comprar un auto usado en muchos países es una buena opción por el precio asequible. Dado que después de algunos años de uso, se puede obtener una ganancia de vender de nuevo. Es por este motivo que es necesario saber con certeza qué factores influyen en el precio final. En los mercados de segunda mano, los precios de los autos usados no son constantes, es por este problema que la evaluación del auto para posteriormente calcular el precio se hace una práctica constante.

Además por la reciente emergencia sanitaria que sufrió todo el mundo, tener un automóvil para uso personal a paso de ser un privilegio a una necesidad, que al menos por familia se cuenta con un automóvil para el transporte de esta misma, tanto por salud como por seguridad, siendo un mercado muy activo ultimamente, mas que en años anteriores, y en la zona en que vivimos sudamérica es muy normal comprar autos de segunda mano siendo una aplicación a nuestro entorno o un problema que prácticamente podemos ver a diario.

Debido al incremento del valor de los vehículos, se aprecian cada vez más a las ferias de autos que muestran gran variedad en modelos de autos y precios siendo muchas veces más convenientes que una casa automotriz. Cada zona geográfica (países) tiene sus características que ofrecerán más o menos oportunidades a la industria automotriz dependiendo principalmente de su condición socio-económica.

El precio depende de factores como modelo del automóvil, año de fabricación, marca, opiniones de consumidores, ciudad, versión, seguridad, color, si es concesionario/particular, kilometraje, tipo de combustible (GLP, GNV, Gasolina, Diesel), llantas de aleación, sistema de frenos, aceleración, dimensiones, seguridad, aire acondicionado, su estado físico, el número de dueños anteriores, interior y dirección asistida, tales variables se utilizan para predecir el precio de dichos vehículos para el comercio.

También considerando que algunos vehículos pueden ser de uso particular o laboral pueden tener mayor o menor desgaste según la función que pudieron desempeñar antes del momento de estar a la venta. Tener en cuenta que tanto fueron usados sus diferentes componentes considerando el precio actual de un modelo completamente nuevo del mismo ayudará bastante a la hora de calcular un precio aproximado aparte de brindar un precio justo a nuestro usuario.

Ya que la mayoría de compradores en lo primero que se fijan es el precio, sin saber el valor de cada pieza y calcular el valor por uso, desgaste y/o pieza no original, como ya mencionamos anteriormente hay muchas características que alteran el precio final, pero en la mayoría de casos el comprador no cuenta con el tiempo o la información suficiente para calcular, y poder ver si el precio es razonable, de igual forma un vendedor, mayormente vende a un valor echado a suerte e intuición, y en varias ocasiones este puede ser más bajo de lo que realmente vale, o demasiado alto, y termina perdiendo dinero o tiempo, por no saber calcular el precio adecuado.

Ahora se debe considerar que los diferentes objetos ya de por si tienen un tiempo de vida útil y esto podría afectar al momento de calcular el valor que pueden tener ya que si consideramos un primer dueño que lo uso todo el tiempo donde se tenía la seguridad que dicho vehículo funciona de forma correcta, al momento de vender el precio bajo de forma considerable.

Teniendo en cuenta todo lo anterior el objetivo principal de este trabajo es encontrar el mejor modelo predictivo para predecir el precio de un auto de segunda mano, teniendo en cuenta todos los factores que hacen que varíe el precio entre un vehículo u otro.

## **Materiales y métodos o Metodología computacional**

La metodología utilizada para este proyecto se inicia con la recopilación de datos en bruto en un conjunto de datos lógico o conjunto de datos disponible en línea. El siguiente paso es crear un entorno para Pre-procesamiento de datos

mediante limpieza y reducción de datos. Después obteniendo información útil del conjunto de datos, entrenamos y probamos para los análisis de datos.

Por último, en función de este resultado, se selecciona el modelo de aprendizaje automático para la predicción de precio y clasificación de precio basada en Inteligencia Artificial.

Materiales: revisar Dataset

Metodología computacional:

- Recolección de datos
- Creación de un entorno
- Preprocesamiento de Datos
- Entrenamiento
- Pruebas y análisis
- Selección del modelo
- Predicción del valor

### **DataSet**

Esta investigación se basó en el estudio de un dataset de vehículos usados y su precio. Este dataset de vehículos se encuentra en el sitio web Zenodo[2].

Las características disponibles en nuestro dataset son:

- Title: String. Vehicle name, a combination of brand and model. In some cases it includes model variation an other information.
- Price: Integer. Selling price.
- ref\_num: Integer. ID.
- location: String. Location of the vehicle.
- seller: String. Type of seller: professional or private.
- color: String. Vehicle color.
- door\_num: Integer. Number of doors.
- fuel\_type: String. Type of fuel.
- hp: Integer. Horse power.
- mileage: Integer. Kilometers.
- transmisión: String Either manual or automatic transmission.

- year: Integer. First registration.

## Pre - Procesamiento

En este paso revisamos que en nuestro dataset existen valores atípicos, puede ser debido a la gran cantidad de datos, estos valores han sido filtrados, dado que existían datos como cilindraje en la columna de kilometraje o tipo, valores que no corresponden a esta columna.

	A	B	C	D	E	F	G	H	I	J	K
1	color	door_num	fuel_type	hp	location	mileage	price	ref_num	seller	title	transmission
2	Blanco		5 gasolina	60	Málaga	170000	1450	426875509	Profesional	Renault - Clio	manual
3	Negro		5 híbrido	108	Madrid	14950	23390	429436719	Profesional	RENAULT - Zoe	automático
4	Blanco		5 diesel	165	Cuenca	260000	8990	426571125	Profesional	OPEL - Zafira Tc	manual
5	Marrón		5 diesel	313	Alicante	235000	21900	418805767	Particular	Bmw - Serie 7	automático
6	Rojo		5 gasolina	68	Jae'n	74000	1800	426978271	Particular	Peugeot - 107	manual
7	Beige		5 gasolina	60	Valencia	148200	5200	429155464	Profesional	SKODA - Fabia	manual
8	Blanco		5 gasolina	90	Valencia	10958	13900	429155465	Profesional	RENAULT - Clio	manual
9	Azul		5 gasolina	75	Cádiz	41338	11990	426955686	Profesional	SKODA - Fabia	manual
10	Blanco		5 gasolina	82	Almeria	115000	8500	423852498	Profesional	PEUGEOT - 206	manual
11	Azul		5 diesel	120	Salamanca	127000	9500	384357896	Profesional	OPEL - Insignia	manual
12	Blanco		5 diesel	130	Badajoz	151348	13499	416515268	Profesional	NISSAN - QASH	manual
13	Azul (Misano Blau)		5 diesel	116	Madrid	21500	29900	429446085	Profesional	BMW - Serie 1 1	manual
14	Gris / Plata ("RIV")		5 gasolina	120	Murcia	102666	13200	429454609	Profesional	RENAULT - Cap	automático
15	Negro		5 diesel	120	Madrid	236000	1499	426420195	Profesional	Renault - Scenic	manual
16	Negro		5 gasolina	265	Barcelona	202000	12500	429382406	Profesional	Audi - S3	manual
17	Gris		5 diesel	231	Madrid	194000	8000	42695384	Particular	BMW Serie 3	automático
18	Blanco (T9T9 Blanco)		5 diesel	150	Madrid	100082	21100	413132116	Profesional	AUDI - A4 Avant	automático
19	BlueMetallic		5 diesel	260	Madrid	180000	16500	306916699	Profesional	BMW - 330i325	manual
20	Gris / Plata		5 híbrido	416	Madrid	157000	42890	399596154	Profesional	PORSCHE - Pan	automático
21	Gris / Plata		5 diesel	204	La Coruña	210000	17990	427831866	Profesional	AUDI - A6 Avant	manual
22	Gris / Plata		5 diesel	116	Madrid	96800	15900	429445783	Profesional	BMW - Serie 1 1	manual
23	Rojo		5 gasolina	82	Tenerife	65000	7990	427955980	Profesional	CITROEN - C1 F	manual
24	Gris / Plata		3 gasolina	160	Málaga	12000	18200	429200774	Profesional	ABARTH - 500 1	manual
25	Azul		5 diesel	258	Badajoz	68000	65900	372478528	Profesional	MERCEDES-BE	automático
26	5 puertas	diesel	140cv	340	Pontevedra	manual	6500	425419432	Particular	Volkswagen - Gr	año 2011
27	Gris / Plata (A90 So)		4 diesel	265	Barcelona	111659	39500	426453621	Profesional	BMW - Serie 7 7	automático
28	Gris / Plata		3 diesel	125	Madrid	192000	1190	429386417	Profesional	SAAB - 93 2.2 T	manual
29	Negro		5 diesel	125	Ledn	200000	2900	429164059	Profesional	SAAB - 93 SE 2	manual
30	Gris / Plata		2 gasolina	61	Albacete	129000	4500	427918803	Profesional	SMART - fortwo	automático
31	Negro ("MUR")		5 diesel	165	Albacete	213715	4900	429453596	Profesional	SSANGYONG -	manual
32	Gris		5 diesel	105	Zamora	348000	1800	298389356	Particular	Alfa romeo - 156	manual
33	Blanco (369 Blanco G)		5 diesel	95	Madrid	124713	9100	427556441	Profesional	RENAULT - Meg	manual
34	Blanco		3 gasolina	265	Ourense	105000	20400	389199950	Profesional	VOLKSWAGEN	automático

Figura 1. Formato CSV usado para procesar el dataset

En la Figura 1 observamos valor atípico en la fila 26 columna C, cilindraje en fuel\_type. Usamos un filtro para evitar este tipo de valores atípicos, este dataset fue trasladado a otro documento libre de valores atípicos, la única condición fue eliminar estos valores atípicos.

Los valores no numéricos durante el procesamiento de datos en código serán suprimidos o modificados dado que no nos resultan útiles.

```
Splitting the data and target

[ ] X = car_dataset.drop(['title', 'price', 'location', 'ref_num'], axis=1)
    Y = car_dataset['price']
```

**Figura 2.** Descartando datos como título, locación, precio y ref num para variable X.

## Entrenamiento

Usamos el método linear Regresion para el entrenamiento con nuestro DataSet, por el tipo de datos y los resultados que queremos obtener resulta un método eficiente. Este resultado será contrastado con otro método Lasso para tener un análisis más exhaustivo de los resultados.

Para este entrenamiento hemos usado la plataforma de google colab y el gestor de archivos en la nube google drive.

Como primer paso se hace una carga de datos, con una inspección inicial se revisaron una parte de los datos, tamaño en filas columnas y la información que ofrece este dataset.

```
Data Collection and process

[213] #Cargar datos del archivo csv a pandas dataframe
car_dataset = pd.read_csv('/content/drive/MyDrive/la_dataset/data_cars.csv')

# Inspección de las 5 primeras filas
car_dataset.head()

  door_max  fuel_type  hp  location  mileage  price  ref_max  seller  title  transmission  year
0         5    gasolina  90   Málaga  170000  1450  426875509  Profesional  Renault - Clio  manual  2000
1         5    híbrido  188   Madrid  14950  23390  429436719  Profesional  RENAULT - Zoo Intans 80 kW R110 Bateria 50kWh  automático  2020
2         5    diesel  165  Cuenca  260000  8990  426571125  Profesional  OPEL - Zafira Tourer 2.0 CDTI 165 CV Selectiva  manual  2012
3         5    diesel  313  Alicante  235000  21900  418905767  Particular  BMW - Serie 7  automático  2013
4         5    gasolina  68   Jaén  74000  1800  428978271  Particular  Peugeot - 107  manual  2007

[214] #Revisamos el número de filas y columnas
car_dataset.shape

(6489, 11)

car_dataset.info()

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 6489 entries, 0 to 6488
Data columns (total 11 columns):
 #   Column      Non-Null Count  Dtype
---  ---
 0   door_max    6489 non-null   int64
 1   fuel_type   6489 non-null   object
 2   hp          6489 non-null   int64
 3   location    6489 non-null   object
 4   mileage     6489 non-null   int64
 5   price       6489 non-null   int64
 6   ref_max     6489 non-null   int64
 7   seller      6489 non-null   object
 8   title       6488 non-null   object
 9   transmission 6489 non-null   object
10  year        6489 non-null   int64
dtypes: int64(6), object(5)
memory usage: 557.8+ KB
```

Figura 3. Dataset Collect e inspección inicial

```
# Revisando la cantidad de datos faltantes
car_dataset.isnull().sum()

door_num      0
fuel_type     0
hp            0
location      0
mileage       0
price         0
ref_num       0
seller        0
title         3
transmission  0
year         0
dtype: int64

title missing = 4
```

Figura 4. Revisión de datos faltantes.

```
[217] #Revisando la distribución por categoría de nuestros datos
print(car_dataset.fuel_type.value_counts())
print(car_dataset.seller.value_counts())
print(car_dataset.transmission.value_counts())

diesel      3701
gasolina    2483
híbrido     225
Otro        65
eléctrico   9
GLP         6
Name: fuel_type, dtype: int64
Profesional 5266
Particular  1223
Name: seller, dtype: int64
manual      4386
automático  2103
Name: transmission, dtype: int64
```

Figura 5. Revisión de la distribución por categoría de los datos



Para poder usar ambos modelos propuestos (Regression, Lasso) es necesario presentar datos de forma numérica, se deben escoger los datos a usar, estos mismos deben ser codificados y el resto suprimidos(drop).

```
Encoding categorical data

# codificando "fuel_type" column
car_dataset.replace({'fuel_type': {'':0, 'diesel':1, 'eléctrico':2, 'gasolina':3, 'GAP':4, 'híbrido':5, 'Otro':6}}, inplace=True)
# codificando "seller" column
car_dataset.replace({'seller': {'Profesional':0, 'Particular':1}}, inplace=True)
# codificando "transmission" column
car_dataset.replace({'transmission': {'manual':0, 'automatico':1}}, inplace=True)
# codificando "location" column
car_dataset.replace({'location': {'Álava':0, 'Albacete':1, 'Alicante':2, 'Aleria':3, 'Asturias':4, 'Ávila':5, 'Badajoz':6, 'Balears':7, 'Barcelona':8,
'Burgos':9, 'Cáceres':10, 'Cádiz':11, 'Cantabria':12, 'Castellón':13, 'Ciudad Real':14, 'Córdoba':15, 'Cuenca':16,
'Siroon':17, 'Granada':18, 'Guadalajara':19, 'Guipúzcoa':20, 'Huelva':21, 'Huesca':22, 'Jaén':23, 'La Coruña':24,
'La Rioja':25, 'Las Palmas':26, 'León':27, 'Lleida':28, 'Lugo':29, 'Madrid':30, 'Málaga':31, 'Melilla':32, 'Murcia':33,
'Navarra':34, 'Ourense':35, 'Palencia':36, 'Pontevedra':37, 'Salamanca':38, 'Segovia':39, 'Sevilla':40, 'Soria':41,
'Tarragona':42, 'Tenerife':42, 'Teruel':43, 'Toledo':44, 'Valencia':45, 'Valladolid':46, 'Vizcaya':47, 'Zamora':48, 'Zaragoza':49, ''':50}}, inpl
```

Figura 6. Codificación de datos a usar: fuel\_type, seller, transmision, location

```
car_dataset.head()
```

	door_num	fuel_type	hp	location	mileage	price	ref_num	seller	title	transmission	year
0	5	3	60	31	170000	1450	426875509	0	Renault - Clio	0	2000
1	5	5	108	30	14950	23390	429436719	0	RENAULT - Zoe Intens 80 kW R110 Bateria 50kWh	1	2020
2	5	1	165	16	260000	8990	426571125	0	OPEL - Zafira Tourer 2.0 CDTI 165 CV Selective	0	2012
3	5	1	313	2	235000	21900	418805767	1	Bmw - Serie 7	1	2013
4	5	3	68	23	74000	1800	428978271	1	Peugeot - 107	0	2007

Figura 7. Verificación inicial de los datos codificados

```
[220] X = car_dataset.drop(['title','price','location','ref_num'],axis=1)
      Y = car_dataset['price']

print(X)
```

	door_num	fuel_type	hp	mileage	seller	transmission	year
0	5	3	60	170000	0	0	2000
1	5	5	108	14950	0	1	2020
2	5	1	165	260000	0	0	2012
3	5	1	313	235000	1	1	2013
4	5	3	68	74000	1	0	2007
...	...	...	...	...	...	...	...
6484	5	1	165	141608	0	1	2016
6485	3	1	90	110000	0	0	2011
6486	5	1	115	72997	0	0	2018
6487	5	1	190	136000	0	1	2007
6488	5	1	150	51338	0	0	2017

[6489 rows x 7 columns]

Figura 8. Asignación de valores X Y, verificación de contenido de X

```
print(Y)
```

0	1450
1	23390
2	8990
3	21900
4	1800
...	...
6484	9350
6485	5999
6486	19390
6487	13250
6488	24500

Name: price, Length: 6489, dtype: int64

Figura 9. Verificación del contenido de la variable Y

Se subdividen los datos para entrenamiento y pruebas con la función de sklearn.model train\_test\_split con los parámetros X Y, tamaño de prueba 0.1 ( 10% de los datos será para prueba y 90% serán de entrenamiento) , estado aleatorio (división de datos)

```
splitting training an test data

X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size = 0.1, random_state = 2)
```

Figura 10. Separación de datos de prueba y entrenamiento.

## RESULTADOS

### Selección del modelo

#### Modelo de entrenamiento

#### Regresión Lineal

Modelo de entrenamiento regresión lineal fue escogido por el tipo de datos que manejamos y el objetivo principal que tenemos.

```
# Loading the linear regression model
lin_reg_model = LinearRegression()

[225] lin_reg_model.fit(X_train,Y_train)

LinearRegression()
```

Figura 11. Creación de variable lin\_reg\_model y entrenamiento con los datos de entrenamiento

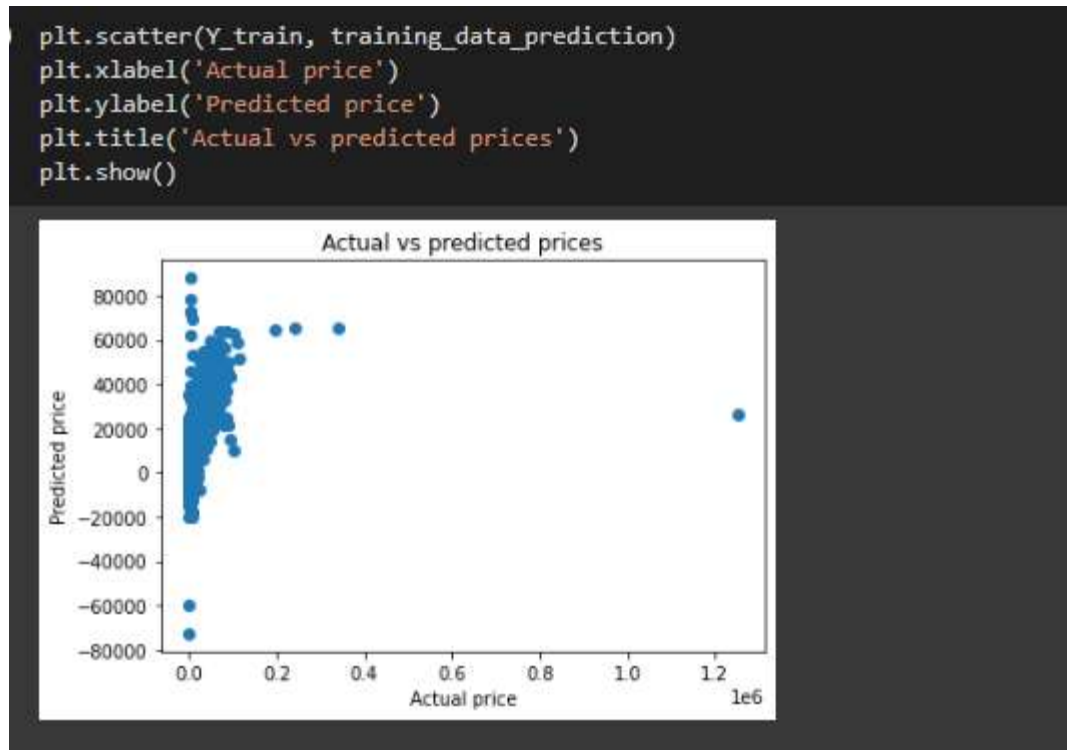
```
Model Evaluation

# predict on training data
training_data_prediction = lin_reg_model.predict(X_train)

[227] # R square error
error_score = metrics.r2_score(Y_train,training_data_prediction)
print("R score error:",error_score)

R score error: 0.2372542581549829
```

**Figura 12.** Creación de la variable training\_data\_prediction y predicción, cálculo de error



**Figura 13.** Visualización de resultados datos de entrenamiento.

```
[235] # prediction on test data
      test_data_prediction = lin_reg_model.predict(X_test)

# R square error
error_score = metrics.r2_score(Y_test, test_data_prediction)
print("R score error:", error_score)

R score error: 0.31320393613194475
```

**Figura 14.** Predicción en los datos de prueba y calculo de error

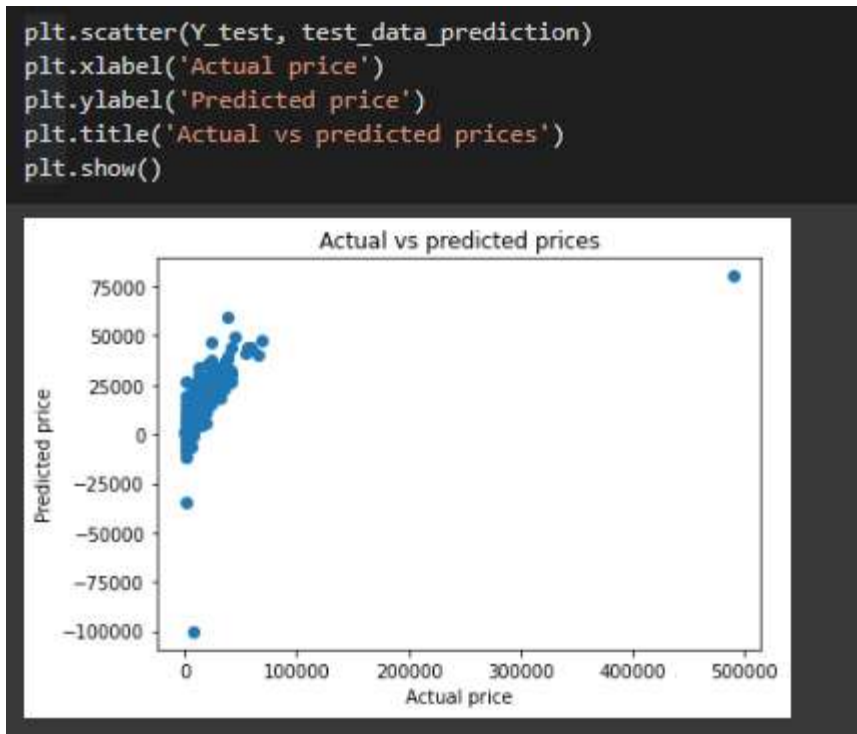


Figura 15. Visualización de resultados en datos de prueba.

## Lasso

Como segunda opción hemos escogido el modelo Lasso que tiene similitud de comportamiento pero nos dio una perspectiva diferente en el entrenamiento.

```
[237] # Loading the Lasso model
lass_reg_model = Lasso()

[238] lass_reg_model.fit(X_train,Y_train)

Lasso()

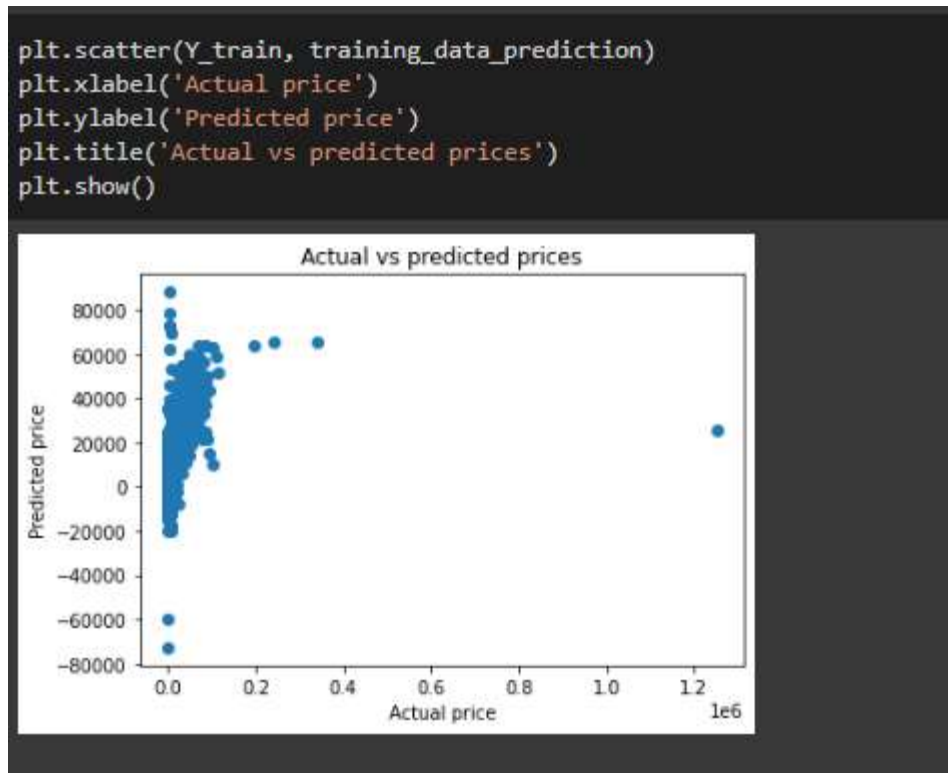
Model Evaluation

[239] # predict on training data
training_data_prediction = lass_reg_model.predict(X_train)

[240] # R square error
error_score = metrics.r2_score(Y_train,training_data_prediction)
print("R score error:",error_score)

R score error: 0.23725421982942563
```

**Figura 16.** Carga del modelo, predicción en datos de entrenamiento, cálculo de error.



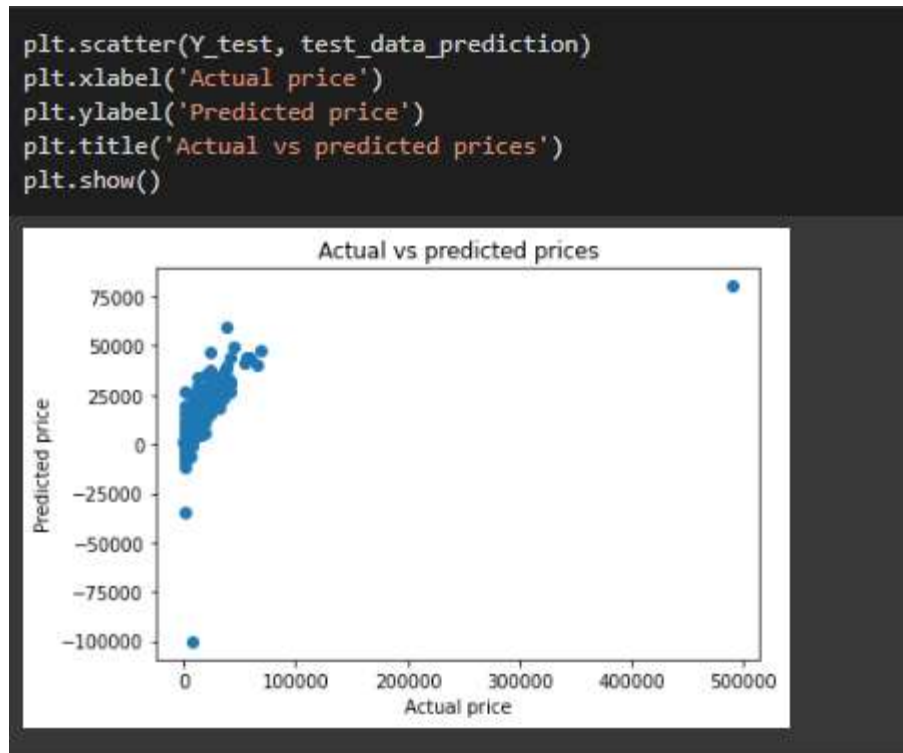
**Figura 17.** Visualización de resultados en datos de entrenamiento modelo Lasso

```
# prediction on test data
test_data_prediction = lass_reg_model.predict(X_test)

# R square error
error_score = metrics.r2_score(Y_test,test_data_prediction)
print("R score error:",error_score)

R score error: 0.3132182033298697
```

**Figura 18.** Entrenamiento en datos de prueba, cálculo de error.



**Figura 19.** Visualización de resultados en datos de prueba modelo Lasso.

## Conclusión

Como pudimos apreciar la recopilación de datos puede llegar a ser fundamental para este trabajo ya que con ella logramos aproximar un precio justo para el mercado actual ,considerando también diferentes factores ya sea el paso del tiempo las diferentes situaciones a las que podría haber sido expuesto el auto, valor de los diferentes materiales y desgaste de los mismos ,precio normal al que estaría disponible en el tiempo actual. Lo cual sirve de mucho al comprador y al vendedor para llegar a un común acuerdo que beneficiaría a ambos.

La cantidad de variables que rodean este segmento que son los autos usados y su correcta predicción de precios, hacen que la incorrecta selección de parámetros afecte drásticamente el resultado. En este documento manualmente hemos normalizado y limpiado algunos datos que puedan generar ruido. Este preprocesamiento es necesario para aumentar el desempeño de nuestro modelo a usar.

Durante el análisis logramos corroborar la cohesión de los resultados entre la predicción y los datos proporcionados, motivo por el cual escogemos el modelo Lasso que mejor resultado nos ha proporcionado usando esta condición.

## Contribución de Autoría

**Yoset Cozco Mauri:** [Conceptualización](#), [Análisis formal](#), [Investigación](#), [Visualización](#), [Metodología](#), [Software](#), [Validación](#), [Redacción - borrador original](#), [Curación de datos](#), [Escritura, revisión y edición](#). **Fiorella Pilar Cayo Cayo:** [Conceptualización](#), [Análisis formal](#), [Investigación](#), [Visualización](#), [Metodología](#), [Software](#), [Validación](#), [Redacción - borrador original](#), [Curación de datos](#), [Escritura, revisión y edición](#). **Jordy Pedro Valencia Jara:** [Conceptualización](#), [Análisis formal](#), [Investigación](#), [Visualización](#), [Metodología](#), [Software](#), [Validación](#), [Redacción - borrador original](#), [Curación de datos](#), [Escritura, revisión y edición](#). **Henry Uriel Bustinza Torres:** [Conceptualización](#), [Análisis formal](#), [Investigación](#), [Visualización](#), [Metodología](#), [Software](#), [Validación](#), [Redacción - borrador original](#), [Curación de datos](#), [Escritura, revisión y edición](#).

## Referencias

- [1] A. Yadav, E. Kumar, and P. K. Yadav, "Object detection and used car price predicting analysis system (UCPAS) using machine learning technique," *Linguist. Cult. Rev.*, vol. 5, no. S2, pp. 1131–1147, 2021, doi: 10.21744/lingcure.v5ns2.1660.
- [2] Duran, D., & Martinez, P. (2021, November 5). Carads. Zenodo. Retrieved August 17, 2022, from <https://zenodo.org/record/5651148>
- [2] Thai-Nichi Institute of Technology, Institute of Electrical and Electronics Engineers, and IEEE Thailand Section., "Proceedings of 2018 5th International Conference on Business and Industrial Research (ICBIR) : smart technology for next generation of information, engineering, business and social science : 17-18 May, 2018, Thai-Nichi Institute of Technology, Bangkok, Th," *2018 5th Int. Conf. Bus. Ind. Res.*, pp. 115–119, 2018.
- [3] G. Reiter Director and R. Blázquez, "Universidad Torcuato Di Tella Escuela de Negocios MBA Tesis de Maestría Valuación de autos usados utilizando la técnica de Regresión Lineal Múltiple," 2007.
- [4] I. Permatasari, "No Title העיורון," *J. Geotech. Geoenvironmental Eng. ASCE*, vol. 120, no. 11, p. 259, 2015.
- [5] A. Gavazza, A. Lizzeri, and N. Roketskiy, "A quantitative analysis of the used-car market," *Am. Econ. Rev.*, vol. 104, no. 11, pp. 3668–3700, 2014, doi: 10.1257/aer.104.11.3668.
- [6] C. Chen, L. Hao, and C. Xu, "Comparative analysis of used car price evaluation models," *AIP Conf. Proc.*, vol. 1839, no. May 2017, 2017, doi: 10.1063/1.4982530.
- [7] J. M. Ceferino and J. Ignacio, "LIII Reunión Anual," pp. 0–16, 2018.



- [8] E. Bustamante *et al.*, “negocio de certificación de autos usados,” 2022.
- [9] J. Berkovec, “New Car Sales and Used Car Stocks: A Model of the Automobile Market,” *RAND J. Econ.*, vol. 16, no. 2, p. 195, 1985, doi: 10.2307/2555410.
- [10] D. Acemoglu *et al.*, “The econometric society,” vol. 76, no. 4, pp. 909–933, 2015.