



Universidad Nacional José Faustino Sánchez Carrión

Facultad de Ingeniería Química y Metalúrgica

Escuela Profesional de Ingeniería Metalúrgica

Desarrollo de un modelo predictivo para estimar la importación de fertilizantes
químicos en el Perú

Tesis

Para optar el Título Profesional de Ingeniero
Metalúrgico

Autores

Eduardo Rodrigo Muñoz Fajardo

Jordan Brian Camillo Cruz

Asesor

Dr. Edgardo Octavio Carreño Cisneros

Huacho – Perú

2025



Reconocimiento - No Comercial – Sin Derivadas - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-nd/4.0/>

Reconocimiento: Debe otorgar el crédito correspondiente, proporcionar un enlace a la licencia e indicar si se realizaron cambios. Puede hacerlo de cualquier manera razonable, pero no de ninguna manera que sugiera que el licenciante lo respalda a usted o su uso. **No Comercial:** No puede utilizar el material con fines comerciales. **Sin Derivadas:** Si remezcla, transforma o construye sobre el material, no puede distribuir el material modificado. **Sin restricciones adicionales:** No puede aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros de hacer cualquier cosa que permita la licencia.



UNIVERSIDAD NACIONAL JOSÉ FAUSTINO SÁNCHEZ CARRIÓN

LICENCIADA

(Resolución de Consejo Directivo N° 012-2020-SUNEDU/CD de fecha 27/01/2020)

"Año de la unidad, la paz y el desarrollo"

FACULTAD DE INGENIERÍA QUÍMICA Y METALÚRGICA

ESCUELA PROFESIONAL DE INGENIERIA METALÚRGICA

INFORMACIÓN DE METADATOS

DATOS DEL AUTOR (ES):		
NOMBRES Y APELLIDOS	DNI	FECHA DE SUSTENTACIÓN
Eduardo Rodrigo Muñoz Fajardo	76614608	03/10/2024
Jordan Brian Camillo Cruz	72856735	03/10/2024
DATOS DEL ASESOR:		
NOMBRES Y APELLIDOS	DNI	CÓDIGO ORCID
Edgardo Octavio Carreño Cisneros	03631561	0000-0001-7063-7072
DATOS DE LOS MIEMBROS DE JURADOS – PREGRADO/POSGRADO-MAESTRÍA-DOCTORADO:		
NOMBRES Y APELLIDOS	DNI	CODIGO ORCID
Maximo Tomas Salcedo Meza	15602588	0000-0003-1993-2513
Alberto Irhaam Sanchez Guzman	15758117	0000-0003-1575-8466
Jaime Iman Mendoza	40936175	0000-0001-6232-0884

Camilo Cruz Jordan Brian_2024-023384 Muñoz Faj...

DESARROLLO DE UN MODELO PREDICTIVO PARA ESTIMAR LA IMPORTACIÓN DE FERTILIZANTES QUÍMICOS EN EL PERÚ

 Quick Submit

 Quick Submit

 Facultad de Ingeniería Química y Metalúrgica

Detalles del documento

Identificador de la entrega

trn:oid::1:2980402192

Fecha de entrega

8 ago 2024, 10:13 p.m. GMT-5

Fecha de descarga

21 ago 2024, 12:33 p.m. GMT-5

Nombre de archivo

Modelo_Predictivo_V3a_2.docx

Tamaño de archivo

317.5 KB

53 Páginas

7,470 Palabras

46,144 Caracteres



Página 2 of 60 - Descripción general de integridad

Identificador de la entrega trn:oid::1:2980402192

20% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Coincidencias menores (menos de 10 palabras)

Exclusiones

- N.º de fuentes excluidas
- N.º de coincidencias excluidas

Fuentes principales

19%  Fuentes de Internet

3%  Publicaciones

12%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión:

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitan distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Dedicatoria

A mis seres queridos por todo lo que me han dado y so en la vida.
Con todo respeto y admiración a mis padres. Gracias.

Eduardo y Jordan

Agradecimiento

Agradezco a Dios por todo, a mi asesor y profesores por el apoyo en mi formación profesional.

Eduardo

Jordan

ÍNDICE

Título de la tesis	3
Miembros del jurado	4
Dedicatoria	v
Dedicatoria	vi
Agradecimiento	7
INDICE DE TABLAS	11
INDICE DE FIGURAS	12
RESUMEN	xii
ABSTRACT	xiii
CAPÍTULO I	15
PLANTEAMIENTO DEL PROBLEMA	15
1.1 Descripción de la realidad problemática	15
1.2 Formulación del problema	16
1.2.1 Problema general	16
1.3.2 Objetivos específicos	16
1.4 Justificación de la investigación	17
1.5 Delimitación del estudio	17
1.6 Viabilidad de estudio	17
CAPÍTULO II	18

MARCO TEÓRICO.....	18
2.1 Antecedentes.....	18
2.1.1 Internacionales.....	18
2.1.2 Nacionales.....	20
2.2 Bases teóricas.....	22
2.3 Marco filosófico.....	27
2.4 Definiciones conceptuales.....	28
2.4 Formulación de la hipótesis.....	29
2.4.1. Hipótesis general.....	29
2.4.2. Hipótesis específicas.....	29
CAPÍTULO III.....	30
METODOLOGÍA.....	30
3.1 Diseño metodológico.....	30
3.1.1. Tipo de investigación.....	30
3.1.2. Nivel de investigación.....	30
3.1.3. Enfoque.....	30
3.2. Población y muestra.....	30
3.3. Técnicas e instrumentos de recolección de datos.....	30
3.4. Técnicas para el procesamiento de la información.....	31
CAPÍTULO IV.....	32

RESULTADOS.....	32
4.1 Análisis de los resultados.....	32
CAPÍTULO V.....	46
DISCUSIÓN, CONCLUSIONES Y RECOMENDACIONES	46
5.1 Discusión de resultados.....	46
5.2 Conclusiones.....	47
5.3 Recomendaciones	47
CAPÍTULO VI.....	48
REFERENCIAS DE INFORMACIÓN.....	48
Referencias.....	48
ANEXO 01: Matriz de consistencia	52

INDICE DE TABLAS

Tabla 1. Propiedades físico químicas de fertilizantes	24
Tabla 2. Parámetros descriptivos de tipos de urea	32

INDICE DE FIGURAS

Figura 1. Modelo de regresión lineal	26
Figura 2.. Diagrama de cajas total importación de fertilizantes.	33
Figura 3.. Importación de fertilizantes.	34
Figura 4.. Diagrama de cajas importación de fertilizantes.	34

RESUMEN

El estudio se enfoca en desarrollar un modelo de regresión para predecir la demanda de fertilizantes destinados a la agricultura, con el fin de optimizar la planificación y gestión de recursos en este sector. La investigación fue cuantitativa, de tipo aplicada explicativa, se tomaron como base registros de reportes del periodo de 1998 a 2021 referidos a importación de fertilizantes en Perú de del repositorio del Instituto Nacional de Estadística e Informática. Se empleó un modelo de regresión predictivo basado en python. Se concluye que, con el modelo de regresión para predecir la demanda de fertilizantes destinados a la agricultura, se logró un R^2 de hasta 90.02% lo que indica que hasta ese valor se explica el modelo

Palabras Clave: Fertilizante, modelo predictivo, python

ABSTRACT

The study focuses on developing a regression model to predict the demand for fertilizers for agriculture, in order to optimize the planning and management of resources in this sector. The research was quantitative, of an applied explanatory type, records of reports from the period from 1998 to 2021 referring to the import of fertilizers in Peru from the database of the National Institute of Statistics and Informatics were taken as a basis. A python-based predictive regression model was used. It is concluded that, with the regression model to predict the demand for fertilizers for agriculture, an R^2 of up to 90.02% was achieved, which indicates that the model is explained up to that value.

Keywords: Fertilizer, predictive model, python

INTRODUCCIÓN

Actualmente, los sistemas económicos requieren una planificación bien estructurada que permitan tomar decisiones y lograr las metas establecidas, se viene observando que en el campo de la ingeniería metalúrgica es necesario implementar modelos que permitan planificar y tomar decisiones. En ese sentido considerando los fertilizantes como sustancias sintéticas o naturales que se usan en el ámbito agrícola principalmente, se han planteado como objetivo desarrollar un modelo de regresión para predecir la demanda de fertilizantes destinados a la agricultura, industria metalúrgica, etc. con el fin de optimizar la planificación y gestión de recursos en este sector.

Justificándose el estudio en que se pretende establecimiento de una herramienta en el potencial consumo de fertilizantes químicos, lo cual ayudaría a planificar eficientemente, ya que con ello se podrían anticipar las posibles demandas de fertilizantes químicos, así como de otros insumos necesarios para atender a los diferentes sectores económicos e industriales. El modelo de predicción se elaboró con apoyo en Python como oportunidad de implementar innovación tecnológica en el ámbito de la ingeniería metalúrgica.

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

1.1 Descripción de la realidad problemática.

La producción agrícola a gran escala a nivel mundial está ocurriendo de manera desorganizada, lo que está provocando un deterioro ambiental significativo, especialmente en la calidad del suelo, debido al uso excesivo de insumos químicos, destacando entre ellos los fertilizantes. La industria de fertilizantes, en sus procesos químicos, utiliza cantidades significativas de materias primas como gas, aire y minerales, centrándose especialmente en la producción de fertilizantes nitrogenados (que combinan nitrógeno con gas natural o metano), fertilizantes fosforados (que incluyen fosfato y ácido sulfúrico) y fertilizantes a base de potasio (que se elaboran a partir de roca potásica). La producción de estos fertilizantes requiere parámetros específicos para garantizar la seguridad, la fiabilidad y, sobre todo, la eficacia, con criterios que permitan preservar el medio ambiente. Sin embargo, las expectativas de producción a nivel nacional no satisfacen completamente la demanda del mercado peruano, por lo que se hace necesario recurrir a la importación de estos insumos.

Es importante destacar que, para alcanzar una productividad agrícola eficiente, es necesario tener previsiones precisas y garantizar la calidad en la producción. Esto implica comprender y gestionar la demanda de insumos y la producción agrícola. A menudo, los niveles de producción no satisfacen plenamente la demanda del mercado, lo que dificulta la reinversión. Los problemas identificados sugieren deficiencias en el proceso de previsión, asignación y

monitoreo del uso de los recursos presupuestarios. Estas cuestiones han sido objeto de investigación para determinar qué tipo de fertilizante es el más adecuado y cuál es la demanda necesaria para importar y satisfacer las necesidades de cultivo, ya sea orgánico o inorgánico.

Por tanto, se requiere implementar un modelo de regresión que facilite la predicción de la demanda de fertilizantes destinados a la agricultura

1.2 Formulación del problema

1.2.1 Problema general

¿Cómo se puede desarrollar un modelo de regresión efectivo para anticipar la demanda de fertilizantes agrícolas y mejorar la planificación y gestión de recursos en el sector agrario?

1.2.2 Problemas específicos Seleccionar la materia prima más idónea

- ¿Cuáles son las variables predictoras fundamentales que ejercen influencia significativa sobre la demanda de fertilizantes destinados a la agricultura?
- ¿Cómo se puede construir y validar un modelo de regresión utilizando datos previos de ventas y otras variables asociadas a la producción agrícola para predecir de manera efectiva la demanda de fertilizantes agrícolas?

1.3 Objetivos de la investigación.

1.3.1 Objetivo general

Desarrollar un modelo de regresión para predecir la demanda de fertilizantes destinados a la agricultura, con el fin de optimizar la planificación y gestión de recursos en este sector.

1.3.2 Objetivos específicos

- Identificar las variables predictoras clave que influyen en la demanda de fertilizantes agrícolas.

- Construir y validar el modelo de regresión utilizando datos históricos de ventas y variables relacionadas con la producción agrícola.

1.4 Justificación de la investigación

El estudio predictivo ayudará significativamente a determinar el potencial consumo de fertilizantes químicos, lo cual ayudaría a planificar eficientemente, ya que con ello se podrían anticipar las posibles demandas de fertilizantes químicos, así como de otros insumos necesarios para atender a los diferentes sectores económicos e industriales, asimismo ayuda a tomar decisiones estratégicamente al maximizar recursos, pues se tendría en cuenta la capacidad logística para importación y distribución considerando la cadena productiva; mejorar el área agrícola. También se espera preservar la sostenibilidad ambiental al disminuir la contaminación de agua y suelo causada por el posible contacto de fertilizantes mitigando la contaminación por lixiviación y reducción de gases durante almacenamiento de estos productos químicos.

1.5 Delimitación del estudio

Delimitación espacial

La investigación se llevó a cabo utilizando la base de datos proporcionada del repositorio del Instituto Nacional de Estadística e Informática (INEI) 2023.

1.6 Viabilidad de estudio

El proyecto resultó factible debido a la disponibilidad de la información relevante en el repositorio del INEI, lo que minimiza la necesidad de destinar muchos recursos económicos para su procesamiento

CAPÍTULO II

MARCO TEÓRICO

2.1 Antecedentes

2.1.1 Internacionales

Molina Rea (2020). Realizó un estudio centrado en la aplicación de un modelo analítico para pronosticar las ventas de productos OTC de una empresa farmacéutica. Su propósito fue encontrar el mejor enfoque para predecir estas ventas, utilizando métodos de investigación como Design Science Research y KDD. Utilizó diversos modelos, como ARIMAX y redes neuronales, basados en datos históricos de ventas. Los resultados demostraron una precisión superior al 90%, reduciendo así el error previo del 15% en promedio. Esto evidencia la eficacia de los modelos desarrollados para predecir las ventas reales.

Spagnolo, et al. (2021). Realizó un estudio que consistió en crear modelos matemáticos para prever la eficacia de la dosificación helicoidal de fertilizantes, considerando diversas variables como inclinaciones, velocidad angular y paso helicoidal. Se realizaron pruebas con diferentes configuraciones de dosificadores helicoidales en laboratorio, evaluando su desempeño ante distintas condiciones. Los resultados revelaron que la inclinación transversal tiene poco efecto en la dosificación, mientras que la inclinación longitudinal influye de manera significativa, mostrando una relación lineal con la dosificación en el caso de un solo helicoide. Sin embargo, la dosificación con dos helicoides exhibió una menor variabilidad en respuesta a las inclinaciones

Longhini, et al. (2024), llevaron a cabo un estudio en Brasil para analizar el impacto de la aplicación de urea en pastos tropicales en tres condiciones de lluvia, mediante modelos matemáticos para estimar la volatilización de amoníaco (NH_3). Tras comparar varios modelos, se seleccionó el modelo Groot debido a su menor error cuadrático medio de predicción (0,29% de N total perdido como NH_3). Este modelo mostró una alta precisión y exactitud al predecir la volatilización de NH_3 , siendo especialmente relevante en condiciones de lluvia húmeda y seca. Se recomienda el uso del modelo Groot para estimar la volatilización de NH_3 después de la aplicación de urea en pastos Marandu, especialmente en condiciones de lluvia húmeda y seca. Estos hallazgos resaltan la importancia de considerar las condiciones climáticas al predecir y gestionar las pérdidas de nitrógeno como NH_3 en sistemas agrícolas tropicales, contribuyendo así a una gestión más eficiente y sostenible de los fertilizantes.

El análisis realizado por Castellanos Serrano, et al. (2024) se centra en la Inteligencia Artificial (IA) para mejorar los Sistemas de Soporte de Decisiones (SSD) en agricultura. Se emplearon métodos de aprendizaje automático y modelos predictivos para optimizar la gestión de cultivos y recursos. Los resultados muestran una precisión mejorada en la predicción de rendimientos, con un aumento del 15% en la eficiencia del manejo del uso de agua y fertilizantes en comparación con métodos tradicionales. Además, se observó un incremento en la colaboración y publicación científica en este ámbito, resaltando el potencial de la IA para impulsar la agricultura sostenible.

Asencio (2022) en su investigación se centra en desarrollar un modelo de aprendizaje automático supervisado que predice los precios cambiantes de insumos agrícolas en la región costera de Ecuador. Los agricultores de esta zona necesitan planificar sus cultivos considerando los costos de fertilizantes y agroquímicos. La propuesta implica la creación de un prototipo de algoritmos supervisados de aprendizaje automático para anticipar los precios de dichos

insumos. Se emplean series de tiempo con redes neuronales artificiales MLP y LSMT, utilizando datos de precios desde enero de 2013 hasta abril de 2022. Las métricas de evaluación se utilizan para determinar el modelo óptimo.

2.1.2 Nacionales

En su estudio, Castillo (2022) se centra en la creación de algoritmos de machine learning para construir modelos predictivos de regresión en el ámbito de la industria minera. Las empresas mineras enfrentan riesgos diversos, como factores geológicos, ambientales y sociales. Para mitigar estos riesgos y mejorar la rentabilidad, muchas empresas están adoptando tecnologías basadas en Inteligencia Artificial. La implementación de estas tecnologías ha resultado en mejoras significativas en la productividad, eficiencia energética, reducción de contaminación y seguridad laboral. El estudio plantea soluciones predictivas en diferentes casos de la industria minera: estimación del precio del oro, niveles de sílice en el concentrado de hierro y consumo de combustible en los vehículos mineros. Los modelos, desarrollados a partir de datos históricos mediante diversos algoritmos de machine learning, muestran un buen rendimiento según las métricas de evaluación, destacando el uso de algoritmos como SVR y Árbol de regresión para algunos casos, y Random Forest para otros, según la complejidad de cada situación. Se enfatiza la necesidad de un enfoque estructurado que combine conocimientos en ciencia de datos, minería y comprensión clara del problema a resolver mediante machine learning.

En su investigación, Penalillo (2021) se enfocó en mejorar la precisión en la estimación de la sobre dilución en tajos mineros mediante técnicas de análisis de regresión predictivo y aprendizaje automático (ML). Utilizando datos de reconciliación de tajos mineros explotados con el método de Sub Level Stopping (SLS) entre el periodo de 2017 y 2019, se aplicaron varias

técnicas, como análisis de regresión lineal y no lineal, así como métodos de ML como Máquinas de Vectores de Soporte (SVM) y bosques aleatorios (RF). Con la integración de estas técnicas se logró el mejoramiento significativo de la precisión de las estimaciones, lo que resultó en una reducción en los costos asociados al carguío y transporte de material roto en los tajos mineros.

En su investigación, Alcántara (2021) se enfocó en la predicción de la demanda de Gas Licuado de Petróleo (GLP) para el parque automotor peruano durante el segundo semestre de 2021. El estudio examinó la evolución de la demanda de GLP en el mercado peruano en los últimos seis años. El objetivo principal fue prever si la producción local y la importación de GLP serían suficientes para satisfacer la demanda del sector automotriz. La metodología utilizada fue el proceso estándar CRISP-DM, que consta de diez etapas para identificar y analizar las variables relevantes para el modelo. Se optó por un modelo de aprendizaje predictivo, que combina diversas técnicas estadísticas y algoritmos de aprendizaje automático. En la etapa de análisis y comprensión de la problemática, se emplearon herramientas como Power BI, KNime y Python.

Chang Hidalgo (2023), En su estudio comparación de técnicas de estimación mediante machine learning para predicción de costos en los programas de adquisiciones de entidades gubernamentales en el Perú. Anualmente, estas entidades deben estimar presupuestos para atender las necesidades de bienes y servicios en sus planes de adquisiciones. El Ministerio de Economía y Finanzas (MEF) revisa, evalúa, aprueba y asigna los recursos para estas propuestas. La investigación buscó identificar una técnica de machine learning para facilitar la predicción de costos. Se utilizó un dataset de contrataciones públicas del portal web de datos abiertos de OSCE y se implementaron técnicas como regresión lineal múltiple, árbol de decisión, bosque aleatorio y XGBoost, evaluando su desempeño con métricas como MAE,

MAPE, MSE, RMSE y R^2 , concluyendo que la regresión lineal múltiple obtuvo el mejor desempeño.

2.2 Bases teóricas

Los fertilizantes, ya sean orgánicos o inorgánicos, son sustancias que proporcionan nutrientes a las plantas para mejorar su crecimiento cuando estos elementos son escasos o se han agotado. Además de favorecer el crecimiento, los fertilizantes también contribuyen a mejorar la calidad de las plantas. Se dividen en nutrientes principales como Nitrógeno (N), Fósforo (P) y Potasio (K), nutrientes secundarios como Azufre (S), Sodio (Na), Calcio (Ca) y Magnesio (Mg), y micronutrientes como Boro (B), Cobalto (Co), Cobre (Cu), Hierro (Fe), Manganeso (Mn), Molibdeno (Mo) y Zinc (Zn). Estos nutrientes pueden presentarse en forma quelada o compleja (Navarro Garcia, 2023).

En ese sentido Asencio (2022), con respecto a los fertilizantes, cita a los autores como Finck (2012), Tisdale, S. L., Nelson, W. L., Balasch, J., & Piña, C. (1988), y Ginés, I., & Mariscal Sancho, I. D. L. (2002), quienes consideran a los fertilizantes como sustancias sintéticas o naturales usadas principalmente en la agricultura y que proveen nutrientes vitales para el desarrollo de las plantas; Estas sustancias en su contenido destacan: el nitrógeno (N), el fósforo (P), el potasio (K) y oligoelementos como hierro (Fe), boro (B), cobre (Cu), manganeso (Mn), zinc (Zn) y molibdeno (Mo). Estos elementos, contenidos en los fertilizantes, son importantes para el crecimiento de las plantas, contribuyendo al rendimiento eficiente de los cultivos. Estas sustancias o fertilizantes abastecen de los nutrientes necesarios para promover un crecimiento saludable y una producción agrícola óptima.

Urea (nitrato de amonio).

Cuando se habla de urea, se hace referencia al compuesto químico del ácido carbónico de la di-amida representado por la fórmula química $\text{CO}(\text{NH}_2)_2$, también se le conoce como carbamida, (industriales, 2023).

Nitrato de amonio.

El nitrato de amonio, también llamado nitrato amónico, es una sal formada por iones de nitrato y de amonio, su fórmula química es NH_4NO_3 , de aspecto incoloro, higroscópico. Se obtiene por neutralización de ácido nítrico con amoniaco: $\text{NH}_3 + \text{HNO}_3 \rightarrow \text{NH}_4\text{NO}_3$, [(Quimica.es, 2023) ; (Biología del Sr. Paul, 2012)].

Sulfato de amonio (sulfato amónico, sulfato diamónico).

El sulfato de amonio es de apariencia sólida, higroscópico y cristalino. Es una sal cuya fórmula química es $(\text{NH}_4)_2\text{SO}_4$. Es de color blanco y se presenta en forma de cristales. Su aplicación principal es actuar como fertilizante de suelos. Contiene un 21% de nitrógeno y un 24% de azufre. Se produce mediante la siguiente reacción química: $2\text{NH}_3 + \text{H}_2\text{SO}_4 \rightarrow (\text{NH}_4)_2\text{SO}_4$. (Sulfato de Amonio, 2023)

Fosfato de amonio

Es una sal neutra de fosfato de amonio solubles en agua, se obtiene mediante la siguiente reacción química (Fosfato diamónico, 2023):



Sulfato de magnesio y potasio.

El sulfato doble de potasio y magnesio es un fertilizante de origen natural que se refina en procesos de lavado y refinado. Composición: Potasio K_2O (K) = 22%; Magnesio (Mg)= 46,1%;

azufre (S)= 46%; cloro (Cl)=2,5% y humedad 0,3% [(YFC, 2024); (Barco Javier y otros, 2024)].

Tabla 1.

Propiedades físicas químicas de fertilizantes.

	Fórmula	Masa Molecular g/mol	Punto de fusión, °C	Punto de ebullición, °C	Densidad d/ml.
Urea	CO(NH ₂) ₂	60	132,7		768
Nitrato de amonio	NH ₄ NO ₃	80,04	169.6	210	1,72
Sulfato de amonio	(NH ₄) ₂ SO ₄	132,14	257	NO determinado	1,769
Fosfato de amonio	(NH ₄) ₂ HPO ₄	132.06	155 °C		1,619

Fuente: Elaboración propia. En base a Wikipedia y otros.

La previsión de la demanda implica estimar las ventas futuras para ajustar decisiones y planificación estratégica, reduciendo la incertidumbre. Aunque ningún método es perfecto, basarse en datos reales estimativos mejora la fiabilidad de los cálculos. La incorporación progresiva de más datos permite prever o ajustar posibles desviaciones en el proceso decisorio (Martínez, 2014). Para Krumag, Wells & Graddy (2013, pág. 66) , la demanda se ve afectada por diversos factores: cambios en los precios de bienes sustitutos y complementarios, fluctuaciones en la renta, evolución de gustos y preferencias, variaciones en expectativas de compra y cambios en el número de consumidores, incluyendo el aprendizaje automático.

En cuanto al aprendizaje automático se puede manifestar que una rama de la inteligencia artificial y la informática que se centra en usar datos y algoritmos para imitar la forma en que los humanos aprenden a hacer cierta tarea, mejorando progresivamente su precisión. El Deep Learning es un subconjunto de la inteligencia artificial basado en redes neuronales artificiales con aprendizaje de representación (Vargas, et al., 2017).

Modelos de predicción.

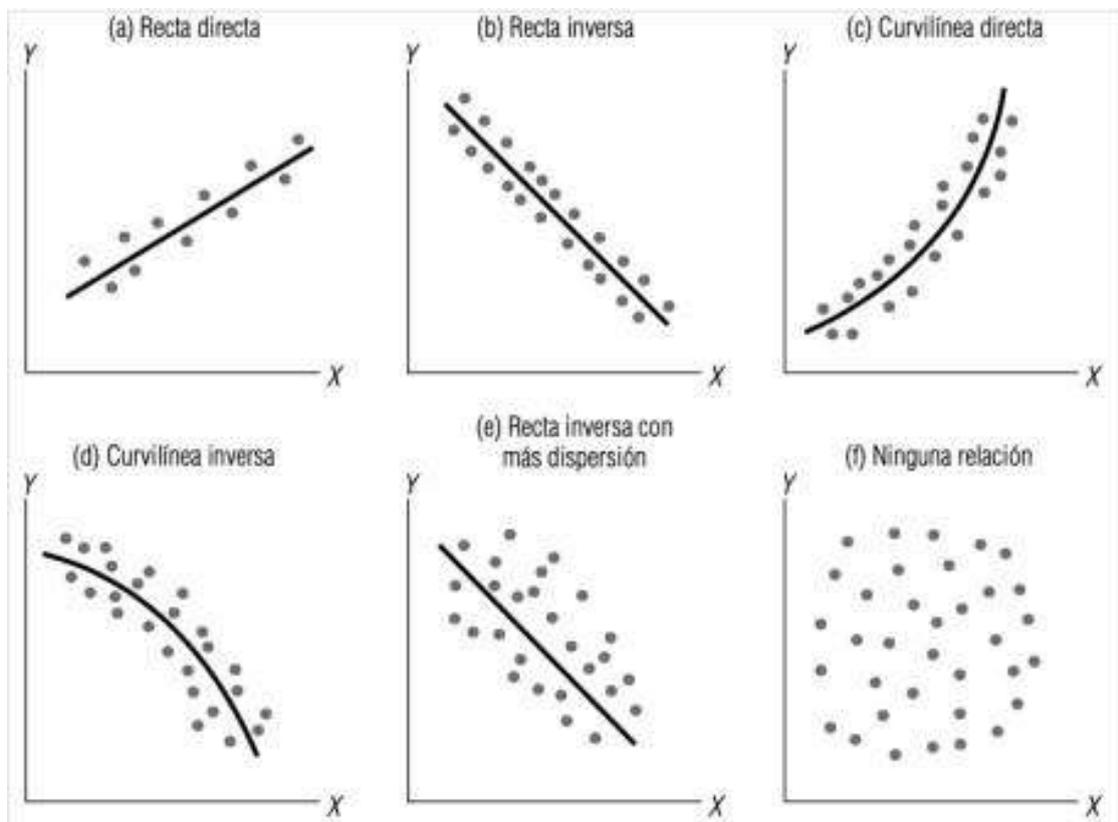
Actualmente el análisis predictivo viene tomando mucha importancia en las decisiones empresarial y principalmente en los sectores importantes de la economía. Estos modelos se basan en métodos estadísticos y de algoritmos para simular escenarios de comportamientos futuros basados en reportes históricos. Además, se extraen modelos analíticos para predecir tendencias o resultados que muchas veces son desconocidos o limitados cuando se emplean técnicas matemáticas y estadísticas. La interacción entre la minería de datos (estructurados y no estructurados); así como de la estadística construyen en la generación de modelos predictivos (Big Data Marketer, 2024).

Según Menoyo, et al. (2021), los modelos predictivos pueden ser de clasificación o de regresión. El modelo de clasificación analiza una entrada (x) y produce una salida discreta (y), mientras que el modelo de regresión analiza una entrada (x) y produce una salida numérica (y)

Rayón (2017) señala la importancia de encontrar un ajuste adecuado a los datos mediante modelos como la regresión lineal y la logística. Estos modelos pueden enfrentar el problema del "overfitting", ajustándose demasiado a los datos disponibles y ofreciendo resultados menos eficientes en casos de mayor complejidad.

Modelo De Regresión Lineal, El modelo de regresión lineal analiza la relación entre dos variables: la variable independiente y la variable dependiente. Es esencial reconocer que esta relación no implica causalidad. La ecuación recta que determina la dirección (positiva o negativa) y el grado de correlación es la siguiente. $y = a + bx$, Donde: y es la variable dependiente; x es la variable independiente; a es el valor de la variable en la ordenada Y ; b es la pendiente de la recta. Y se calcula en base X (Levin & Rubin, 2004).

Figura 1. Modelos de regresión lineal.



Fuente: (Levin & Rubin, 2004)

Scikit-Learn es una biblioteca de Python que ofrece acceso a versiones eficientes de muchos algoritmos comunes, lo que permite a los usuarios desarrollar modelos de aprendizaje automático de manera rápida y fácil.

Scikit-Learn es una biblioteca de Python que proporciona una API estandarizada para el desarrollo de modelos de aprendizaje automático. Aunque el modelo a utilizar puede variar, los pasos básicos para el modelado son similares:

Elegir un modelo importando la clase adecuada de Scikit-Learn.

Establecer los parámetros del modelo. Si ya está seguro de los parámetros que desea utilizar, puede rellenarlos a mano, o utilizar técnicas como GridSearchCV para encontrar los parámetros óptimos (DataScientest, 2024)

Entrenar el modelo en el conjunto de aprendizaje utilizando el método de ajuste.

Probar el modelo con datos nuevos:

- a) Para el aprendizaje supervisado, utilice el método de predicción en los datos de prueba.
- b) Para el aprendizaje no supervisado, utilice los métodos de transformación o predicción.

2.3 Marco filosófico.

El marco filosófico de esta investigación se basa en una perspectiva pragmática que destaca la importancia de aplicar el conocimiento de manera práctica de la ingeniería metalúrgica para resolver problemas específicos en la agricultura. Se emplea un enfoque científico que enfatiza la utilidad y eficacia del modelo de regresión como una herramienta predictiva para mejorar la planificación y gestión de recursos agrícolas. Además, se adopta una postura epistemológica positivista que busca objetividad y validez al recopilar y analizar datos empíricos para desarrollar el modelo. Este enfoque filosófico respalda la búsqueda de soluciones concretas y aplicables que puedan aumentar la eficiencia y sostenibilidad del sector agrícola mediante una predicción precisa de la demanda de fertilizantes.

2.4 Definiciones conceptuales.

Demanda

Fertilizante

Son sustancias de naturaleza orgánica o inorgánica, natural o sintético, que abastece a las plantas con los nutrientes necesarios para su desarrollo, crecimiento y una producción efectiva.

(García & Navarro García, 2014)

Insumo

Son todos aquellos bienes o servicios empleados en la producción agrícola, se transforman mediante la tecnología correspondiente en la industria para generar productos y servicios.

(Madrid, 2008)

Minería de datos

Es el proceso de utilizar Bases de Datos, estadísticas y correlaciones en una cantidad de datos.

Modelo predictivo

En el ámbito de la inteligencia artificial, la evaluación de modelos en este ámbito es esencial en el desarrollo de sistemas de aprendizaje automático. Se analiza el rendimiento y la calidad de las predicciones mediante indicadores o métricas que varían según la tarea: clasificación o regresión en estudio. (Ascencio Beltran, 2022)

Modelo de predicción.

Son procedimientos sistematizados que empleando técnicas computacionales para el análisis de datos permiten de eventos pasados inferir la probabilidad que ocurra un evento y descubrir potenciales oportunidades comerciales (REDACCIÓN ESPAÑA, 2020).

2.4 Formulación de la hipótesis

2.4.1. Hipótesis general

Al desarrollar un modelo de regresión para predecir la demanda de fertilizantes agrícolas, se logrará optimizar la planificación y gestión de recursos en el sector agrícola.

2.4.2. Hipótesis específicas

- Al identificar las variables predictoras clave que influyen en la demanda de fertilizantes agrícolas, será posible comprender mejor los factores determinantes de dicha demanda.
- Al construir y validar un modelo de regresión utilizando datos históricos de ventas y variables relacionadas con la producción agrícola, se logrará desarrollar un modelo predictivo preciso y confiable para predecir la demanda de fertilizantes agrícolas.

CAPÍTULO III

METODOLOGÍA

3.1 Diseño metodológico

3.1.1. Tipo de investigación.

La investigación es aplicada se tomaron como base reportes referidos a importación de fertilizantes en Perú de la base de datos del INEI. Es transversal porque se realizó en un determinado momento.

3.1.2. Nivel de investigación

Es explicativa dado que busca analizar y proyectar datos para tomar decisiones.

3.1.3. Enfoque.

Considerando la naturaleza de los datos el enfoque es cuantitativo.

3.2. Población y muestra.

La población de interés estuvo constituida por los registros de datos obtenidos del INEI correspondientes al periodo 1998 al 2021 sobre la importación de fertilizantes en el Perú.

El tamaño de la muestra se consideró igual al tamaño de la población.

3.3. Técnicas e instrumentos de recolección de datos

Para obtener los datos se considerará el análisis de Datos Secundarios, para lo cual se utilizarán datos que han sido recopilados por el Instituto Nacional de Estadística e Informática (INEI) referente a la importación de fertilizantes en el país durante el período

de interés (1998-2021). Estos datos obtenidos proporcionan una visión histórica y detallada de la demanda de fertilizantes para el mercado peruano.

3.4. Técnicas para el procesamiento de la información

Para procesar los datos recopilados sobre la importación de fertilizantes en el Perú, se emplearon las siguientes técnicas:

Análisis Estadístico Descriptivo: Se realizó un análisis detallado de los principales parámetros de estadísticas descriptivas de los datos, como media, mediana, desviación estándar y percentiles. Estos proporcionaron una comprensión inicial de la distribución y las tendencias de la demanda de fertilizantes.

Modelado Predictivo: Se aplicaron técnicas de modelado predictivo basados en programación basado en Python.

CAPÍTULO IV

RESULTADOS

4.1 Análisis de los resultados.

Tabla 2.

Parámetros descriptivos de tipos de urea.

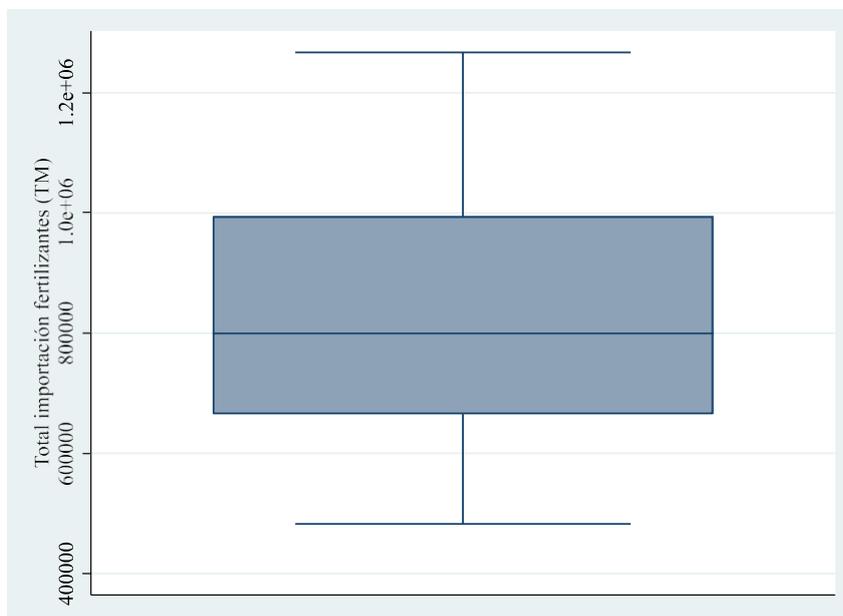
Variable	Media	Mediana	Desv Standard	Máx	Mín	95% intervalo confianza	
						Min	Máx
Total	837373.30	799518.30	238848.70	1267447.00	482552.00	736516.30	938230.20
Urea	344395.80	346024.80	51192.57	424975.50	247864.80	322779.10	366012.60
Nitrato de amonio	81668.62	62125.89	70155.45	312479.30	9913.00	52044.57	111292.70
Sulfato de Amonio	133089.60	116647.60	75232.66	264289.30	31586.65	101321.60	164857.60
Fosfato de amonio	144530.90	145872.20	46324.46	248317.70	53190.42	124969.80	164092.00
Cloruro de potasio	71633.63	63274.94	32733.74	143739.20	23222.63	57811.38	85455.88
Sulfato de potasio	40452.74	36339.00	22231.42	85325.12	8384.57	31065.24	49840.25
Sulfato de Magnesio y potasio	16867.25	15082.82	11727.67	44529.00	0.32	11915.09	21819.41

Con respecto a la cantidad Total de fertilizantes se observa en tabla 1 que el promedio en toneladas métricas es de 838 373,30 TM (DE=238 848,70), siendo el valor máximo de 1 267 447,00 y mínimo de 482 552,00. El intervalo de confianza va desde 736 516,30 hasta 938 230,20. Lo que significa que con un nivel de confianza del 95%, se espera que el verdadero valor de la población esté dentro de este rango.

Con respecto a la mayor cantidad de fertilizantes se observa que es la urea, el promedio en toneladas métricas es de 344 395,80 TM (DE=51 192,57), siendo el valor máximo de 424 975,50 TM y mínimo de 247 864,80 TM. El intervalo de confianza va desde 322 779,10 TM hasta 366 012,60 TM. Lo que significa que con un nivel de confianza del 95%, se espera que el verdadero valor de la población esté dentro de este rango.

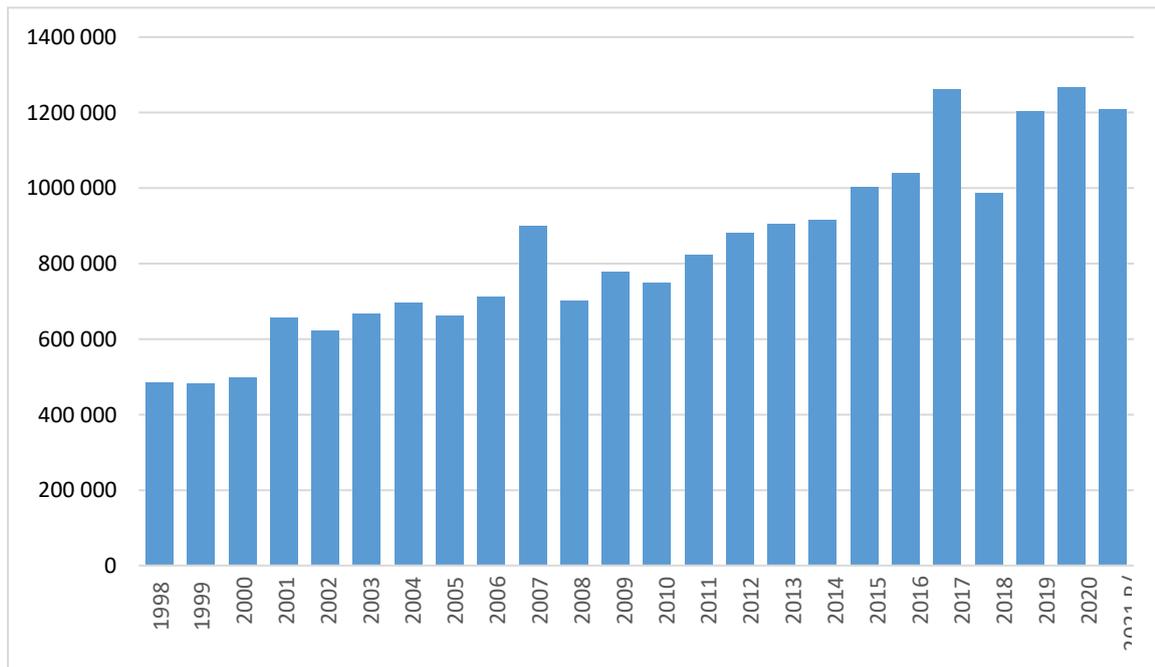
Con respecto a la menor cantidad de fertilizantes importados se observa que es la urea, el promedio en toneladas métricas es de 16 867,25 TM (DE=11 727,67), siendo el valor máximo de 44 529,00 TM y mínimo de 0,32 TM. El intervalo de confianza va desde 11 915,09 TM hasta 21 819,41 TM. Lo que significa que con un nivel de confianza del 95%, se espera que el verdadero valor de la población esté dentro de este rango.

Figura 2. Diagrama de cajas Total importación fertilizantes.



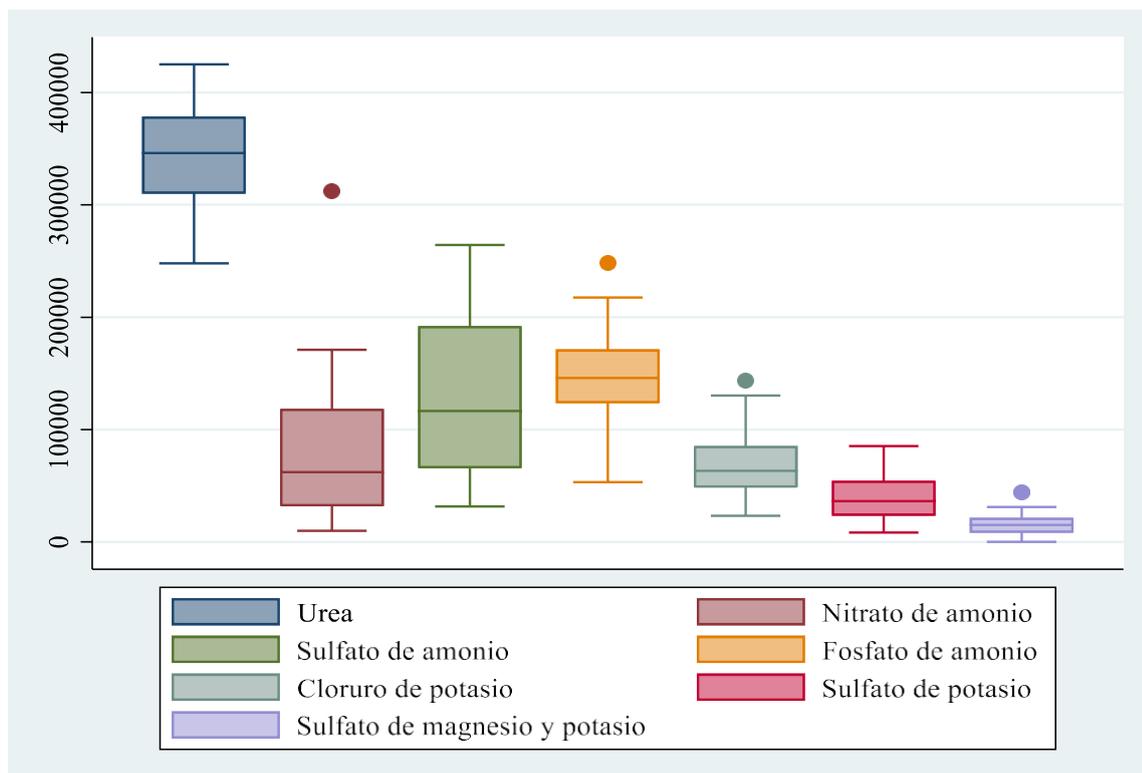
En figura 2 se aprecia el reporte de registro de total de fertilizantes importados, encontrándose que el 25% (cuartil 1) de las importaciones esta alrededor de 664 998,10 TM y que el 75% (cuartil 3) de las importaciones está en 994 950,20 TM.

Figura 3. Importación de fertilizantes.



En figura 3, se observa un incremento en el comportamiento de la importación de Fertilizantes, lo cual evidencia un incremento.

Figura 4. Diagrama de cajas importación de fertilizantes.



En Figura 4 diagrama de cajas sobre las importación de fertilizantes, se aprecia que la urea es la que más se importa; mientras que el Sulfato de Magnesio y potasio como fertilizante de menor consumo., .

Programación en Python.

Importar librerías necesarias

```
import pandas as pd

import numpy as np

from sklearn.model_selection import train_test_split

from sklearn.linear_model import LinearRegression

from sklearn.metrics import mean_squared_error, r2_score
```

Crear DataFrame con los datos

```
data = {

    'Año': range(1998, 2022),

    'Total': [484296, 482552, 498523, 656447, 622613, 666781, 694766, 663215, 710767,
898227, 701485, 777249, 747866, 821787, 881962, 905305, 915050, 1002131, 1039725,
1260705, 987769, 1202665, 1267447, 1207627],

    'Urea': [278849, 296182, 350139, 326571, 374278, 334212, 323422, 247865, 295338,
367786, 277114, 424976, 327046, 382875, 400532, 365079, 341911, 424309, 358008, 413689,
256901, 399004, 373600, 325816],

    'Amonio_1': [21031, 9913, 13190, 15547, 34591, 39145, 63036, 61216, 66922, 109160,
117545, 22971, 32443, 31037, 64054, 55561, 99364, 50572, 119554, 153109, 171016, 169337,
127253, 312479],

    'Amonio_2': [45341, 36969, 39476, 95311, 31587, 67359, 63976, 108548, 63409, 93529,
112679, 104207, 128070, 120616, 149005, 181557, 134224, 187730, 227205, 234949, 196711,
264289, 250812, 256592],
```

```

'Amonio_3': [67348, 78509, 53190, 122879, 104231, 123857, 152166, 139578, 183732,
135929, 87398, 159052, 134140, 129386, 163070, 157391, 172561, 169899, 189004, 217448,
162621, 189729, 248318, 127306],
'Fato_de_cal': [17056, 8395, 6225, 18719, 13, 10041, 4291, 1871, 3606, 242, 1647, 5949,
np.nan, 1988, 2303, 2643, 1854, 2171, 3739, 5307, 2903, 3498, 9170, 0],
'Magnesio': [34655, 30265, 23223, 51980, 50370, 46657, 49836, 62759, 46561, 104738,
52743, 42940, 82361, 63791, 52810, 81033, 82349, 107664, 79772, 130255, 128155, 85340,
143739, 85213],
'Potasio_1': [14456, 14485, 8385, 17082, 23644, 35349, 27976, 26699, 34587, 55776, 36282,
10508, 23219, 47565, 36396, 47180, 53300, 40961, 46179, 61919, 69462, 76163, 85325,
77969],
'Potasio_2': [5560, 7834, 4696, 8359, 3901, 10162, 10064, 14679, 16613, 31066, 16076,
6646, 20587, 44529, 13792, 14861, 29487, 18825, 16262, 44029, 0, 15305, 29230, 22251]
}
df = pd.DataFrame(data)
#

```

Separar las variables predictoras (X) y la variable objetivo (y)

```

X = df.drop(['Año', 'Total'], axis=1)
y = df['Total']

```

Dividir los datos en conjunto de entrenamiento y conjunto de prueba

```

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

```

Crear y entrenar el modelo de regresión lineal

```

model = LinearRegression()
model.fit(X_train, y_train)

```

Realizar predicciones sobre el conjunto de prueba

```
y_pred = model.predict(X_test)
```

Evaluar el rendimiento del modelo

```
mse = mean_squared_error(y_test, y_pred)
```

```
r2 = r2_score(y_test, y_pred)
```

```
print("Mean Squared Error (MSE):", mse)
```

```
print("Coefficient of Determination (R^2):", r2)
```

Dividir los datos en conjunto de entrenamiento y conjunto de prueba

```
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

Crear y entrenar el modelo de regresión lineal

```
model = LinearRegression()
```

```
model.fit(X_train, y_train)
```

Realizar predicciones sobre el conjunto de prueba

```
y_pred = model.predict(X_test)
```

Evaluar el rendimiento del modelo

```
mse = mean_squared_error(y_test, y_pred)
```

```
r2 = r2_score(y_test, y_pred)
```

```
print("Mean Squared Error (MSE):", mse)
```

```
print("Coefficient of Determination (R^2):", r2)
```

Entrenando con algunas variables (Código independiente):

```
import pandas as pd
```

```
import numpy as np
```

```

import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression

# Datos
datos = {
    'Año': np.arange(1998, 2022),
    'Total': [484296, 482552, 498523, 656447, 622613, 666781, 694766, 663215, 710767,
898227, 701485, 777249, 747866, 821787, 881962, 905305, 915050, 1002131, 1039725,
1260705, 987769, 1202665, 1267447, 1207627],
    'Urea': [278849, 296182, 350139, 326571, 374278, 334212, 323422, 247865, 295338,
367786, 277114, 424976, 327046, 382875, 400532, 365079, 341911, 424309, 358008,
413689, 256901, 399004, 373600, 325816],
    'Amonio': [21031, 9913, 13190, 15547, 34591, 39145, 63036, 61216, 66922, 109160,
117545, 22971, 32443, 31037, 64054, 55561, 99364, 50572, 119554, 153109, 171016, 169337,
127253, 312479]
}

# Crear DataFrame
df = pd.DataFrame(datos)

# Separar las características (año) y la variable objetivo (total)
anio = df['Año'].values.reshape(-1, 1)
total = df['Total'].values

# Crear y entrenar el modelo de regresión lineal
modelo = LinearRegression()
modelo.fit(anio, total)

# Predicción del modelo de regresión
prediccion = modelo.predict(anio)

# Gráfico de dispersión de datos reales
plt.scatter(df['Año'], df['Total'], color='blue', label='Datos reales')

# Gráfico de la línea de regresión

```

```
plt.plot(df['Año'], prediccion, color='red', linewidth=2, label='Regresión lineal')
```

```
# Etiquetas y título
```

```
plt.xlabel('Año')
```

```
plt.ylabel('Total')
```

```
plt.title('Regresión lineal de la demanda de fertilizantes')
```

```
# Leyenda
```

```
plt.legend()
```

```
# Mostrar el gráfico
```

```
plt.show()
```

Proyectando al 2030

```
import numpy as np
```

```
import matplotlib.pyplot as plt
```

```
# Años desde 1998 hasta 2030
```

```
nuevos_anios = np.arange(1998, 2031)
```

```
# Predicción del modelo para los nuevos años
```

```
prediccion_2030 = modelo.predict(nuevos_anios.reshape(-1, 1))
```

```
# Graficar los datos reales y la predicción hasta 2030
```

```
plt.scatter(anio, total, color='blue', label='Datos reales')
```

```
plt.plot(anio, prediccion, color='red', label='Predicción')
```

```
# Graficar la predicción hasta 2030
```

```
plt.plot(nuevos_anios, prediccion_2030, color='green', linestyle='--', label='Predicción hasta 2030')
```

```
# Etiquetas y título del gráfico
```

```
plt.xlabel('Año')
```

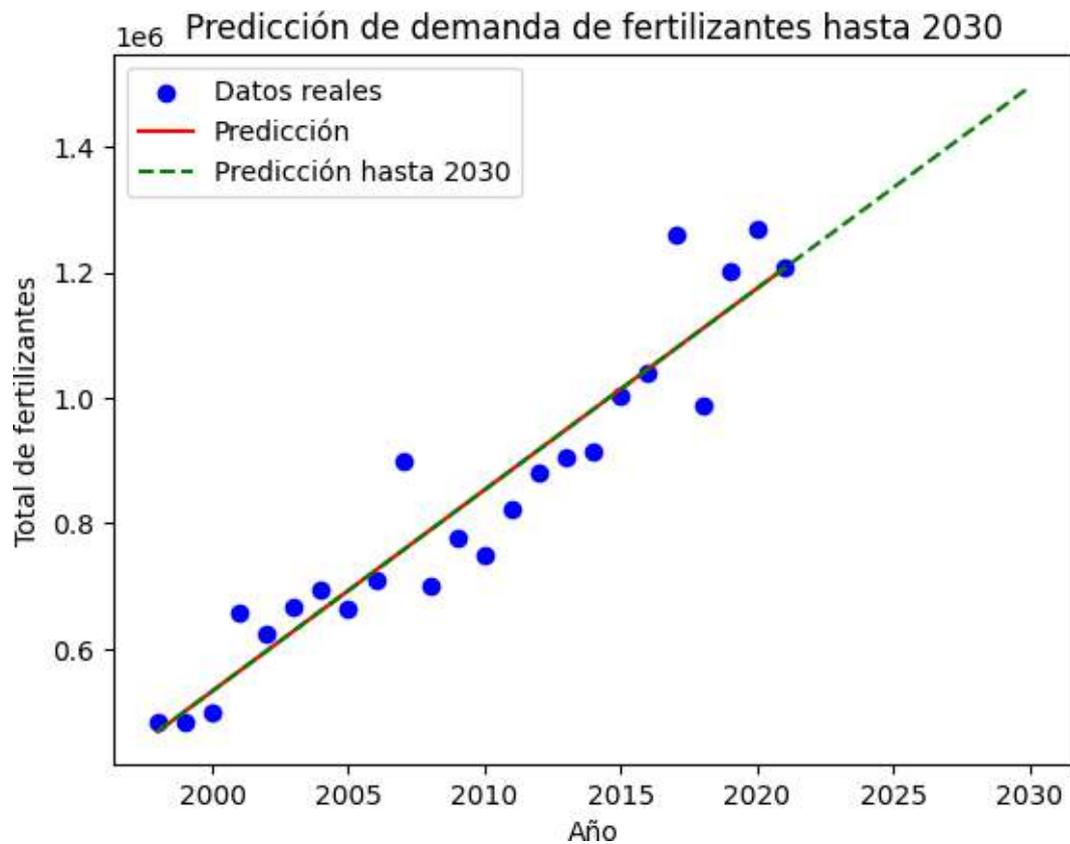
```
plt.ylabel('Total de fertilizantes')
plt.title('Predicción de demanda de fertilizantes hasta 2030')
```

```
# Mostrar leyenda
```

```
plt.legend()
```

```
# Mostrar el gráfico
```

```
plt.show()
```



```
from sklearn.metrics import mean_squared_error, r2_score
```

```
# Calcular el Error Cuadrático Medio (MSE)
```

```
mse = mean_squared_error(total, prediccion)
print("Error Cuadrático Medio (MSE):", mse)
```

```
# Calcular el Coeficiente de Determinación (R^2)
```

```
r2 = r2_score(total, prediccion)
print("Coeficiente de Determinación (R^2):", r2)
```

```
from sklearn.metrics import mean_squared_error, r2_score
```

Calcular el Error Cuadrático Medio (MSE)

```
mse = mean_squared_error(total, prediccion)
print("Error Cuadrático Medio (MSE):", mse)
```

Calcular el Coeficiente de Determinación (R²)

```
r2 = r2_score(total, prediccion)
print("Coeficiente de Determinación (R2):", r2)
```

Ahora corro para tres productos

```
import numpy as np
import pandas as pd
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score
import matplotlib.pyplot as plt
```

Datos de entrenamiento

```
anio = np.array([1998, 1999, 2000, 2001, 2002, 2003, 2004, 2005, 2006, 2007, 2008, 2009,
2010, 2011, 2012, 2013, 2014, 2015, 2016, 2017, 2018, 2019, 2020, 2021])
amonio_1 = np.array([278849, 296182, 350139, 326571, 374278, 334212, 323422, 247865,
295338, 367786, 277114, 424976, 327046, 382875, 400532, 365079, 341911, 424309,
358008, 413689, 256901, 399004, 373600, 325816])
amonio_2 = np.array([21031, 9913, 13190, 15547, 34591, 39145, 63036, 61216, 66922,
109160, 117545, 22971, 32443, 31037, 64054, 55561, 99364, 50572, 119554, 153109,
171016, 169337, 127253, 312479])
amonio_3 = np.array([45341, 36969, 39476, 95311, 31587, 67359, 63976, 108548, 63409,
93529, 112679, 104207, 128070, 120616, 149005, 181557, 134224, 187730, 227205,
234949, 196711, 264289, 250812, 256592])
```

Inicializar el modelo de regresión lineal para cada variable de amonio

```
modelo_1 = LinearRegression()
modelo_2 = LinearRegression()
modelo_3 = LinearRegression()
```

Entrenar el modelo para cada variable de amonio

```
modelo_1.fit(anio.reshape(-1, 1), amonio_1)
modelo_2.fit(anio.reshape(-1, 1), amonio_2)
modelo_3.fit(anio.reshape(-1, 1), amonio_3)
```

Predicción para el año 2030

```
anio_2030 = np.array([2030]).reshape(-1, 1)
prediccion_1 = modelo_1.predict(anio_2030)
prediccion_2 = modelo_2.predict(anio_2030)
prediccion_3 = modelo_3.predict(anio_2030)
```

Gráfico de dispersión de datos reales

```
plt.scatter(anio, amonio_1, color='red', label='Amonio_1')
plt.scatter(anio, amonio_2, color='blue', label='Amonio_2')
plt.scatter(anio, amonio_3, color='green', label='Amonio_3')
```

Línea de regresión para cada variable de amonio

```
plt.plot(anio, modelo_1.predict(anio.reshape(-1, 1)), color='red', linestyle='dashed',
label='Regresión Amonio_1')
plt.plot(anio, modelo_2.predict(anio.reshape(-1, 1)), color='blue', linestyle='dashed',
label='Regresión Amonio_2')
plt.plot(anio, modelo_3.predict(anio.reshape(-1, 1)), color='green', linestyle='dashed',
label='Regresión Amonio_3')
```

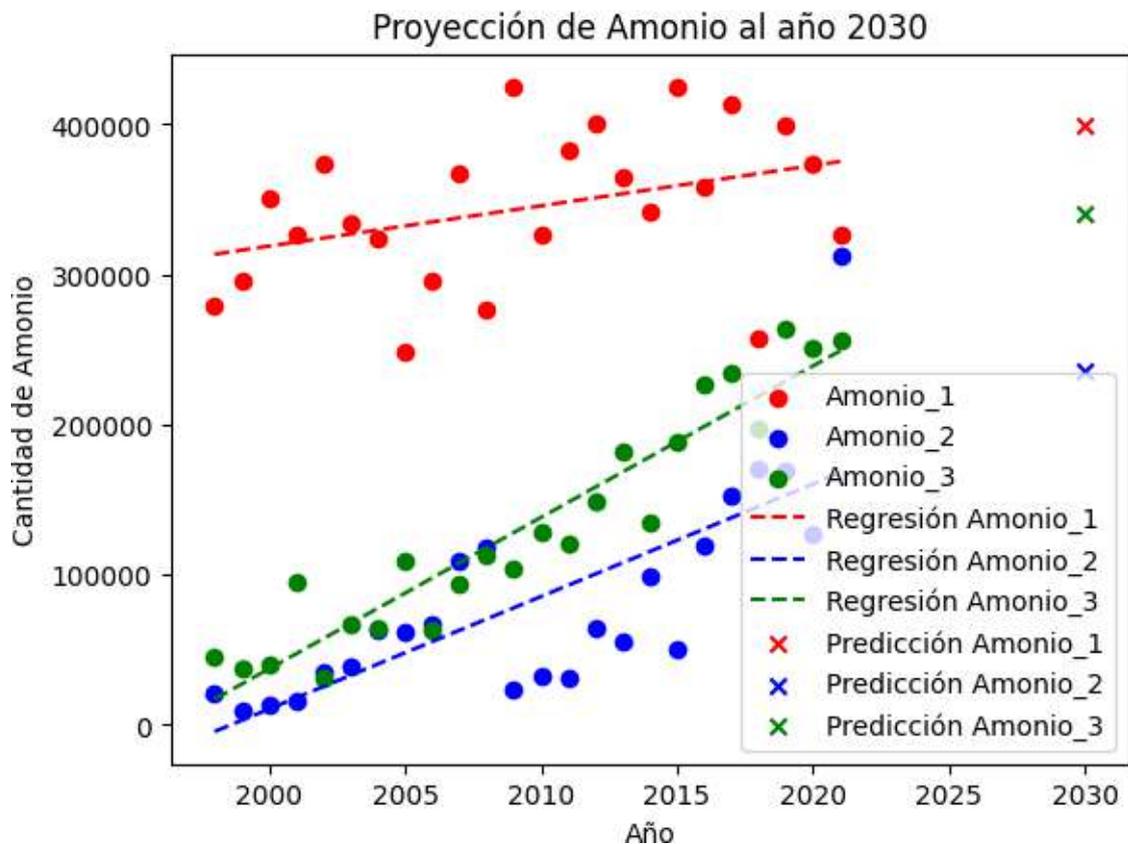
Proyección al año 2030

```
plt.scatter(2030, prediccion_1, color='red', marker='x', label='Predicción Amonio_1')
plt.scatter(2030, prediccion_2, color='blue', marker='x', label='Predicción Amonio_2')
plt.scatter(2030, prediccion_3, color='green', marker='x', label='Predicción Amonio_3')
```

```
plt.xlabel('Año')
```

```
plt.ylabel('Cantidad de Amonio')
plt.title('Proyección de Amonio al año 2030')
plt.legend()
plt
```

```
<module      'matplotlib.pyplot'      from      '/usr/local/lib/python3.10/dist-
packages/matplotlib/pyplot.py'>
```



Calcular las predicciones para los datos de entrenamiento

```
prediccion_entrenamiento_1 = modelo_1.predict(anio.reshape(-1, 1))
prediccion_entrenamiento_2 = modelo_2.predict(anio.reshape(-1, 1))
prediccion_entrenamiento_3 = modelo_3.predict(anio.reshape(-1, 1))
```

Calcular el Error Cuadrático Medio (MSE)

```
mse_1 = mean_squared_error(amonio_1, prediccion_entrenamiento_1)
mse_2 = mean_squared_error(amonio_2, prediccion_entrenamiento_2)
```

```
mse_3 = mean_squared_error(amonio_3, prediccion_entrenamiento_3)
```

```
print("Error Cuadrático Medio (MSE) Amonio_1:", mse_1)
```

```
print("Error Cuadrático Medio (MSE) Amonio_2:", mse_2)
```

```
print("Error Cuadrático Medio (MSE) Amonio_3:", mse_3)
```

```
# Calcular el Coeficiente de Determinación (R^2)
```

```
r2_1 = r2_score(amonio_1, prediccion_entrenamiento_1)
```

```
r2_2 = r2_score(amonio_2, prediccion_entrenamiento_2)
```

```
r2_3 = r2_score(amonio_3, prediccion_entrenamiento_3)
```

```
print("Coeficiente de Determinación (R^2) Amonio_1:", r2_1)
```

```
print("Coeficiente de Determinación (R^2) Amonio_2:", r2_2)
```

```
print("Coeficiente de Determinación (R^2) Amonio_3:", r2_3)
```

```
Error Cuadrático Medio (MSE) Amonio_1: 2165757305.9792566
```

```
Error Cuadrático Medio (MSE) Amonio_2: 2020945672.0813115
```

```
Error Cuadrático Medio (MSE) Amonio_3: 541340710.6622734
```

```
Coeficiente de Determinación (R^2) Amonio_1: 0.1376573331543377
```

```
Coeficiente de Determinación (R^2) Amonio_2: 0.5715340436458413
```

```
Coeficiente de Determinación (R^2) Amonio_3: 0.9001973378095771
```

CAPÍTULO V

DISCUSIÓN, CONCLUSIONES Y RECOMENDACIONES

5.1 Discusión de resultados.

Con respecto al objetivo general sobre desarrollar un modelo de regresión para predecir la demanda de fertilizantes destinados a la agricultura, con el fin de optimizar la planificación y gestión de recursos en este sector se logró un R^2 de hasta 90.02% lo que indica que hasta ese valor se explica el modelo; tal como lo indica el estudio de Molina (2020), quien logro una eficiencia del 90% en su modelo, como el estudio Longhini, et al. (2024) quien contribuyo en predecir pérdidas de nitrógeno en sistemas agrícolas, Alcántara (2021) quien en su estudio empleó programación de python.

En cuanto al objetivo específico uno, referente a identificar las variables predictoras clave que influyen en la demanda de fertilizantes agrícolas, se identificó la demande importación de fertilizantes, coincidente con el estudio de Castillo (2022) quien determinó diversos modelos de predicción basándose en registro de datos históricos.

Así mismo, el objetivo específico dos construir y validar el modelo de regresión utilizando datos históricos de ventas y variables relacionadas con la producción agrícola, el dato fue validado con tres tipos de fertilizantes, así como el estudio de Castillo (2022) quien involucró la definición de variables operativas, en base a la recopilación de reportes.

5.2 Conclusiones

- Se concluye que, al desarrollar un modelo de regresión para predecir la demanda de fertilizantes destinados a la agricultura, con el fin de optimizar la planificación y gestión de recursos en este sector se logró un R^2 de hasta 90.02% lo que indica que hasta ese valor se explica el modelo.
- Así mismo al identificar las variables predictoras clave que influyen en la demanda de fertilizantes agrícolas, se identificó la demanda importación de fertilizantes, como: urea, sulfato de amonio, cloruro de potasio, sulfato de magnesio y potasio, nitrato de amonio, fosfato de amonio y sulfato de potasio..
- Así mismo, el objetivo específico dos construir y validar el modelo de regresión utilizando datos históricos de ventas y variables relacionadas con la producción agrícola, el dato fue validado con tres tipos de fertilizantes, entre los que destaca el nitrato de amonio con un $R^2=0.9001973378095771$.

5.3 Recomendaciones

Se recomienda realizar estudios predictivos comparativos con redes neuronales artificiales, series de tiempo, entre otros aplicando estas herramientas a la ingeniería metalúrgica,

CAPÍTULO VI

Referencias

- Alcántara Santillán, B. O., Morales Tisnado, L., & Sierra Sanabria, J. (2021). *Predicción de demanda de GLP para el parque automotor peruano para el segundo semestre del año 2021*. Trabajo de investigación, Universidad Peruana de Ciencias Aplicadas. <http://hdl.handle.net/10757/659110>
- Ascencio Beltran, L. S. (2022). *Diseño de un modelo predictivo de aprendizaje automático supervisado para determinar precios dinámicos de insumos agrícolas de la región costa del ecuador*. Tesis. Tesis, Universidad de Guayaquil. <https://repositorio.ug.edu.ec/server/api/core/bitstreams/e64d84dc-447f-4c58-a2fc-78b9c2d0bfc8/content>
- Barco Javier, C. D., Guerrero Rosillo, S. B., Romero Ahumada, T. F., & Tello Castañeda, C. C. (2024). *Modelo Prolab: Humus de lombriz potenciado con nutrientes orgánicos de nitrógeno-potasio-fósforo (NPK) en presentación grow cubes, una propuesta sostenible para mejorar la calidad de los cultivos*. Tesis, Pontificia UNiversidad Católica del Perú. <http://hdl.handle.net/20.500.12404/27048>
- Big Data Marketer. (enero de 2024). *¿Qué es el Análisis Predictivo?* <https://www.bigdata-social.com/que-es-el-analisis-predictivo/>
- Biología del Sr. Paul. (22 de 5 de 2012). *Diccionario de fundamentos de química II*. <https://biologiadonpaul.blogspot.com/2012/05/diccionario-de-fundamentos-de-quimica.html>
- Castellanos Serrano, L. T., Gómez Aguila, M. V., C, Castellanos Suárez, J. A., & Pérez Vivar, M. A. . (2024). Optimización de sistemas de soporte de decisiones en agricultura mediante IA: un enfoque integrado: Optimization of decision support systems in agricutura mediante IA: un enfoque integrado:Optimization of decision support

- systems in agriculture using AI. *E-CUCBA*, (21), 21, 150–155.
<https://doi.org/https://doi.org/10.32870/e-cucba.vi21.333>
- Castillo, O. (2022). *Desarrollo de modelos predictivos de regresión en la industria minera mediante el uso de algoritmo de machine learning*. Repositorio institucional Cybertesis UNMSM. 8. Tesis de pregrado, Universidad Nacional Mayor de San Marcos.
<https://doi.org/https://hdl.handle.net/20.500.12672/1845>
- Chang Hidalgo, H. M. (2023). *Comparación de técnicas de estimación basadas en machine learning para predecir costos en los planes de adquisiciones de las entidades públicas del Perú*. Tesis, Universidad Señor de Sipán.
<https://doi.org/https://hdl.handle.net/20.500.12802/10566>
- DataScientest. (marzo de 2024). *Scikit-Learn : Descubre la biblioteca de Python dedicada al Machine Learning*. <https://datascientest.com/es/scikit-learn-decubre-la-biblioteca-python>
- Fosfato diamónico. (22 de 11 de 2023). *Wikipedia*.
https://es.wikipedia.org/w/index.php?title=Fosfato_diam%C3%B3nico&oldid=153486183
- García, G., & Navarro García, S. (2014). *Fertilizantes: química y acción*. Ediciones Paraninfo, SA.
- industriales, D. d. (12 de 12 de 2023). *Distribuidora de químicos industriales*.
<https://www.dqisa.com/wp-content/uploads/2020/12/UREA-TECNICA.pdf>
- Krumag, P., Wells, R., & Graddy, K. (2013). *Fundamentos de Economía* (13 ava ed.). (E. Reverté, Ed.) <https://cbceconomia.files.wordpress.com/2017/09/krugman-2013-fundamentos-de-economc3ada.pdf>
- Levin, R., & Rubin, D. (2004). *Estadística para administración y economía* (7ma ed.). México: Editorial Pearson Educación.

- Longhini, V. Z., Ítavo, L. C. V., Gurgel, A. L. C., Cardoso, A. da S., Boddey, R. M., Difante, G. dos S., Dias, A. M., Ítavo, C. C. B. F., Silva, G. de S. L., & Ruggieri, A. C.. (2024). Mathematical models for adjustments in the quantification of ammonia volatilization from urea fertilizer applied on tropical pastures. *Ciência Rural*, 54(5). <https://doi.org/https://doi.org/10.1590/0103-8478cr20230230>
- Madrid, E. (2008). Los insumos invisibles de decisión: datos, información y conocimiento. *In Anales de documentación*, 11, 183-196.
- Martínez, A. (2014). *Planificación y gestión de la demanda* (5.0 ed.). España: EDITORIAL ELEARNING S.L.
- Menoyo Ros, D., García López, E., & García Cabot, A. (2021). *Fundamentos de la ciencia de datos*. Alcalá de Henares, España: Editorial Universidad de Alcalá. <https://elibro.net/es/ereader/bibsipan/177631?page=177>.
- Molina Rea, K. (2020). *Implementación de un modelo analítico para la predicción en la venta del portafolio de productos OTC de un laboratorio Farmacéutico*. Trabajo de Fin de Estudios , Universidad de las Fuerzas Armadas ESPE. <http://repositorio.espe.edu.ec/handle/21000/22561>.
- Navarro Garcia, G. (2023). *Fertilizantes. Química y acción* (2da ed.). Ediciones MundiPrensa. <https://books.google.com.pe/books?id=1yjFEAAAQBAJ&lpg=PR7&ots=c7N98zW MF6&dq=procesos%20quimicos%20fertilizantes&lr&hl=es&pg=PA48#v=onepage&q=procesos%20quimicos%20fertilizantes&f=false>
- Palomino, C. T. (2021). *Aplicación de técnicas de análisis de regresión y aprendizaje automático para la estimación de sobre dilución en el método de sub level Stopping - Compañía minera condestable*. Lima: Universidad Peruana de Ciencias Aplicadas.
- Penadillo Palomino, C. T. (2021). *Aplicación de técnicas de análisis de regresión y aprendizaje automático para la estimación de sobre dilución en el método de Sub Level Stopping -*

- Compañía Minera Condestable* . Tesis de Ingeniera de Gestión Minera, UNIVERSIDAD PERUANA DE CIENCIAS APLICADAS, Lima.
https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/655994/Penadillo_PC.pdf?sequence=3&isAllowed=y
- Quimica.es. (12 de 12 de 2023). *Química.es/Nitrato de amonio*.
https://www.quimica.es/enciclopedia/Nitrato_de_amonio.html
- Rayon, A. (25 de abril de 2017). *Deusto Data*. <https://blogs.deusto.es/bigdata/guia-para-comenzar-con-algoritmos-demachine-learning/>
- REDACCIÓN ESPAÑA. (2020). *Qué es un modelo predictivo y cómo se aplica al negocio*.
<https://agenciab12.com/noticia/que-es-modelo-predictivo-como-aplica-negocio>
- Spagnolo, R. T., Rosa, D. P., Pinho, M. d., Schiavon, C. S., & Schmechel, D. (2021). Models for predicting the performance of fertilizer metering in seed cum fertilizer drill. *Revista Brasileira de Engenharia Agrícola e Ambiental Campina Grande, PB*, 25(1), 51-57.
- Sulfato de Amonio. (23 de 11 de 2023). *En Wikipedia*.
https://es.wikipedia.org/w/index.php?title=Sulfato_de_amonio&oldid=154155166
- Vargas, R., Mosavi, A., & Ruiz, R. (2017). Deep learning: A review.
- YFC. (15 de 01 de 2024). *FERTILIZANTES: Sulfatos de potasio y magnesio*.
<https://www.ypf.com/productosyservicios/Paginas/Sulfato-de-potasio-y-magnesio.aspx>

ANEXO 01: Matriz de consistencia

DESARROLLO DE UN MODELO PREDICTIVO PARA ESTIMAR LA IMPORTACION DE FERTILIZANTES QUIMICOS EN EL PERU

PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES	METODOLOGÍA
¿Cómo se puede desarrollar un modelo de regresión efectivo para anticipar la demanda de fertilizantes agrícolas y mejorar la planificación y gestión de recursos en el sector agrario?	Desarrollar un modelo de regresión para predecir la demanda de fertilizantes destinados a la agricultura, con el fin de optimizar la planificación y gestión de recursos en este sector.	Al desarrollar un modelo de regresión para predecir la demanda de fertilizantes agrícolas, se logrará optimizar la planificación y gestión de recursos en el sector agrícola.	Modelo de regresión	Se utilizaron registros de importación de fertilizantes en Perú de la base de datos del INEI, periodo 1998 al 2021. Evaluación. Modelo predictivo
PROBLEMAS ESPECÍFICOS	OBJETIVOS ESPECÍFICOS	HIPÓTESIS ESPECÍFICAS		
¿Cuáles son las variables predictoras fundamentales que ejercen influencia significativa sobre la demanda de fertilizantes destinados a la agricultura?	Identificar las variables predictoras clave que influyen en la demanda de fertilizantes agrícolas	Al identificar las variables predictoras clave que influyen en la demanda de fertilizantes agrícolas, será posible comprender mejor los factores determinantes de dicha demanda.	Demanda de fertilizantes	
¿Cómo es la distribución ¿Cómo se puede construir y validar un modelo de regresión utilizando datos previos de ventas y otras variables asociadas a la producción agrícola para predecir de manera efectiva la demanda de fertilizantes agrícolas?	Construir y validar el modelo de regresión utilizando datos históricos de ventas y variables relacionadas con la producción agrícola.	Al construir y validar un modelo de regresión utilizando datos históricos de ventas y variables relacionadas con la producción agrícola, se logrará desarrollar un modelo predictivo preciso y confiable para predecir la demanda de fertilizantes agrícolas		