

Modelo de regresión basado en máquinas de aprendizaje utilizando datos estadísticos del café Colombiano

Regression model based on machine learning using Colombian coffee statistical data.

Recibido: 8 de junio de 2022

Aprobado: 19 de noviembre de 2022

Forma de citar: F. A. Fernández-Gelvez, L. Jaimes-Cerveleón, L.E. Mendoza, “Modelo de regresión basado en máquinas de aprendizaje utilizando datos estadísticos del café Colombiano”, Mundo Fesc, vol. 13, no. S1, pp. 258-272, 2023. <https://doi.org/10.61799/2216-0388.1499>

Fredy Alonso Fernández-Gelvez*



Ingeniero Industrial
Fredy.fernandez@unipamplona.edu.co
Universidad de Pamplona
Pamplona, Colombia

Leonor Jaimes Cerveleón



Magister en Administración de Empresas e Innovación
Leonor.cerveleon@unipamplona.edu.co
Universidad de Pamplona
Pamplona, Colombia

Luis Enrique Mendoza



Magister en Ingeniería Biomédica
Luis.mendoza@unipamplona.edu.co
Universidad de Pamplona
Pamplona, Colombia

***Autor para correspondencia:**

Leonor.cerveleon@unipamplona.edu.co



Modelo de regresión basado en máquinas de aprendizaje utilizando datos estadísticos del café Colombiano

Resumen

La inteligencia artificial está teniendo un impacto positivo en el mundo gracias a su capacidad para resolver problemas de la vida real. En este contexto, se está llevando a cabo un proyecto investigativo que propone el uso de técnicas de inteligencia artificial para predecir la demanda de producción y exportación de café colombiano. Para estimar una predicción futura a partir de datos históricos, se emplearán dos técnicas de aprendizaje automático: máquinas de soporte vectorial y la red neuronal recurrente (RNN) tipo Long Short Term Memory (LSTM), ambas aplicadas para predicciones con el método de regresión. En este proyecto, se utilizaron los datos de 107 registros mensuales entre 2014 y 2022 para predecir la demanda de producción y exportación de café. Se identificaron 17 variables que afectan las exportaciones de café y 12 variables que afectan la producción. Estas variables se incluyen en un archivo CSV que contiene 107 registros. Durante el entrenamiento, el 70% de los datos se usará para que el modelo predictivo aprenda, mientras que el 30% restante se utilizará para visualizar el rendimiento del modelo predictivo.

Palabras clave: Demanda, Exportación, Predicción, Producción, Rendimiento, Variables.

Regression model based on machine learning using Colombian coffee statistical data.

Abstract

Artificial intelligence is having a positive impact on the world thanks to its ability to solve real-life problems. In this context, a research project is being carried out that proposes the use of artificial intelligence techniques to predict the demand for production and export of Colombian coffee. To estimate a future prediction from historical data, two machine learning techniques will be used: support vector machines and the Long Short-Term Memory (LSTM) type recurrent neural network (RNN), both applied for predictions with the regression method. In this project, data from 107 monthly records between 2014 and 2022 will be used to predict the demand for coffee production and export. 17 variables that affect coffee exports and 12 variables that affect production are identified. These variables are included in a CSV file containing 107 records. During training, 70% of the data will be used for the predictive model to learn, while the remaining 30% will be used to visualize the performance of the predictive model.

Keywords: Demand, Export, Prediction, Production, Performance, Variables

Introducción

La inteligencia artificial (IA) ha revolucionado en forma en que las máquinas interactúan con el mundo, siendo así que estas puedan emular el comportamiento en el que el ser humano aprende, esto lo hace a través del aprendizaje de grandes cantidades de datos y algoritmos. Las redes neuronales artificiales (RNA) son un ejemplo de esto, inspiradas en las redes neuronales biológicas, son capaces de resolver problemas de manera eficiente. En el contexto de la producción y exportación de café en Colombia, se han enfrentado diversos desafíos que han impactado negativamente la economía del país y la calidad de vida de los caficultores, pues los caficultores colombianos han enfrentado diversos problemas en la producción y productividad de café en los últimos años. La producción y exportación de café se ven afectadas por cambios climáticos, mal manejo de cafetales, alta volatilidad de precios internacionales, tasa de cambio, mala gestión estatal, bloqueos en las vías y altos costos de producción. La producción de café en Colombia en 2021 fue de 12,6 millones de sacos de 60 kilos, una disminución del 9% en comparación con el año anterior, y las exportaciones disminuyeron en un 1% [1]. La caída en la producción se debe principalmente al fenómeno de La Niña y al alto costo de los fertilizantes importados. Además, los bloqueos por el paro nacional en abril de 2021 también afectaron la producción y exportación de café [2]. En el calendario cafetero de octubre de 2021 a julio de 2022, la producción de café en Colombia disminuyó cerca de 9,9 millones de sacos, un 12% menos que el año anterior [3,12,13]. Las exportaciones de julio de 2022 también tuvieron una fuerte caída del 14%, a un millón de sacos de 60 kg de café verde, en comparación con los casi 1,2 millones exportados en julio de 2021 [4,14]. Los problemas en la producción de café también afectan la calidad de vida de los caficultores y sus familias, especialmente aquellos que tienen un acceso limitado a la educación y la información. Estos factores pueden resultar en una gestión inadecuada de los cultivos y baja productividad, lo que lleva a los caficultores a ceder la producción de café a grandes empresas con mejor capacidad de negociación y herramientas de producción. Dado este contexto, surge la pregunta de investigación: ¿Cómo se pueden implementar mejoras en la producción y exportación de café en Colombia a través de un modelo de predicción de la demanda basado en técnicas de inteligencia artificial?

Materiales y métodos

Inteligencia artificial.

Según [5], es la combinación de algoritmos que le permiten a una máquina tener cierta relación con la inteligencia humana, pues ella tiene la capacidad de emular el comportamiento de los humanos mediante una gran cantidad de datos y algoritmos que son entrenados para su aprendizaje, se dice que esta rama no está definida completamente pero que se tiene varios enfoques en los que la inteligencia artificial

tiene sistemas capaces en un gran porcentaje de pensar y actuar como una persona. Tiene también la capacidad de aprender, crear y planear. Otro enfoque está dado en que sus sistemas son capaces de pensar racionalmente buscando como llegar a percibir el comportamiento humano y también tratan de emular las actuaciones de un ser humano y algunas actividades repetitivas que se hacen en el diario vivir.

Máquina de vectores de soporte (SVM).

Es un algoritmo de clasificación, usada también para aprendizaje estadístico desde sus inicios, esta herramienta es muy usada para resolver problemas de clasificaciones binarias y en la actualidad resuelve problemas como; visión artificial, reconocimiento de caracteres, caracterización de texto o hipertexto y uno muy importante como series temporales. Encaminada por el tipo de clasificación lineal o separadores lineales también llamados hiperplanos, en la cual el hiperplano a través de un vector que divide al plano en dos, los datos son clasificados según su categoría y separados en cada lado del plano según su categoría [6]. Las máquinas de soporte vectorial no solo resuelven problemas de clasificación, sino que también abarca en gran parte problemas de regresión (SVR) utilizando los mismo componentes y principios de SVM para problemas de clasificación, con algunas diferencias muy mínimas. Debido a que en primera instancia, se da la salida de un número real, resulta muy difícil predecir la información que hay disponible, lo que tiene infinitas posibilidades. En el caso de regresión, se estable parámetros para el margen de tolerancia ε (épsilon) y el algoritmo suele ser más complicado; sin embargo, el objetivo principal siempre será el mismo: minimizar el error, individualizado el hiperplano que maximiza el margen, teniendo en cuenta la tolerancia de error [7]. Una de las características más importante de las máquinas de soporte vectorial es que puede resolver problemas lineales y no lineales. Como podemos ver a continuación. Dados los conjuntos de datos $s = \{(x_1, y_1), \dots, (x_n, y_n)\}$, donde $x_i \in \mathbb{R}^d$ y $y_i \in \mathbb{R}$, nuestro objetivo en Support Vector Regresión (SVR) es encontrar los parámetros $w = w_1, \dots, w_d$ que definen un hiperplano de regression $f(x) = (w_1 x_1 + \dots + w_d x_d) + b$.

Se introduce la función de pérdida ε -insensible, $L_\varepsilon(x)$ que permite cierta flexibilidad en la función solución al permitir un margen de error. Las variables de holgura cuantifican el error de predicción permitido para cada ejemplo de entrenamiento.

El problema de optimización busca minimizar la suma de las funciones de pérdida asociadas, considerando las variables de holgura y una penalización (C). La formulación del problema dual involucra multiplicadores de Lagrange (α^+ , α^- , β^+ , β^-) [8,16,17,18]. La solución óptima para la regresión es expresada como una combinación lineal ponderada de funciones kernel aplicadas a los ejemplos de entrenamiento y algunos entre ellos tenemos las ecuaciones (1), (2), (3) y (4):

Kernel Lineal:

$$K(x, x_i) = x^T \cdot x_i \quad (1)$$

Kernel Polinómico:

$$k(x, x_i) = (x^T \cdot x_i + c)^d \quad (2)$$

Donde c es una constante y d es el grado del polinomio.

Kernel Radial (RBF):

$$k(x, x_i) = \exp \left(-\frac{\|x - x_i\|^2}{2\sigma^2} \right) \quad (3)$$

Donde σ es un parámetro que controla la anchura de la función.

Kernel Sigmoidal:

$$k(x, x_i) = \tanh(\alpha x^T \cdot x_i + c) \quad (4)$$

Donde α y $c > 0$ son parámetros.

La kernelización de las SVR se logra mediante la introducción de funciones kernel para manejar casos donde se tengan datos que no pueden ajustarse linealmente. Los parámetros c y ϵ afectan la complejidad del modelo, y su elección debe considerar la presencia de ruido en los datos.

Long Short-Term Memory (LSTM). Es de las redes neuronales recurrentes, básicamente hacen parte del aprendizaje profundo y tiene un amplio campo de memoria el cual les permite aprender con información del pasado, las Long Short Term Memory (LSTM) le permiten red neuronal recurrentes (RNN) recordar las entradas durante cierto tiempo además permite leer, borrar y escribir. Siendo especialmente eficaz en tareas como la regresión y predicción de series temporales cuando se trabaja con datos numéricos [9].

Estructura Básica de LSTM. Una unidad LSTM consta de varios componentes clave:

Celda de Memoria (CT): Mantiene la memoria a largo plazo de la red, permitiendo recordar información importante a lo largo del tiempo.

Puerta de Entrada (iT): Decide qué información nueva se debe almacenar en la celda de memoria.

Puerta de Olvido (fT): Determina qué información existente en la celda de memoria se

debe descartar.

Puerta de Salida (oT): Controla qué información en la celda de memoria se debe emitir como salida.

La salida de una unidad LSTM se calcula mediante las ecuaciones (5)-(10):

$$it = \sigma(w_{ii} \cdot xt + b_{ii} + W_{hi} \cdot ht-1 + b_{hi}) \quad (5)$$

$$ft = \sigma(w_{if} \cdot xt + b_{if} + W_{hf} \cdot ht-1 + b_{hf}) \quad (6)$$

$$ot = \sigma(w_{io} \cdot xt + b_{io} + W_{ho} \cdot ht-1 + b_{ho}) \quad (7)$$

$$gt = \tanh(W_{ig} \cdot xt + b_{ig} + W_{hg} \cdot ht-1 + b_{hg}) \quad (8)$$

$$ct = ft \cdot ct-1 + it \cdot gt \quad (9)$$

$$ht = ot \cdot \tanh(ct) \quad (10)$$

Donde:

- xt es la entrada en el tiempo t
- ht es la salida en el tiempo t
- W_{ii} , w_{fi} , w_{i0} , w_{ig} y w_{hf} , w_{hf} , w_{h0} , w_{hg} . son los pesos de la red.
- b_{ii} , b_{if} , b_{io} , b_{ig} y b_{hi} , b_{hf} , b_{ho} , b_{hg} son los sesgos.
- σ es la función sigmoide.
- $\tanh$ es la función tangente hiperbólica.

Tipos de Activación:

Las funciones de activación son esenciales en las unidades LSTM. Algunas funciones comunes incluyen:

Sigmoide (σ): Se utiliza para producir salidas binarias (0 o 1) y para regular las puertas de entrada, olvido y salida. **Tangente Hiperbólica ($\tanh$):** Se utiliza para regular la actualización de la celda de memoria. La función de activación lineal se usa a veces en la capa de salida de las unidades LSTM cuando se desea obtener una salida lineal sin transformaciones no lineales adicionales. Esta función de activación es menos frecuente en las capas internas porque las redes neuronales recurrentes, como LSTM, se benefician de su habilidad para aprender representaciones no lineales complejas. No obstante, en algunos casos específicos, como la regresión simple, la función de activación lineal puede ser conveniente.

Predicción de la demanda: Según [10-11], la acción de predecir hace referencia a la anticipación de un fenómeno o evento que pueda ocurrir en un determinado tiempo. En estadística la predicción es un anuncio anticipado de lo que se espera que pueda

suceder en el futuro que se prevé para una variable, ya sea cualitativa o cuantitativa. Además, cabe resaltar que la predicción se basa en evidencias como intuición, es decir que no es necesario que sea objetiva. Este tema de predecir a tomando importancia en los últimos años pues a partir de ellas ya muchas empresas han logrado buenos resultados ya sean en ventas o visiones más generales en cuanto a la demanda de artículos o productos y es ahí donde la inteligencia artificial juega un papel importante brindando diferentes herramientas o técnicas como Machine Learning y Deep Learning y también la minería de datos que aportan soluciones de alguna manera más rápida y más precisa reduciendo en si el error humano, es así como la inteligencia artificial se convertido en una herramienta de gran apoyo para las empresas a nivel global (figura 1).




Figura 1. Diagrama de bloques y fases de la metodología

Resultados y discusión

Predecir la demanda de producción y exportación suele ser desafiante y a la vez interesante para la aplicación y obtención de nuevos conocimientos. Son múltiples los factores que afecta tanto el proceso productivo de café como también los procesos de exportación del mismo, problemas del cambio climático y las altas volatilidades de los precios internaciones y también las decisiones gubernamentales hacen que este producto se vea afectado y que a su vez afecte a comerciantes productores y los grandes empresarios involucrados en este rol. A continuación, se presentan las variables encontradas y que afectan dichos procesos, estas variables son tenidas encuesta después de una intensa búsqueda bibliográfica en todos los repositorios académicos y también de la federación nacional de cafeteros, páginas del gobierno y noticias importantes, en la tabla 1 y 2 mencionaré aquellas variables que van hacer las variables de entrada de manera historia, pues Colombia produce café en distintas regiones del país y de los 32 departamentos 23 según la federación nacional de cafeteros produce café en pequeñas y grandes cantidades.

Conjunto de datos para modelo de exportación de café periodo (2014-2022):

1. Volumen de producción
2. Valor de exportaciones
3. Precio internacional del café KC

4. Nivel precipitaciones.
5. Índice de precio al consumidor (IPC-EU)
6. Exportaciones
7. Tasa de cambio
8. Tasa de desempleo
9. Producto bruto interno (PBI)
10. Exportación de Brasil
11. Exportaciones de vietnam
12. Indicador compuesto ICO
13. Arábicas Colombianos
14. Inflación

Para abordar estos problemas, se propone la implementación de un modelo de predicción de la demanda basado en técnicas de inteligencia artificial, el cual podría servir a los caficultores y grandes empresarios a generar buenos beneficios a partir de ella. En este contexto, el presente trabajo se enfocará en identificar las variables que afectan la productividad del café y las exportaciones en Colombia además, explorar las diferentes técnicas de inteligencia artificial aplicadas a modelos predictivos, en particular, las redes neuronales de aprendizaje profundo, incluyendo las Redes Neuronales Recurrentes (RNR) como las LSTM (Long Short-Term Memory), así como el aprendizaje supervisado, que entre sus variantes se encuentra el enfoque de Máquinas de Soporte Vectorial (MVS) aplicado de ella el Support Vector Regression (SVR) para construir un modelo que permita predecir la demanda de producción y exportación de café con mayor precisión [19, 20, 21]. Durante este proceso, se han encontrado diferentes tendencias en cada una de las variables estudiadas, como tendencias ascendente en la producción y exportación de café, también tendencias cíclicas ya que en ciertos periodos de tiempo se presentan tendencia de crecimiento y en otros hay declives, esto principalmente se debe a las variables que lo afecta como las variables climáticas, las regulaciones internacionales respecto al consumo de café, los diferentes precios en el mercado, la competencia y la calidad del café, estas variables han permitido comprender de manera más precisa cómo influyen en la producción y exportación de café en el país. Posteriormente se hace un análisis correlacional donde variables correlación fuerte mayores a 0.8 son excluidas del conjunto de datos y se dejan aquellas variables que entre si posee una correlación débil para efectividad del modelo como podemos ver en la figura. Cabe resaltar que se está trabajando con una única variable de salida por lo tanto la correlación se hace entre variables y luego entre las variables predictoras y la variable objetivo (figura 2).




Figura 2. Correlación entre variables y variable objetivo

Desarrollo de los modelos.

Los modelos predictivos desarrollados se llevaron a cabo en dos técnicas las cuales se inicia con un proceso de importación de librerías necesarias para cada modelo en especial sklearn y librerías para gráficas y manipulación de datos como; Matplotlib, Pandas, Numpy. las dos técnicas empleadas son: redes neuronales recurrentes (RNR) usando LSTM y máquinas de soporte vectorial (SVM) con el método de regresión (SVR) ambos modelos se aplicaron para la predicción demanda de producción como de exportación de café, definiendo en primer instante las variables que contienen tanto la variable objetivo y las variables predictoras como podemos ver en las figuras 3 y 4 [22, 23, 24, 25].

```
# X es el conjunto de características (variables independientes)
X = data.iloc[:, :-1]

# y es la variable objetivo (variable dependiente)
y = data.iloc[:, -1:]
```

Figura 3. Definición de variables para modelo RNR LSTM

```

#we separate the data in the variable X, this contains all the variables that affect the export of coffee
X = ModeSvm[['inflation(%)', 'USD/PC01', 'Colombian Milds', 'robust', 'colombian coffee production',
            'nominal export value', 'ValorPrecipitacion',
            'IPC_EEUUcatCafe(%)', 'Expo_OtrosPaises', 'Exp_M_Vietnam',
            'Exp_M_brasil', 'PIB', 'Tasa_Deseempleo (%)', 'ConsumoExterno', 'Mes_1',
            'Mes_2', 'Mes_3', 'Mes_4', 'Mes_5', 'Mes_6', 'Mes_7', 'Mes_8', 'Mes_9',
            'Mes_10', 'Mes_11', 'Mes_12']]
# Nuestra variable objetivo
Y = ModeSvm['canExportacion']

```

Figura 4. Definición de variables para modelo SVR

Luego dividiendo el conjunto de datos en un 70% para entrenamientos del modelo y el 30% restantes para pruebas como se puede ver las figuras 5 y 6.

```

# Dividimos los datos en 2/3 del tiempo para entrenamiento y 1/3 para pruebas,
# lo cual resultaría en 6 años para entrenamiento y 3 año para pruebas.
train_month = int(2 * data.shape[0] / 3)

X_train = X_ss[:train_month, :]
X_test = X_ss[train_month:, :]
y_train = y_mm[:train_month, :]
y_test = y_mm[train_month:, :]

# Convertir a tensores y variables
X_train_tensors = Variable(torch.Tensor(X_train))
X_test_tensors = Variable(torch.Tensor(X_test))

y_train_tensors = Variable(torch.Tensor(y_train))
y_test_tensors = Variable(torch.Tensor(y_test))

```

Figura 5. División de datos para entrenamiento y pruebas con red LSTM

```

# división de datos el 30% para pruebas y el 70% para entrenamientos
X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size=0.30, random_state=35)

# Normalizacion de datos
scaler = StandardScaler()
X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

# Selección de características
selector = SelectKBest(f_regression, k='all')
X_train = selector.fit_transform(X_train, Y_train)
X_test = selector.transform(X_test)

```

Figura 6. División de datos para entrenamiento y pruebas con SVR

Posteriormente se entrenamiento los modelos con el 70% de los datos y el 30% restante se deja para pruebas o validación, donde en la red neuronal recurrente brinda un mejor rendimiento para el modelo de predicción de la demanda de producción de café y máquinas de soporte vectorial para la exportación de café.

En la técnica de Long Short-Term Memory (LSTM) donde el modelo arroja una salida en las métricas de desempeño como: El RMSE de prueba=103.652, El MAE de prueba=52.203,

El R^2 de prueba= 0.756. Estos resultados indican que la diferencia entre los datos reales y predichos son en promedio de 103.652, y que la magnitud de error en promedio de los datos es de 52.203 y el ajuste del modelo es de 0.756 es decir un 75,6% de rendimiento el cual me indica que es un buen ajuste y que tiene capacidad de trabajar con datos no vistos bajo supervisión. En la figura 7 se muestra el rendimiento de este modelo que fue más efectivo para predecir la demanda de producción de café.




Figura 7. Rendimiento del modelo de RNR con LSTM.

En la figura 7 se muestra el rendimiento para el modelo de predicción de la demanda de producción de café y además, se puede ver una línea vertical que divide el gráfico, las curvas azules representan el entrenamiento del modelo en un antes y un después donde después las curvas naranjas representan los datos reales del modelo en comparación con los datos predichos, lo cual se puede decir que predice bastante bien los primeros 2 años y que a partir del 3 año el modelo comienza a tener bastante deficiencia, en la gráfica también podemos ver que hay solo número en el eje de las X las cuales representan los meses desde el 2014 hasta el final del 2022, es decir que la validación parte del año 2020 y un mes aproximadamente.

Por otro lado, el modelo de la demanda de exportación de café el que mejor rindió fue Máquinas de Soporte Vectorial (MVS) con el método de Regresión de Vectores de Soporte (SVR), en la evaluación del modelo, se observaron diferencias en las métricas entre el conjunto de entrenamiento y el conjunto de prueba. Durante el entrenamiento, el error absoluto medio fue de 29.85, indicando la magnitud promedio de las desviaciones entre las predicciones y los valores reales. El error cuadrático medio se situó en 2297.44, mostrando la dispersión de los errores al cuadrado. La raíz del error cuadrático medio resultó en 47.93, representando la desviación promedio entre las predicciones y los valores reales. En cuanto al coeficiente de determinación (R^2), se obtuvo un valor de 0.9 en el conjunto de entrenamiento, lo que sugiere que el modelo explica aproximadamente el 90% de la variabilidad presente en los datos de entrenamiento. En el conjunto de prueba, el valor de R^2 fue 0.86, indicando que el modelo tiene una capacidad razonable para capturar las relaciones subyacentes en los datos de prueba y que, además, puede

trabajar con datos no vistos de una manera efectiva. En las figuras 8 y 9 podemos ver cómo se comportan las curvas de este modelo desarrollado.



Figura 8. Modelo de SVR de prueba

En la figura 8 podemos ver el rendimiento de prueba del modelo para la predicción de la demanda de exportación de café colombiano con máquinas de soporte vectorial empujando el método de regresión. Como podemos ver en el eje de las X se muestran solo números el cual me indica en meses predichos comprados en meses de datos reales, como se mencionaba anteriormente los conjuntos de datos tiene registros en meses desde el 2014 hasta el final del 2022 de manera mensual y el 30% de prueba son equivalentes a 32 meses, es decir datos desde el 2020 y 1 mes hasta el final del 2022 son datos para pruebas, observando la figura 8 podemos ver que el modelo predice bastante bien los datos y que se adapta a los patrones apreciados de los datos de entrenamiento y es capaz de predecir a un periodo de 3 años de una manera efectiva. La figura 9 nos muestra ya un panorama más efectivo de lo que fue el modelo en la parte de entrenamiento y pruebas.




Figura 9. Modelo final con SVR

Conclusiones

- Con respecto a los resultados, se pudo concluir que el modelo de (SVR) ha logrado demostrar desempeño importante en la predicción de la demanda de exportación de café en el contexto evaluado. En la fase de entrenamiento, el modelo logró reducir el error absoluto medio a 29.85, lo que significa que en promedio las predicciones estuvieron desviadas por este valor con respecto a los valores reales. Además, el error cuadrático medio de 2297.44 indicó que los errores se dispersaron en valores cuadráticos en comparación con los valores reales.
- Los resultados del modelo de Predicción de Demanda de Producción utilizando la arquitectura LSTM son alentadores y sugieren su eficacia en la estimación de la demanda futura. El RMSE de prueba de 103.652 indica que las predicciones tienden a tener un error medio de alrededor de 103 unidades en relación con los valores reales. El MAE de prueba de 52.203 revela que la magnitud promedio de las desviaciones entre las predicciones y los valores reales es de aproximadamente 52 unidades. El R2 de prueba de 0.756 señala que el modelo es capaz de explicar alrededor del 75.6% de la variabilidad observada en los datos de prueba.
- Los modelos de predicción desarrollados son útiles para predecir la demanda de producción como de exportación de café colombiano en función de las variables que lo afectan, aunque es importante tener en cuenta que los resultados pueden estar sujetos a cierta incertidumbre y variabilidad. Es recomendable seguir monitoreando los datos y ajustando el modelo a medida que haya más información disponible para mejorar su precisión.

Referencias

- [1] Portafolio, "La producción de café en Colombia cayó a julio de 2022", 2022. [En línea]. Disponible en: <https://www.portafolio.co/economia/finanzas/la-produccion-de-cafe-en-colombia-cayo-a-julio-de-2022-569080>
- [2] G. González, "Bloqueos y clima disminuyeron en 9% la producción de café en Colombia," 2021. [En línea]. Disponible en: <https://www.redagricola.com/co/clima-y-bloqueos-disminuyeron-en-9-la-produccion-de-cafe-en-colombia/>
- [3] Iberdrola, "¿Qué es la Inteligencia Artificial?," 2022. [En línea]. Disponible en: <https://www.iberdrola.com/innovacion/que-es-inteligencia-artificial>
- [4] A. Rico, "En julio 2022 la producción de café disminuyó 22%, quedó en 944.000 sacos de 60 kg," Agronegocios, 2022. [En línea]. Disponible en: <https://www.agronegocios.co/agricultura/en-julio-2022-la-produccion-de-cafe-cayo-22-queda-en-944-000-sacos-de-60-kg-3416913>

- [5] D. Stacey, "Paro y clima, entre las razones para la caída de 9% en la producción de café en 2021", 2022. [En línea]. Disponible en: <https://www.agronegocios.co/agricultura/paro-y-clima-entre-las-razones-para-la-caida-de-9-en-la-produccion-de-cafe-en-2021-3285221>
- [6] R. Hernández, C. Fernández, and P. Baptista, "Metodología de la investigación," McGraw Hill, 2014. [En línea]. Disponible en: https://www.academia.edu/32697156/Hern%C3%A1ndez_R_2014_Metodologia_de_la_Investigacion
- [7] J. M. Guareño, and E. C. Bravo, "Support Vector Regression: Propiedades y Aplicaciones," Trabajo Fin De Grado, Universidad de Sevilla, 2016.
- [8] E. C. León, "Introducción a las máquinas de vector soporte (SVM) en aprendizaje supervisado", 2016.
- [9] A.I. Torres, "Redes neuronales recurrentes", sf. [En línea]. Disponible en: <https://torres.ai/redes-neuronales-recurrentes/>
- [10] E. Carmona, "Tutorial sobre máquinas de vectores soporte (SVM)," 2016. [En línea]. Disponible en: https://www.cartagena99.com/recursos/alumnos/apuntes/Tema8_Maquinas_de_Vectores_Soporte.p. 2016.
- [11] G. Westreicher, "Predicción (estadística) - qué es, definición y concepto," Economipedia, 2020. [En línea]. Disponible en: <https://economipedia.com/definiciones/prediccion-estadistica.html>. 2020.
- [12] J. C. M. Rendón, C. F. A. Villalobos, and F. A. R. Ledesma, "Mirada a los aspectos económicos, financieros, sociales y ambientales del cultivo del café en Colombia-2022", *Documentos de Trabajo ECACEN*, no. 1, pp. 144-161, 2023.
- [13] F. A. Salazar Gallego, "Café de Colombia, análisis de los Principales Productores de café del mundo," Bachelor's thesis, Escuela de Economía, Administración y Negocios, Facultad de Negocios Internacionales, Universidad Pontificia Bolivariana, Bucaramanga, Colombia, 2021.
- [14] M. C. Yosa, and J. G. Regalado, "Análisis de la competitividad de las exportaciones de café de Ecuador versus Colombia y Brasil hacia el mercado de USA", *X-pedientes Económicos*, vol. 5, no. 12, pp. 65-80, 2021.
- [15] C. R. Rivera Rojo, "Competitividad del café mexicano en el comercio internacional: un análisis comparativo con Brasil, Colombia y Perú (2000-2019)", *Análisis económico*, vol. 37, no. 94, pp. 181-199, 2022.
- [16] Y. T. Tovar, A. F. Calvo, and A. Bejarano, "Desarrollo de un sistema de clasificación de

imágenes digitales para medir la humedad en granos de café", *Información tecnológica*, vol. 33, no. 3, pp. 117-128, 2022.

- [17] A. D. Coppiano Marín, and C. J. Herrera Vargas, "Desarrollo de aplicativo web basado en máquinas de vectores de soporte (SVM) de aprendizaje supervisado para la predicción en la recomendación de cultivos mediante datos ambientales para fincas agroecológicas del cantón La Maná, provincia de Cotopaxi", Bachelor's thesis, Universidad Técnica de Cotopaxi (UTC), Latacunga - Ecuador, 2022.
- [18] Y. Muñoz-Castaño, L. Castillo-Ossa, O. Castrillón-Gomez, F. Buitrago-Carmona, and S. Loaiza Giraldo, "Desarrollo de una aplicación para la predicción de ingredientes y recetas de cocina por medio de TensorFlow y máquinas de soporte vectorial", *Revista Ingenierías Universidad de Medellín*, vol. 19, no. 37, p. 1, 2020.
- [19] C. C. Muñoz Ordóñez, C. A. Cobos Lozada, and J. F. Muñoz Ordóñez, "Predicción del rendimiento de cultivos de café: un mapeo sistemático", *Ingeniería y competitividad*, vol. 25, no. 3, 2023.
- [20] A. Castellano-Corzo, D. Lara-Rodriguez, and E. López-Mélendez, "Comparación de redes neuronales convolucionales (RNC) para la detección de plagas en el cultivo del durazno en departamento Norte de Santander, Colombia", *Informador Técnico*, vol. 87, no. 2, 2023.
- [21] L. A. Rojas Sepúlveda, "Tipificación técnico-económica para los sistemas productivos cafeteros en Colombia," Doctoral dissertation, Universidad Nacional de Colombia, 2023.
- [22] D. I. Baron Jaramillo, "Modelo predictivo de ventas usando aprendizaje automático (Machine Learning) para pronosticar las ventas diarias de una empresa", 2023
- [23] E. A. Hincapié Herrera, "Predicción de la Demanda Usando Modelos de Machine Learning", trabajo de grado, Universidad de Antioquia, Medellín, Colombia, 2021.
- [24] C. C. García Palacios, "Modelo basado en redes neuronales para la predicción de precios de inmuebles Piura-2021", trabajo de grado, Universidad César Vallejo, Perú, 2021
- [25] M. Ramírez Quiceno, and A. Medina Báez, "Aplicación de técnicas de Machine Learning para la predicción del riesgo de default de un cliente en una compañía de Filipinas", trabajo de grado, Universidad de Antioquia, Medellín, Colombia, 2022.