

**Pronóstico de la inflación colombiana: una aproximación desde los modelos**  
*machine learning*

**Jose Fernando Loaiza Zapata**

**Trabajo de Grado**

**Asesores:**

**Liz Jeanneth Londoño Sierra**

**Jaime Andrés Riascos Salas**

**Profesores:**

**Mauricio Andrés Ramírez Gómez**

**Tatiana Isabel Caly Amador**

**Universidad EAFIT**

**Escuela de Finanzas, Economía y Gobierno**

**Medellín**

**2022**

### **Resumen:**

El objetivo de este trabajo es pronosticar la inflación mensual de colombiana a partir de sus determinantes macroeconómicos. Se utilizan **7** modelos de *machine learning*: regresión lineal, SMV, Árboles de Decisión, MLP, KNN, SVR y LSTM, y 1 modelo convencional ARIMA.

Los modelos de mejor pronóstico fueron los ARIMA y el LSTM. Aunque, puede mejorarse la predicción del LSTM haciendo una óptima arquitectura de los datos dado que logra capturar los cambios drásticos de las variables, incluso podría mejorar si se incluye el comportamiento de cada una de las divisiones que componen la canasta básica.

**Palabras clave:** Inflación, pronóstico, *machine learning*, ARIMA

**Clasificación JEL:** E31, C5, C19

## Índice

1.	Planteamiento, formulación y sistematización del problema .....	4
2.	Resultado esperado .....	7
3.	Objetivos .....	7
4.	Justificación .....	8
5.	Marco teórico y antecedentes del problema.....	9
5.1	Modelo ARIMA .....	15
5.2	Modelos machine learning.....	16
5.2.1	Modelo de regresión lineal múltiple .....	16
5.2.2	Regresión lineal con árboles de decisión .....	17
5.2.3	Modelo de Perceptrón Multicapa (MLP).....	18
5.2.4	Modelo de K- vecinos (KNN, del inglés <i>K-nearest neighbours</i> ).....	19
5.2.5	Modelo de vectores de soporte de regresión (SVR) .....	19
5.3	Modelo Long Short-Term Memory (LSTM).....	20
6.	Metodología .....	23
6.1	Descripción de datos.....	23
7.	Resultados .....	26
8.	Conclusiones .....	30
9.	Bibliografía .....	31

## **1. Planteamiento, formulación y sistematización del problema**

La inflación es el aumento generalizado y persistente en los precios de bienes y servicios de un país en un periodo de tiempo determinado. El precio de un producto o un servicio hace referencia al valor relativo que los individuos tienen sobre algún producto de la economía al ser adquirido por medio de la moneda; es decir, es la unidad común de valor que es respaldada de forma legal por el banco central. Los precios están determinados por la oferta y la demanda del mercado, de manera que los movimientos en estas, de forma generalizada en una economía, generan la inflación que impacta la vida de los individuos, hogares, empresas y gobierno (BanRep, 2021).

La inflación es una de las variables macroeconómicas más importantes en los análisis de política económica. Predecirla con la mayor precisión posible es importante para que la autoridad monetaria tome sus decisiones de política de manera eficaz y para que los agentes tengan una menor incertidumbre. Siguiendo a (Tarapuez Chamorro, Rivera , & Donneys , 2010) el incremento acelerado y persistente de los precios en una economía reduce el uso eficiente de los recursos productivos, incrementa la incertidumbre, desincentiva la inversión y genera distorsiones arbitrarias entre el ingreso y la riqueza. Es de anotar que el crecimiento persistente de los precios afecta la rentabilidad de la inversión y el ahorro en el tiempo y, en consecuencia, afecta la producción de bienes y servicios de la economía.

En palabras del exgerente general del Banco de la República (2005-2017), José Darío Uribe:

“La inflación es una enfermedad progresiva y degenerativa creada por el hombre, que reduce el potencial de la economía para crecer y generar empleo productivo. Cuando

los países tienen presiones inflacionarias duraderas el desempleo sube y el crecimiento de la economía se debilita”. (Uribe Escobar, 2007)

Es por ello que la autoridad monetaria debe luchar por controlar la inflación, entre otras razones, porque tener una inflación baja y estable promueve el crecimiento económico y reduce la incertidumbre de los agentes de la economía.

En Colombia, desde el año 2000 la autoridad monetaria tiene por objetivo controlar la inflación y utiliza todos los instrumentos de política monetaria para lograrlo. Sin embargo, no siempre logra mantener la inflación en el rango meta debido a la dificultad de pronosticarla. Especialmente, porque no siempre es claro cuando se debe a un fenómeno temporal o persistente. Disponer de mejores pronósticos de inflación puede ayudar a las autoridades a tomar mejores decisiones monetarias, que los agentes mantengan sus expectativas de inflación ancladas y que se confíe en que la autoridad monetaria es capaz de controlar la inflación.

Existen diversas investigaciones recientes y significativamente acertadas, de carácter metodológico, que elaboran predicciones de la inflación para economías emergentes, cuyos medios han sido modelos econométricos y de *machine learning* (ML). Al ser economías emergentes comparten características comunes en el control de la inflación, el crecimiento económico y el desarrollo del sistema financiero.

En general, las investigaciones evalúan y comparan modelos convencionales para predecir la inflación; algunos de ellos son: ARIMA (Carmona Restrepo, 2022), SARIMA, MA, AR (Zilberman, Leal, & Molina, 2020), Media, Mediana y VAR (Villarreal Veloz, 2021). Por otra parte, se destacan modelos más desarrollados e innovadores de aprendizaje supervisado, uno de los elementos del *machine learning*, como: *Random Forest*, *Elnet*, *Ridge*, *Lasso* (Ozgun & Ugur, 2021). Estos tienen como propósito observar y calificar cuáles han sido los modelos de mejor predicción y si los modelos *machine learning* superan o igualan a los convencionales.

Para Colombia, como caso de análisis, existen dos trabajos monográficos. El primero se titula “Redes neuronales regularizadas para la predicción de la inflación colombiana” (Cardona Restrepo, 2020). El trabajo estudia y revisa los antecedentes de las variables que explican el comportamiento de la inflación. En él se seleccionan 24 variables de carácter monetario y de producción, de estas solo 7 son seleccionadas para realizar la predicción. Su análisis es de tipo comparativo, ya que usa modelos de econometría y de aprendizaje supervisado. Finalmente, después de un proceso de validación concluye que el modelo *Elnet* es el que mejor predice la inflación y solo es superado por un modelo ARIMA con un margen de diferencia mucho menor (Carmona Restrepo, 2022).

El segundo trabajo se titula “Pronóstico de la inflación colombiana: una aproximación desde un modelo Arima desagregado y Machine Learning” (Peña Ordoñez, 2019). Este, a diferencia del anterior, concentra el análisis en las 12 divisiones de gasto que componen el IPC para el periodo comprendido entre enero del 2009 y octubre del 2019. Para simplificar, únicamente elabora dos modelos: uno Arima de econometría y otro de *Random Forest*, con el objetivo de comparar los resultados respecto a la variación real de la inflación, junto con las diferentes medidas de error. En conclusión, el modelo *Random Forest* tuvo mejor desempeño que un modelo convencional Arima (Peña Ordoñez, 2019).

De los trabajos para economías emergentes, vale la pena destacar una investigación realizada para el caso chileno. En ella, la implementación de modelos *machine learning* respecto a modelos convencionales en econometría han resultado altamente competitivos. En la investigación “Proyección de la inflación en Chile con métodos de *machine learning*” (Zilberman, Leal, & Molina, 2020) se analiza la inflación con 64 variables y 14 clasificaciones distintas. Se entrenan 3 modelos *benchmarks*, 8 modelos lineales de ML y convencionales, y 2 modelos no lineales de ML, que son puestos a competir en términos de RMSE y MAE. Los resultados obtenidos mostraron que

los modelos *Random Forest* y AR presentaron el mejor desempeño respecto al comportamiento real de la inflación y las medidas de error. No obstante, no se descartan los demás modelos, ya que tuvieron un desempeño cercano y competitivo (Zilberman, Leal, & Molina, 2020).

En cada una de las investigaciones se identifican debilidades que dificultan la predicción de la inflación y el respaldo teórico para explicar sus determinantes, bien sea con los modelos econométricos o de *machine learning*. Por una parte, las investigaciones no profundizan en la teoría de la inflación, apenas expresan aspectos generales al respecto y los efectos básicos en la economía. Y, por otra parte, omiten el rezago en la información estadística de las variables, esto aparentemente dificulta significativamente la elaboración de modelos y el resultado de la predicción.

Por lo tanto, la presente investigación intentará responder el siguiente interrogante: ¿Es posible predecir la inflación actual a partir de sus determinantes macroeconómicos por medio de la metodología *machine learning*?

## **2. Resultado esperado**

El principal resultado esperado es que la inflación mensual proyectada por el modelo sea lo más cercano posible a la inflación efectiva una vez que se publiquen los resultados por el Departamento Nacional de Estadística -DANE-. Adicionalmente, se espera que un análisis desde el punto de vista de los determinantes macroeconómicos prediga la inflación actual mejor que aquellos modelos que hacen seguimiento al comportamiento de los precios en los mercados que componen la canasta básica de bienes y servicios.

## **3. Objetivos**

### **1.1 Objetivo general**

Predecir la inflación mensual para Colombia

### **1.2 Objetivos específicos**

- Identificar los determinantes macroeconómicos que explican el comportamiento de la inflación en Colombia.
- Realizar un análisis exploratorio de los datos que explican el comportamiento de la inflación en Colombia.
- Construir un modelo de *machine learning* para predecir la inflación colombiana.
- Entender y detectar las limitaciones predictivas de la inflación, en caso de haberlas, de los modelos *machine learning*.

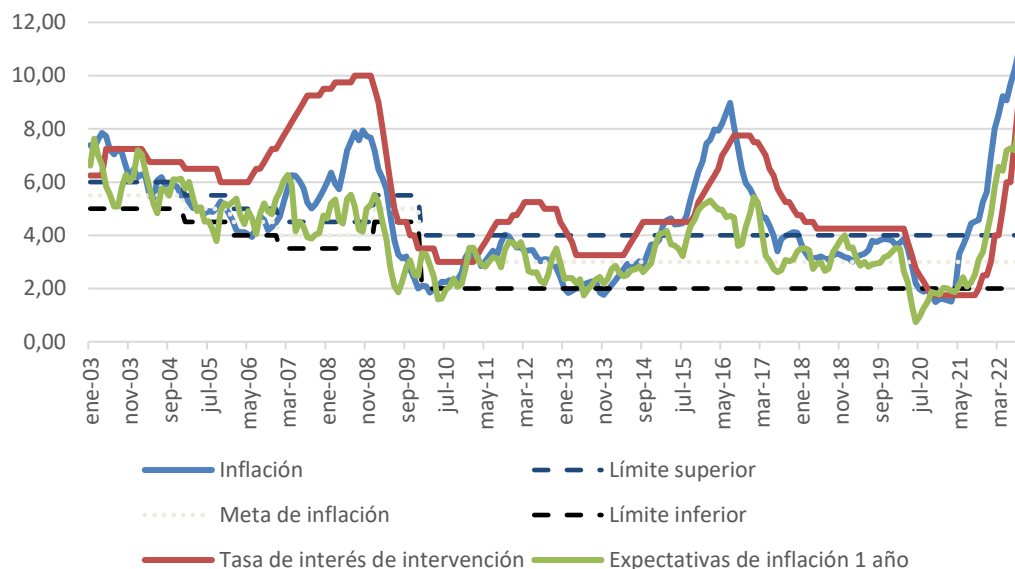
#### 4. Justificación

La pandemia del COVID-19 llevó a que tanto los gobiernos como las autoridades monetarias aplicaran políticas fiscales y monetarias expansivas para contener y mitigar sus efectos. No obstante, la demora en el endurecimiento posterior de la política monetaria –con el ingrediente adicional de la guerra entre Ucrania y Rusia– ha traído como consecuencia el crecimiento de la inflación en el mundo.

Como se observa en la figura 1, la autoridad monetaria colombiana se demoró en comenzar a implementar una política restrictiva, inclinándose por aceptar más crecimiento económico con más inflación. Pero, desde hace unos pocos meses para acá, las autoridades parecen haber optado por prestarle más atención al dilema intertemporal: tener menos inflación hoy y menos expectativas de inflación mañana para poder tener más crecimiento económico mañana. Finalmente, la Junta Directiva del Banco de la República decidió hacer aún más restrictiva la política monetaria, tratando de impedir una futura estanflación (Posada y Londoño-Sierra 2022).

**Figura 1.** Colombia. Tasa de inflación anual mensualizada, tasa de interés de intervención (política monetaria) y expectativas de inflación a un año (implícitas en las negociaciones de títulos de deuda pública). Enero 2003 – septiembre 2022.





**Fuente:** cálculos propios, Banco de la República (2022 a,b) y DANE (2022).

Las presiones inflacionarias mundiales continúan y las decisiones de la autoridad monetaria ayudan a controlarla. Sin embargo, tener mejores pronósticos de inflación les permite a los agentes una mejor toma de decisiones anticipadas sobre ahorro, inversión y consumo de bienes y servicios.

De acuerdo con lo anterior, la presente investigación realiza un análisis exploratorio con nuevas metodologías cuantitativas, como el *machine learning*, para predecir y explicar la variabilidad de la inflación en el tiempo, comparando escenarios de inflación alta y baja. Además, y dada la coyuntura actual, buscará contribuir en el debate académico.

## 5. Marco teórico y antecedentes del problema

Muchas economías, entre ellas la colombiana, han decidido que su objetivo de política monetaria es controlar la inflación en un rango meta. Sin embargo, desde octubre de 2021 ha crecido de manera acelerada y los modelos de predicción usualmente utilizados no logran acercarse a los valores observados. Dado que la inflación afecta las decisiones de los agentes, mejorar su pronóstico permitiría una mejor toma de decisiones por parte de la autoridad monetaria.

El punto de partida de esta investigación, respecto al control de la inflación, es la política monetaria elaborada por el economista Milton Friedman en la segunda mitad del siglo XX; un periodo de recesión en Estados Unidos. Sus políticas resultaron ser exitosas, tanto que por treinta años predominaron sus ideas en la política monetaria de la escuela keynesiana. En principio, esta política demostró las fallas en la Curva de Phillips para explicar el comportamiento de la inflación y la ineficacia de las políticas económicas en su control. La Curva de Phillips explica que existe una relación inversa entre la inflación y el desempleo en el corto plazo; y que en el largo plazo el desempleo no acelera la inflación, ya que la oferta y la demanda tienden a ajustarse. Además, Friedman demostró, en 1968, que en el largo plazo no existe un intercambio y una relación directa entre el desempleo y la inflación (Argandoña, 2020, pág. 33).

En segundo lugar, criticó el procedimiento de las autoridades monetarias en la formulación y ejecución de políticas keynesianas. Friedman las definió “como una combinación de instinto, juicio, corazonadas crudas para evaluar las implicaciones de las diferentes trayectorias de la política sobre la economía” (1968), de modo que él y la escuela monetarista construyeron una serie de objetivos y reglas que el banco central debe llevar a cabo para el control de la inflación. Estas consistieron en que el banco central debe estabilizar el camino entre el dinero y los precios, mantener una función poderosa y absolutamente libre de la esfera política, y mantener reglas que conlleven a evitar acciones exógenas por los políticos en el corto plazo y la rendición de cuentas hacia la opinión pública (Argandoña, 2020).

Simultáneamente tuvieron que incorporar los siguientes principios esenciales: 1) la inflación es siempre y en todas partes un fenómeno monetario y puede controlarse mediante la política monetaria; 2) la política monetaria a corto plazo tiene efectos reales en la economía a causa de la presencia de rigideces nominales o retrasos en el ajuste de la inflación esperada a la real; 3) debe existir una distinción entre las tasas de interés nominales y reales incorporadas en la ecuación

de Fisher; y 4) las reglas de política son importantes para una política monetaria estable (Argandoña, 2020).

Un tercer postulado del monetarismo de Friedman es la relación entre las expectativas racionales y la incertidumbre inflacionaria, que consiste en que los agentes económicos tomen decisiones intertemporales de acuerdo con las decisiones de política del banco central. Este, el banco central, influye en el movimiento negativo o positivo de las expectativas, y esto depende, en gran medida, del rol de los agentes económicos al tomar decisiones a futuro con respecto a la inflación del periodo anterior; con ello, modifican sus expectativas y su posición de incertidumbre (Argandoña, 2020).

Ahora, a manera de ejemplo, se podría suponer que la inflación se ha comportado de forma estable y a un nivel bajo, como producto de decisiones de políticas estabilizadoras. Tras esto llegan choques externos que incrementan la inflación, lo que trae como consecuencia que los agentes aumentaran sus expectativas de inflación y, con ello, la incertidumbre. Así, los costos asociados se incrementarían dado que aumentaría la falta de control de la inflación futura. Ahora bien, el rol del banco central sería aumentar los tipos de interés, sacrificando el crecimiento del producto con el objetivo de que en el largo plazo mejore la asignación de los recursos en la economía.

Las políticas de corrección de la inflación propuestas por Friedman tuvieron eficacia en Occidente hasta la década de 1980. La razón fundamental fue que la Reserva Federal encontró que la demanda agregada de dinero empezó a cambiar de forma volátil, lo que originó un nuevo problema para controlar la cantidad de dinero en la economía. Tiempo después los post-monetarias, junto con la comunidad académica, concluyeron que las políticas fueron efectivas para el control de la inflación en el corto y largo plazo, momento en el que el dinero no es neutral, sin descartar la neutralidad en largo plazo (Argandoña, 2020). De igual manera, encontraron que no

necesariamente los agregados monetarios representan un papel importante en la inflación, debido a choques exógenos producidos por los mercados en la oferta y la demanda.

En la actualidad el monetarismo originado en Friedman bajo el consenso académico afirma que la política monetaria no debe ser discrecional sino completamente reglado y ligeramente flexibles en el control de la inflación y en la ejecución misma de la política, para evitar que las expectativas de los agentes económicos generen un gran cambio en la tasa de inflación respecto al objetivo del banco central (Argandoña, 2020). Por el lado de los objetivos de política, el banco central debe comunicar con transparencia los objetivos; cuantificables y precisos con un análisis fundamentado junto con las variables que afectan la inflación, y de ser cambiado los objetivos por cambios no esperados, explicar lo que se esperaría en el futuro de esos nuevos cambios (Argandoña, 2020).

La escuela Estructuralista también contribuyó al entendimiento de las causas de la inflación durante la segunda mitad del siglo XX por economistas destacados de la Comisión Económica para América Latina y el Caribe (CEPAL). Concibieron las causas de la inflación como fallas en las estructuras de producción, distribución y consumo de la sociedad. Postulan la existencia de una relación positiva entre la variación de los precios de la economía y el crecimiento del producto interno bruto, hasta ciertas circunstancias (Rojas Velásquez & Cerquera Losada, 2019).

De modo que, según los estructuralistas, mantener en equilibrio la inflación se dará solo por medio del crecimiento económico, de ahí las causas de la inflación son de carácter estructural, y por lo tanto las variables monetarias cumplen el papel de generadoras de la inflación. Producto de sus análisis definieron nueve determinantes que causan la inflación de acuerdo con una línea temporal. En el corto plazo los determinantes son: el exceso de dinero, el déficit fiscal y políticas inconsistentes, y en el largo plazo: la contracción de la oferta agregada, incremento de la demanda agregada, la tasa de interés y las expectativas de inflación. Tiempo después, resaltaron dos grandes

determinantes: 1) Por el incremento general de bienes, 2) cuando los costos de producción agregado aumentan, 3) Por la previsión de los agentes económicos en el aumento de los precios frente a las expectativas, cuyo fenómeno fue nombrado las expectativas sobre la inflación (Rojas Velásquez & Cerquera Losada, 2019).

En la evolución de la teoría monetaria de la inflación, la predicción de la inflación representa otro gran aparte en la comprobación de los determinantes de la inflación en el tiempo. Existen un gran número de modelos para la predicción de la inflación que consideran las expectativas de inflación, la incertidumbre de la inflación que no es más que la volatilidad en el tiempo de la inflación respecto al pasado, y los efectos de los choques exógenos o las sorpresas monetarias.

En primer lugar, están los modelos dinámicos estocásticos de equilibrio general (DSGE), son modelos que predicen bajo condiciones flexibles y razonables. Reconocen que el dinero es neutral en el largo plazo y no en el corto plazo, y acepta que la política monetaria no debe utilizarse sólo para obtener resultados a corto plazo en el crecimiento económico y el empleo, lo cual ayuda a la estabilización de las expectativas (Argandoña, 2020). En segundo lugar, están los modelos de series temporales; AR, MA, SARIMA y LARIMA, los cuales son modelos de corte transversal o datos de tipo panel. En cada uno de estos existe la posibilidad de introducir todos los cambios estructurales que conlleva el régimen de metas de inflación, son modelos bastante utilizados en todo el mundo y en la mayoría de las economías porque capturan eficientemente la incertidumbre y la volatilidad de la inflación (Cruz Zúñiga & Ramírez Tapia, 2021, pág. 29).

En tercer lugar, están los modelos de la variante GARCH, este es modelo autorregresivo generalizado que captura las agrupaciones de volatilidad de las rentabilidades a través de la varianza condicional, en los análisis de inflación su función es la de estimar simultáneamente las medias condicionales, la varianza y la covarianza de la inflación con el crecimiento de la

producción, de forma análoga ejecutan las principales pruebas causalidad; como la de Granger para poner a prueba el sentido de causalidad que existe entre el valor esperado de la inflación y la incertidumbre de la inflación (Cruz Zúñiga & Ramírez Tapia, 2021).

En América Latina este tipo de modelos son muy útiles para comprobar los supuestos teóricos de incertidumbre y expectativas de inflación de Milton Friedman y Bell, donde muestran que existe una relación positiva entre la inflación y la incertidumbre provocando crecimiento económico bajo (Cruz Zúñiga & Ramírez Tapia, 2021).

En resumen, la teoría de la inflación es el resultado de la evolución sistemática de la teoría monetaria del dinero en el tiempo, que transcurre entre el siglo XIX y el siglo XX, por los más grandes exponentes John Maynard Keynes y Milton Friedman, padre del monetarismo de la escuela de Chicago, quien por entonces refutó sistemáticamente la relación inversa entre la inflación y el empleo, además de la política monetaria carente de objetivos y reglas. El monetarismo pudo exponer al detalle la influencia irrestricta en la capacidad de influenciar en las expectativas de inflación del futuro, respecto al pasado, y como choques externos diferentes a los determinantes de inflación alteraban positivamente la inflación y las estrategias, llamadas reglas para disminuir la inflación en las variables monetarias en largo plazo, como la oferta la demanda de dinero.

A continuación, se expone el método de *machine learning*, el cual está siendo muy utilizado en la literatura para predecir variables económicas complejas, debido a la riqueza de modelos que contiene, sus usos y resultados. Hace parte del campo de la inteligencia artificial computacional que involucra algoritmos de aprendizaje automático de los datos con el objetivo de elaborar predicciones. El ML permite: detectar el conocimiento de los datos eficientemente, hallar los modelos predictivos con mayor rendimiento y permitir una toma de decisiones respecto al conocimiento de los datos.

Para pronosticar la inflación es pertinente utilizar el aprendizaje supervisado. Este último, hace parte de una de las tres ramas del ML, cuyo propósito fundamental es elaborar un modelo que aprenda con base en datos de entrenamiento etiquetados, es decir, muestras de datos conocidos, de modo que con estos se generen predicciones de datos. Por ejemplo, la inflación que se mide como la variación porcentual del índice de precios al consumidor, se identifica como un dato continuo, que en el aprendizaje supervisado se analiza como una regresión, en la que se identifica unas variables explicativas y por supuesto la variable resultada.

Siguiendo el método de ML, la inflación puede ser estudiada desde modelos de regresión múltiple o univariable. Si es múltiple, se debe seleccionar un conjunto de variables con base a la literatura económica, donde se muestre la relación lineal, positiva o negativa respecto a la inflación; pero, si es univariable, se utiliza la misma variable de estudio. Con estos casos se puede elaborar un modelo de regresión lineal múltiple o univariable considerando el tiempo como un componente de influencia sobre la variable a explicar, esto significa que los datos se analizan desde un orden temporal, donde el pasado marca el camino para predecir el futuro. Por consiguiente, se usarán los siguientes modelos: El Autorregresivo Integrado de Promedio Móvil (ARIMA), regresión lineal múltiple de ML, Árboles de Decisión, MLP, KNN, SVR y LSTM. Con esto podrá evaluarse la superioridad del ML con respecto a los análisis de predicción tradicionales.

## **5.1 Modelo ARIMA**

La elaboración de un modelo ARIMA según la literatura se hace con la metodología de Box-Jenkins. Consiste fundamentalmente en cumplir con 4 pasos: la identificación, estimación, examen de diagnóstico y finalmente el pronóstico. Inicialmente se debe identificar si la serie temporal es estacional, sino lo es, se debe diferenciar la serie hasta que sea estacional, en el

momento en que sea estacionaria, la serie ya es un proceso integrado de orden  $d$  o una serie que fue diferenciada una sola vez.

Consecuentemente con la serie diferenciada, se construyen dos correlogramas: la función de autocorrelación parcial (FAC) y la función de autocorrelación parcial (FACP). A partir de los resultados en los correlogramas se encuentran los procesos autorregresivos (AR) de orden  $p$ , este explica que el valor del pronóstico de la variable independiente en el periodo  $t$  es sencillamente una proporción ( $=\text{Alpha1}$ ) de su valor en el periodo  $(t-1)$  más un choque aleatorio en el tiempo  $t$ , por otro lado, se encuentran los procesos de Media Móviles (MA) de orden  $q$ , que es una constante más un promedio móvil de los términos de error presente y pasado. En consecuencia en esta primera etapa se construye el modelo ARIMA de orden  $(q,d,p)$ . Teniendo el modelo ya elaborado y preparado, se ejecuta la estimación del modelo ARIMA para  $t$  periodos en el futuro, adicionalmente se realiza un examen de diagnóstico para probar que la FAC y la FACP de los residuos son estadísticamente significativos, es decir, los residuos son puramente aleatorios, y por último se corre el pronóstico del modelo ARIMA final.

## **5.2 Modelos machine learning**

### **5.2.1 Modelo de regresión lineal múltiple**

Los modelos ML derivados de la regresión lineal hacen parte del aprendizaje supervisado para la predicción de variables continuas. En esta tenemos un conjunto de variables explicativas y una variable resultado  $y$ , de modo que debemos encontrar la relación lineal entre el conjunto de variables para realizar buenos pronósticos. Con el conjunto de datos contenidos en cada variable se les da instrucciones a los ordenadores la capacidad de aprender el patrón de comportamiento de los datos y automatizar las predicciones. Antes de construir cualquier tipo de modelos de regresión es importante hallar la correlación entre las variables, generalmente se utilizan gráficos de



correlación y el coeficiente de correlación acotado entre 0 y 1, donde 0 es que no hay relación lineal entre las variables y 1 es si existe una relación lineal, adicionalmente esta la prueba de causalidad, a diferencia del anterior esta prueba lo que hace en determinar si una variable temporal  $x$  tiene la capacidad de predecir una variable  $y$ , por tanto ambas pruebas funcionan como filtro para elaborar modelos eficientes con buenas predicciones.

El modelo de regresión lineal múltiple *-LinearRegression-* consiste en desarrollar algoritmos de aprendizaje avanzado para estimar los parámetros  $w$  que minimizan la suma de las distancias verticales cuadradas en los puntos de muestra.

$$y = w_0x_0 + w_1x_1 + \dots + w_mx_m = \sum_{i=0}^m w_i x_i = w^T x$$

En el cual  $w_0$  es el peso en el eje  $y$  que intercepta con  $x_0 = 1$  (Rascha & Mirjalili, 2019), por lo tanto, el objetivo de esta ecuación es aprender los pesos de la ecuación lineal para describir la relación lineal entre las variables explicativas y la variable destino. En síntesis, el modelo hace casi lo mismo que un modelo de regresión lineal múltiple, la diferencia radica en la creación de patrones o algoritmos de aprendizaje de comportamiento para realizar mejores predicciones, identificados por los pesos  $w$  (Gonzalez L. , Regresión Lineal - Teoría, 2018).

### 5.2.2 Regresión lineal con árboles de decisión

Es un modelo de aprendizaje supervisado que se encarga de elaborar predicciones de respuesta por medio del aprendizaje de reglas de decisión derivadas de la clasificación de características. El funcionamiento de este divide un espacio de características en diferentes regiones rectangulares simples (Gonzalez L. , 2019). Ahora, para obtener una predicción de una observación particular se usa el promedio de las características, es decir:

$$f(x) = \sum_{m=1}^M W_m \phi(X; V_m)$$

Donde:

$W_m$  = es la respuesta promedio en una región particular.

$V_m$  = representa como se divide cada variable en un valor de umbral particular.

La heurística básica para crear un árbol de decisión es: 1) se divide el espacio de características en  $P$  dimensiones con  $M$  regiones mutuamente distintas; 2) para cada observación nueva en el modelo se ubica en la partición particular; 3) se hace una división binaria regresiva para minimizar el error; 4) Se minimiza la suma de cuadrados residuales (RSS); y, se finaliza con una división binaria recursiva en la parte superior del árbol, seccionando el árbol en dos ramas u/o espacios (Gonzalez L. , 2019).

### 5.2.3 Modelo de Perceptrón Multicapa (MLP)

Es un modelo de carácter matemático en la que su estructura funciona como una neurona biológica, a esto se le llama un *perceptrón*. Comúnmente se usa para comprender el concepto de los clasificadores binarios, perteneciente al sistema de redes neuronales. El MLP implementa una red neuronal para que aprenda características, generalizando un patrón de entradas para desarrollar pronósticos precisos con datos no vistos. Esta red neuronal se le conoce como *retro propagación*, el cual cuando es de una sola capa está compuesto por: 1) unas entradas  $(x_1, x_{n-1}, x_n)$ ; 2) unos pesos que representa un valor preliminar cuando se inicia el aprendizaje del algoritmo; 3) una suma ponderada; 4) una función de activación; y, 5) una salida, es decir, la suma ponderada que pasa por la función de activación finalmente es la predicción. Adicionalmente, si el modelo es multicapa

está compuesto por: unas capas de entradas, ocultas y de salida, las cuales se ejecutan en dos etapas hacia adelante y hacia atrás (Gonzalez L. , 2021).

Finalmente, el modelo MLP forma redes neuronales sobre cada una de las capas, generando una función de activación no lineal, de manera que, son funciones de activación no lineales.

#### **5.2.4 Modelo de K- vecinos (KNN, del inglés *K-nearest neighbours*)**

Es un modelo de aprendizaje supervisado que no crea suposiciones explícitas dentro de la forma funcional de los datos y memoriza instancias de formación que luego se usan para la fase de predicción. La ejecución del modelo consiste en calcular la distancia de los  $k$  vecinos, hallar los vecinos más cercanos y hacer una votación para las etiquetas (los datos de cada variable explicativa) (Gonzalez L. , 2019).

Ahora bien, un valor  $k$  es un hiperparámetro que es preseleccionado cuando se realiza la construcción del modelo. Este consiste, en primer lugar, en definir el algoritmo particionado los datos  $(x, y)$  en datos de prueba y entrenamiento; en segundo lugar, se realiza el entrenamiento del modelo; en tercer lugar, se ejecuta el pronóstico; y, finalmente, se evalúa el rendimiento del modelo (Gonzalez L. , 2019).

#### **5.2.5 Modelo de vectores de soporte de regresión (SVR)**

Los modelos de vectores de soporte con regresión derivan del modelo original llamado máquinas de vectores de soporte (SVM). La teoría del SVR esta soportada en la teoría SVM. El modelo en esencia funciona según el modelo original de algoritmos del Perceptrón umbralizado de Frank Rosenblatt (Rascha & Mirjalili, 2019). Consiste en la imitación del funcionamiento general de una neurona cerebral, células nerviosas interconectadas en el cerebro que participan en el proceso y la transmisión de señales eléctricas y químicas.

Los objetivos principales de este modelo son: minimizar el error, individualizar el hiperplano que maximiza el margen y que el modelo pueda tolerar el error (Gonzalez L. , 2019). La fórmula para calcular los datos lineales es:

$$\min \frac{1}{2} \|W\|^2 + C \sum_{i=1}^N (\xi + \xi^*)$$

Donde,

$w$  = es la longitud del vector o del hiperplano.

$C$  = es una constante  $> 0$  ; determina el equilibrio entre la regularidad de la función y la cuantifica hasta una tolerancia de desviaciones mayores que sus bandas de soporte.

$\xi + \xi^*$  = son variables que confrontan el error cometido por la función de regresión al aproximar las bandas.

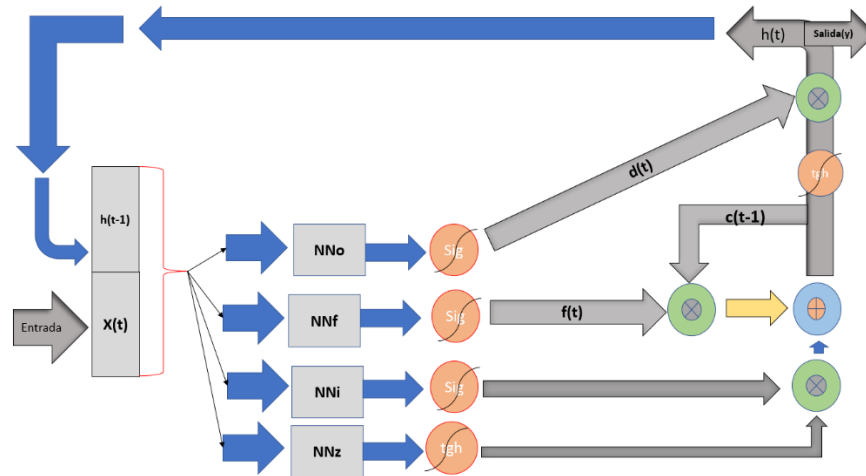
La lógica del hiperplano óptimo es generar límites de decisión con amplios márgenes porque error de generalización sería bajo, de lo contrario con márgenes pequeños se presentaría sobreajuste en el modelo de predicción (Rascha & Mirjalili, 2019). Ahora bien, con base a la teoría se elaboran modelos SVM, pero para predecir variables continuas o no categóricas, con la diferencia de que se emplean funciones y códigos de programación razonablemente distintos.

### 5.3 Modelo Long Short-Term Memory (LSTM)

Es una red neuronal con origen en las redes neuronales recurrentes (RNN) con la capacidad de recordar secuencias de datos importantes y mantenerlos por varios periodos de tiempo. Es una red neuronal que puede ser entrenada con una memoria de corto plazo, así como también de largo plazo, y funciona casi como nuestro cerebro entiende las secuencias de información de características y números.

**Figura 2.**

*Esquema de funcionamiento de una Red Neuronal Recurrente LSTM*



Fuente: XpiKuos. [28 de febrero del 2020]. ¡Redes Neuronales LSTM Recurrentes (RNN) IA – NO MÁS DUDAS! 2022 [Archivo de video]. YouTube.  
<https://www.youtube.com/watch?v=ppJA9iyByNo>

La red neuronal (NN por sus siglas en inglés) LSTM (ver figura 2) está compuesta por cuatro ramas con funciones distintas al paso de datos. La rama  $NN_i$  es una red neuronal con una función sigmoide que solo deja pasar elementos de memoria necesarios para tomar decisiones que ya han sucedido anteriormente. La rama  $NN_z$  ignora la información inútil de la entrada, la rama  $NN_f$  tiene la capacidad recordar y olvidar información, es decir, le da un valor a aquella información que merece ser recordada u olvidada y memorizada por el canal  $c(t-1)$ , y finalmente la rama  $NN_o$  que funciona para seleccionar la información de los estados anteriores, el cual pasan por el vector  $h(t-1)$ , en base a los coeficientes de las matrices de pesos. Matemáticamente la red neuronal LSTM se identifica de la siguiente manera:

Es una NN genérica:  $y(t) = f(wx(t) + b)$

$$X(t) = [x(t)[h(t - 1)]], w \rightarrow [w_j|U_i]$$

$$Y(t) = f(WX(t) + Uh(t - 1) + b]$$

- $NN_z : Z(t) = tgh (W_z X(T) + U_z h(t - 1) + b_z )$
- $NN_i : i(t) = sig (W_i X(t) + U_i h(t - 1) + b_i)$
- $NN_f : f(t) = sig (W_f X(t) + U_f h(t - 1) + b_f)$
- $NN_o : o(t) = sign (W_o X(t) + U_o h(t - 1) + b_o)$
- $c(t) = C(t - 1) * f(t) + i(t) * z(t)$
- $h(t) = o(t) * tgh (c(t))$

donde,

- $x(t)$ : es la serie temporal del fenómeno.
- $W$  : Es un vector de pesos sinápticos que se aplican a las entradas.
- $h(t - 1)$  : es un estado oculto anterior construido por el modelo.
- $U$  : Es un vector de pesos sinápticos que se aplican a los estados ocultos previos.
- $W_z, W_i, W_f, W_o$  : Son vectores de pesos respectivamente para cada red  $NN_z, NN_i, NN_f, NN_o$ , que se aplican sobre los vectores de entrada  $X(t)$ .
- $U_z, U_i, U_f, U_o$ : Son vectores de pesos respectivamente para cada red  $NN_z, NN_i, NN_f, NN_o$ , que se aplican sobre los estados ocultos.
- $sig$ : una función de activación sigmoideal definida tal que  $sig \in [0, 1]$ .
- $tgh$ : una función de activación tangente hiperbólica acotada entre -1 y +1.
- $C(t - 1)$ : un vector que memoriza para un tiempo anterior dado,

En otras palabras, la red neuronal LSTM funciona como si fuera una banda transportadora en la que se le pueden agregar o quitar información no deseada en la memoria de la red. Ahora bien, la red LSTM decide qué información recordar, olvidar y seleccionar por medio del algoritmo de aprendizaje supervisado Backpropagation.

## 6. Metodología

### 6.1 Descripción de datos

Para realizar las predicciones se elaboraron cinco modelos de regresión lineal múltiple para observar la influencia de las variables en la inflación y tres modelos de series temporales en el software de programación de Python: dos univariados y 6 multivariados. A partir de la teoría se seleccionaron 24 variables económicas y financieras, para hacer los ejercicios cuantitativos para el periodo de análisis (enero del 2002 - septiembre del 2022). La frecuencia es mensual, así se tienen 249 observaciones para cada variable.

En la tabla 1, se describe el conjunto de variables utilizadas para el análisis cuantitativo.

**Tabla 1.** *Variables XXX*

Nombre de la variable	Nombre de la variable en el modelo	Fuente
Índice de precios al consumidor de Colombia	<i>Ippcol</i>	<i>DANE</i>
Índice de precios al consumidor en Estados Unidos	<i>Ipcusa</i>	<i>Federal Reserve Bank of St. Louis</i>
Tasa de política monetaria	<i>Tsplm</i>	<i>Banco de la República de Colombia</i>
Tasa de ocupación	<i>Empleo</i>	<i>DANE</i>
Tasa de desempleo	<i>Desempleo</i>	<i>DANE</i>
Índice de precios al productor	<i>Ippcol</i>	<i>DANE</i>

Índice de precios importados	<i>Ipimp</i>	<i>DANE</i>
Meta de inflación	<i>Metainf</i>	<i>Banco de la República de Colombia</i>
Tasa Representativa del Mercado	<i>Trm</i>	<i>Banco de la República de Colombia</i>
Base monetaria	<i>Basmont</i>	<i>Banco de la República de Colombia</i>
Depósitos en el sistema financiero total	<i>Dpfcrs</i>	<i>Banco de la República de Colombia</i>
M2	<i>M2</i>	<i>Banco de la República de Colombia</i>
Reserva Bancaria	<i>Resbanc</i>	<i>Banco de la República de Colombia</i>
Total, Cartera Bruta sin ajuste por titularización en moneda extranjera expresada en COP	<i>Tcbmx</i>	<i>Banco de la República de Colombia</i>
Total, Cartera Bruta sin ajuste por titularización en moneda local	<i>Tcbml</i>	<i>Banco de la República de Colombia</i>
Tasa de interés de crédito de consumo	<i>Tincc</i>	<i>Banco de la República de Colombia</i>
Tasa de interés Cero cupón, Títulos de tesorería (TES), en pesos a 1 año.	<i>Tccpcop</i>	<i>Banco de la República de Colombia</i>
Tasa de interés Cero cupón, Títulos de tesorería (TES), en UVR a 1 año	<i>Tccuvr</i>	<i>Banco de la República de Colombia</i>
Tasa de interés de colocación del Banco de la República	<i>Tidcln</i>	<i>Banco de la República de Colombia</i>
Tasa de interés interbancaria (TIB)	<i>Tinbnc</i>	<i>Banco de la República de Colombia</i>
Precio internacional del Petróleo WTI	<i>Pwti</i>	<i>U.S Energy Information Administration</i>
Expectativas de inflación 1 año en Colombia	<i>Expinfl</i>	<i>Banco de la República de Colombia</i>
Producto Interno Bruto a precios corrientes	<i>pib</i>	<i>DANE</i>

**Fuente:** elaboración propia

El tratamiento de los datos fue distintito para los ocho modelos de regresión múltiple y de series temporales. Para los modelos de series temporales, LSTM y SARIMA, se usó la variable índice de precios al consumidor para Colombia con datos mensuales desde el año 2002 hasta septiembre del año 2022 mientras que para los multivariable (LSTM, SVR, K-vecinos, MLP,



Regresión Lineal y Árboles de decisión) se utilizaron las 24 variables en el mismo periodo de tiempo.

En los modelos de serie temporal se implementó para el SARIMA la metodología Box-Jenkins. Para el LSTM fue separada la serie en datos de entrenamiento y prueba, en una proporción 80% y 20%, respectivamente; se tomó una muestra de 64 datos aleatorios, 100 épocas, 1 capa oculta y una tasa de aprendizaje 0,001.

Por su parte, en los modelos multivariados de regresión lineal múltiple se realizan los siguientes pasos: 1) se elabora la correlación lineal con la variable IPC y una prueba de multicolinealidad; 2) se define el modelo con el algoritmo dividiendo los datos (X, Y) en entrenamiento y prueba; 3) se definen los parámetros del establecidos; 4) se ejecuta la predicción con sus coeficientes y el intercepto; y, 5) se evalúa el rendimiento del algoritmo con el error estadístico MSE y el R-cuadrado.

Con el modelo LSTM multivariable, se realizaron pruebas de correlación lineal y de causalidad de Granger con rezagos a 12, 24 y 36 meses; se separaron los datos en prueba y entrenamiento en una proporción 80 % y 20%, respectivamente: El algoritmo LSTM se implementó con una muestra de 150 datos de 249 del periodo analizado, 600 épocas, 1 capa oculta, 0.006 de tasa de aprendizaje y otros parámetros predeterminados. Luego, se evaluó el rendimiento del modelo con los errores estadísticos MSE, MME y un gráfico de pérdida en el entrenamiento y conjunto de datos de prueba y, por último, se ejecutó el pronóstico mensual del IPC.


Adicionalmente, a los modelos de regresión lineal múltiple se les aplico un *PowerTransformer* para hacer que los datos sean más gaussianos (Scikit - learn developers, 2022), y para los modelos LSTM les fue aplicado un *MinMaxScaler* para transformar las variables continuas a un rango por defecto entre (0,1) (Scikit - Learn developers, 2022).

## 7. Resultados

Para comprobar la teoría económica respecto a los determinantes de la inflación se aplicaron las pruebas de correlación lineal y la prueba de causalidad de Granger para series temporales. En la primera prueba los resultados fueron los esperados (figura 3): las variables monetarias tienen una correlación lineal cercana a uno, es decir, están altamente correlacionadas con el IPC de Colombia, y la mayoría de las tasas de interés de los mercados financieros tienen una correlación negativa con el IPC Colombia. Con respecto a las variables estructurales el PIB Colombia mensualizado tiene una correlación positiva cercana a 1, en las variables empleo y desempleo la correlación es media, y las variables *ipcusa*, *ippcol*, *ipimp*, *trm* y *pwti* resultaron con alta correlación sobre el *ipccol*.

Ahora bien, con la prueba de causalidad de Granger efectivamente las variables base monetaria, *m1*, tasa de política monetaria, depósitos financieros totales, tasa de interés cero cupón en pesos a 1 año, total cartera bruta sin ajuste por titularización en moneda local y la tasa de interés interbancaria causan a un nivel de rezagos del 12, 24 y 36 meses. Para las variables con rezagos de 12 y 24 meses son: *m1*, *trm*, la reserva bancaria, total cartera bruta sin ajuste por titularización en moneda extranjera, IPC estados unidos y tasa interés cero cupón a 1 año en UVR, finalmente el resto de las variables tuvieron causalidad menores o iguales a 12 rezagos. Por consiguiente, se seleccionaron las siguientes variables: *tsplm*, empleo, desempleo, *tinbcn*, *tincc*, *ticcpcop*, *tccp*, *tccpuvr*, *pib*, *m1*, *ipcusa*, *trm* y *expinfl*.

**Figura 3.** *Gráfico de calor de la correlación lineal entre IPC de Colombia y las variables explicativas*



**Fuente:** elaboración propia con datos del DANE (2022) & BanRep (2022)

En los modelos de regresión lineal múltiple de ML los resultados fueron los esperados. El R- cuadrado, en todos los modelos se aproximan a uno, es decir, las variables explicativas generan una buena predicción sobre el IPC; y, para el MSE se aproximan a cero, con lo cual, los modelos minimizan efectivamente el error. Finalmente, de los cinco modelos el de mejor rendimiento es el de Árboles de decisión.

**Tabla 2.** Pruebas de eficiencia de los modelos de regresión lineal de ML

Modelo	R- cuadrado de entrenamiento	R-cuadrado de prueba	Error cuadrático medio (MSE)
Regresión lineal	0.998	0.997	0.0034
K-vecinos	0.998	0.998	0.0021
SVR (SVM)	0.995	0.995	0.0045
Árboles de decisión	1.0	0.998	0.0020
MLP	0.995	0.997	0.0074

**Nota.**

**Fuente:** Elaboración propia con datos del BanRep (2022), Dane (2022)

En los modelos de series temporales univariable y multivariable los rendimientos son diversos con tendencia a subestimar la predicción del IPC (Tabla 3). En el modelo ARIMA el MSE es cercano a cero, es decir, el modelo genera una buena minimización del error. En los otros dos modelos se presentan los errores más elevados, específicamente en el de prueba para el LSTM multivariable y en el entrenamiento LSTM univariable. Por lo tanto, es en estos dos modelos donde la predicción tiende a ser subestimada.

**Tabla 3** . *Pruebas de eficiencia de los modelos de series temporales*


Modelo	MSE de entrenamiento	MSE de prueba	MSE ARIMA
ARIMA			0.085
LSTM univariable	0.19	0.96	
LSTM multivariable	0.1385	27.04	

**Nota.**

**Fuente:** elaboración propia con datos del DANE (2022) & BanRep(2022).

De igual forma se puede observar en la figura 4 la pérdida de error de entrenamiento y validación (prueba) en ambos modelos, el cual explica como a través de las épocas se minimizan los errores hasta un nivel de convergencia. Tal como el LSTM univariado la variación del error es más volátil que en el multivariado.

**Figura 4.** *Gráficos de pérdida de error de entrenamiento y validación de los modelos LSTM*



**Fuente:** elaboración propia con datos del DANE(2022) & BanRep (2022).

La predicción del Índice de Precios al Consumidor de los modelos para el mes de octubre del 2022 fueron las siguientes: Arima 123.75, LSTM univariable 122.44 y LSTM multivariable 122.61. En consecuencia, el mejor modelo de predicción es el ARIMA, dado que el valor real de octubre del 2022 fue de 123.51. No obstante, con este modelo no podemos comprender detalladamente que variables influyeron en el resultado de la inflación, mientras que en modelo multivariado si es posible entenderlo, por el hecho de seleccionar las variables que explican estadísticamente la inflación.

De acuerdo con los resultados en cada uno de los modelos se encuentran las siguientes limitaciones predictivas: primero, los modelos pueden generar mejores predicciones con un mayor número de datos temporales; segundo, los modelos LSTM tienen la desventaja de producir pronósticos erróneos con variables altamente correlacionadas, por tanto es indispensable encontrar variables económicas con correlaciones bajas negativas o positivas; tercero, los modelos LSTM propenden a generar pronósticos ineficientes con una arquitectura de códigos mal construida con respaldo teórico en el software de Python; y, por último el modelo LSTM por su avanzada arquitectura se convierte en un proceso complejo en el cambio de parámetros para generar un buen pronóstico.

## 8. Conclusiones

La teórica económica del Monetarismo y del Estructuralismo condujo a esta investigación para seleccionar un conjunto de variables macroeconómicas de carácter financiero, producción y monetario, elaborando ocho modelos predictivos: cinco modelos de regresión lineal múltiple de ML y tres modelos de series temporales (uno convencional y dos modelos avanzados de ML). Los de mayor importancia son los de series temporales porque nos muestra la predicción mensual del IPC y su respectiva variación mensual – anualizada, de entre estos el de mejor desempeño fue el ARIMA, seguido del Multivariado LSTM debido a que es posible interpretar el pronóstico de acuerdo con las variables explicativas. Por último, es concluyente afirmar que el modelo LSTM multivariado no es perfecto, requiere de una mejor arquitectura en el modelo, incluso podría mejorar si se incluye el comportamiento de cada una de las divisiones que componen la canasta básica, y por ultimo, se pudo comprobar que los algoritmos que implementa este para realizar la predicción logra captar los cambios drásticos de las variables.

## 9. Bibliografía

- Argandoña, A. (2020). *Iberian Journal of the History of Economic Thought*. Retrieved from <https://doaj.org/article/0fce8e7e3bb041379050199634d64479>
- BanRep. (2021, Septiembre). *Banco de la República de Colombia*. Retrieved from <https://www.banrep.gov.co/es/tanto-sabe-sobre-inflacion>
- BanRep. (2022, Agosto). *Banco de la República de Colombia*. Retrieved from <https://totoro.banrep.gov.co/estadisticas-economicas/>
- Carmona Restrepo, N. (2022). *Universidad Nacional de Colombia*. Retrieved from <https://repositorio.unal.edu.co/bitstream/handle/unal/81484/1036676092.2022.pdf?sequence=1>
- Cruz Zúñiga, M., & Ramírez Tapia, D. L. (2021, Mayo). *Universidad Autonoma del Estado de Mexico*. Retrieved from <http://hdl.handle.net/20.500.11799/111730>
- DANE. (2022). *Departamento Nacional de Estadística*. Retrieved from <https://www.dane.gov.co/>
- Gonzalez , L. (2019, Julio 19). *aprendeia*. Retrieved from <https://aprendeia.com/algorithmo-k-vecinos-mas-cercanos-teoria-machine-learning/>
- Gonzalez , L. (2019, Febrero 1). *aprendeia*. Retrieved from <https://aprendeia.com/algorithmo-maquina-de-vectores-de-soporte-regresion-machine-learning/>
- Gonzalez , L. (2021, Octubre 5). *aprendeia*. Retrieved from <https://aprendeia.com/que-es-el-perceptron-simple-y-multicapa/>
- Gonzalez, L. (2018, Noviembre 18). *aprendeia*. Retrieved from <https://aprendeia.com/algorithmo-regresion-lineal-simple-machine-learning/>
- Gonzalez, L. (2019, Marzo 1). *aprendeia*. Retrieved from <https://aprendeia.com/arboles-de-decision-regresion-teoria-machine-learning/>
- Ozgur, O., & Ugur, A. (2021, Enero). *International Journal of Emerging Markets*. Retrieved from <https://www.emerald.com/insight/1746-8809.htm>
- Peña Ordoñez, A. C. (2019, Diciembre). *Repositorio Universidad de los Andes*. Retrieved from Universidad de Los Andes: <https://repositorio.uniandes.edu.co/handle/1992/44645>
- Rascha, S., & Mirjalili, V. (2019). *Python Machine Learning*. Marcombo S.A.
- Rojas Velásquez, L., & Cerquera Losada, O. H. (2019, Febrero 12). *Universidad Surcolombiana*. doi:<https://doi.org/10.25054/25905007.1406>
- Tarapuez Chamorro, E. I., Rivera , C. A., & Donneys , O. A. (2010). *Fundamentos de teoría monetaria y bancaria*. Bogotá : Ecoe Ediciones .

Uribe Escobar, J. D. (2007, Agosto 9). *Banco de la República de Colombia*. Retrieved from <https://www.banrep.gov.co/es/noticias/noticias-y-novedades/apartes-intervencion-gerente-lxiii-andi>

Villarreal Veloz, F. G. (2021). *Escuela Politécnica Nacional*. Retrieved from <https://bibdigital.epn.edu.ec/handle/15000/22148>

XpiKuos. (2020, Enero 30). REDES NEURONALES LSTM RECURRENTES (RNN) IA - NO MÁS DUDAS! 2022. Retrieved from <https://www.youtube.com/watch?v=ppJA9iyByNo>

Zilberman, E., Leal, F., & Molina, C. (2020, Enero). *Banco Central Chile*. Retrieved from <https://www.bcentral.cl/es/web/banco-central/contenido/-/detalle/proyeccion-de-la-inflacion-en-chile-con-metodos-de-machine-learning>

Banco de la República. (2022a). Tasa cero cupón en pesos y en UVR.

<https://www.banrep.gov.co/es/estadisticas/tes>

Banco de la República. (2022b). Tasa de interés de política monetaria.

<https://www.banrep.gov.co/es/estadisticas/tasas-interes-politica-monetaria>

Departamento Nacional de Estadística – DANE (2022) Índice de precios al consumidor.

[https://www.dane.gov.co/files/investigaciones/ipc/jul22/IPC\\_Indices.xlsx](https://www.dane.gov.co/files/investigaciones/ipc/jul22/IPC_Indices.xlsx)