

Facultad Latinoamericana de Ciencias Sociales, FLACSO Ecuador

Departamento de Desarrollo, Ambiente y Territorio

Convocatoria 2020 - 2022

Tesis para obtener el título de Maestría en Economía del Desarrollo

MODELOS DE NOWCASTING PARA LA TASA DE CRECIMIENTO DEL PIB REAL  
DE ECUADOR, UNA APLICACIÓN DE MACHINE LEARNING

Guerra Burbano Silvio Wladimir

Asesor: Ponce Jarrín Juan Elías

Lectores: Intriago Armijos Ruthy Vanessa, Onofa Dávila Mercedes Elizabeth

Quito, mayo de 2025

## **Dedicatoria**

A las maravillosas mujeres de mi familia.

A mi madre, Wilma, a mi hermana, Karol, a mi abuelita, Teresita, a mis tías Lorena, Giovanna, Lilian y Cecilia.

A todas ustedes, gracias por ser el motor que me impulsa a seguir adelante. Este logro también es suyo.

## **Epígrafe**

“All models are wrong, but some are useful”

George Box

## Índice de contenidos

<b>Resumen</b> .....	8
<b>Agradecimientos</b> .....	9
<b>Introducción</b> .....	10
<b>Capítulo 1. Marco teórico</b> .....	12
1.1. Pronósticos en economía.....	12
1.1.1 Breve historia de los pronósticos en economía .....	12
1.2. El rol de las expectativas y la incertidumbre.....	15
1.2.1 Expectativas racionales .....	15
1.2.2 Crítica a las expectativas racionales.....	16
1.2.3 Incertidumbre .....	17
1.3. Pronósticos en la práctica.....	18
1.4. Nowcasting o pronósticos inmediatos.....	20
1.4.1 Nowcasting con machine learning .....	20
1.5. Pronósticos en Ecuador .....	21
1.6. Revisión de la literatura empírica.....	22
<b>Capítulo 2. Marco metodológico</b> .....	26
2.1. Revisión de los métodos.....	26
2.1.1. ARIMA.....	26
2.1.2. Machine Learning .....	26
2.1.3. Ridge, lasso y elastic net .....	26
2.1.4. Decision Tree Regression.....	27
2.1.5. Random Forest .....	28
2.1.6. Support Vector Machine (SVM) .....	29
2.1.7. Gradient Boosting, XGBoost y LGBM.....	30
2.1.8. Interpretabilidad .....	30

2.2. Datos y metodología.....	31
<b>Capítulo 3. Resultados</b> .....	<b>35</b>
<b>Conclusiones</b> .....	<b>39</b>
<b>Referencias</b> .....	<b>40</b>
<b>Anexos</b> .....	<b>45</b>

## **Lista de ilustraciones**

### **Figuras**

Figura 2.1 Funcionamiento de los árboles .....	28
Figura 2.2. Funcionamiento del random forest .....	29
Figura 2.3. Interpretabilidad vs Flexibilidad .....	31

### **Gráficos**

Gráfico 3.1. Comparación de los modelos .....	35
Gráfico 3.2. XGboost .....	35
Gráfico 3.3. Ridge, Lasso y Elastic Net .....	36
Gráfico 3.4. Decision Tree Regression y Random Forest.....	37
Gráfico 3.5. Support Vector Machine (SVM).....	37

### **Tablas**

Tabla 2.1. Variables utilizadas en los modelos .....	32
--	----

Esta tesis/tesina se registra en el repositorio institucional en cumplimiento del artículo 144 de la Ley Orgánica de Educación Superior que regula la entrega de los trabajos de titulación en formato digital para integrarse al Sistema Nacional de Información de la Educación Superior del Ecuador, y del artículo 166 del Reglamento General Interno de Docencia de la Sede, que reserva para FLACSO Ecuador el derecho exclusivo de publicación sobre los trabajos de titulación durante un lapso de dos (2) años posteriores a su aprobación.

## Resumen

Esta tesis investiga cómo los modelos de Machine Learning (ML) pueden mejorar los pronósticos inmediatos (nowcast) del Producto Interno Bruto (PIB) de Ecuador. La hipótesis planteada es que los modelos de ML ofrecen pronósticos más precisos, medidos a través de la Raíz del Error Cuadrático Medio (RMSE). Además, se espera que estos modelos ofrezcan estimaciones en tiempo real, proporcionando información útil antes de que se publiquen las cifras oficiales del PIB, las cuales tienen un retraso de tres meses en Ecuador.

Para probar esta hipótesis, utilicé varios modelos de ML, como Lasso, Ridge, Random Forest, XGBoost y Support Vector Machines (SVM), comparándolos con el modelo ARIMA, utilizado como referencia (benchmark). Empleé datos macroeconómicos con mayor frecuencia, como la inflación, la recaudación de impuestos, el consumo eléctrico, entre otras, lo que permitió obtener pronósticos en tiempo real.

Los resultados de mi investigación confirman que los modelos de ML superan al modelo ARIMA en términos de precisión, mostrando una RMSE más baja. Sin embargo, uno de los principales desafíos para futuras investigaciones es el problema de la interpretabilidad. Estos modelos funcionan como una especie de “caja negra”, lo que dificulta comprender que factores influyen en las predicciones, algo esencial para los responsables de la política económica. Además, los modelos de ML mostraron sensibilidad a choques extremos, como la crisis del COVID-19.

Considero que sería oportuno seguir explorando modelos más avanzados, como las redes neuronales y modelos híbridos, que podrían mejorar la capacidad predictiva en momentos de alta volatilidad. También sería útil incorporar nuevas variables explicativas, como los índices de movilidad o las búsquedas en Google, que pueden ofrecer información valiosa en tiempo real. Además, es fundamental desarrollar técnicas que mejoren la interpretabilidad de los modelos, como los métodos SHAP o LIME, que descomponen las predicciones y permiten entender mejor los factores que influyen en ellas.

Por último, es crucial fomentar el acceso a datos abiertos en Ecuador, mejorando la calidad y la disponibilidad de los datos macroeconómicos. Esto no solo permitiría una mayor adopción de modelos de ML y facilitaría la implementación de modelos predictivos en tiempo real, sino que también mejoraría la capacidad de respuesta ante los desafíos económicos y permitiría decisiones más informadas y oportunas.

## **Agradecimientos**

A Juan Ponce y Wilson Pérez por sus valiosas observaciones y recomendaciones para la elaboración de esta tesis.

A mi familia y amigos, por su constante apoyo durante este proceso.

## Introducción

Los hacedores de política suelen tomar decisiones en tiempo real utilizando información incompleta sobre las condiciones económicas actuales. Además, muchas estadísticas clave se publican con retrasos y están sujetas a revisiones frecuentes (Richardson, van Florenstein Mulder, y Vehbi 2020). El Banco Central del Ecuador (BCE) publica la información oficial del Producto Interno Bruto (PIB), principal indicador macroeconómico del curso de la economía del país, con un retraso de 3 meses lo que puede ser un problema para los hacedores de política económica y el sector privado (Casares 2017).

A modo de ejemplo, si quisiéramos saber cuánto creció la economía en un determinado trimestre tendríamos que esperar hasta finales del siguiente para conocer las cifras oficiales. Para atenuar este problema surgieron los modelos de nowcasting cuyo “principio básico es la explotación de la información que se publica temprano y en frecuencias más altas que la variable objetivo de interés para obtener una estimación anticipada antes de que la cifra oficial esté disponible” (Bańbura et al. 2013). Sin embargo, “se ha avanzado poco en la implementación y evaluación del desempeño de los modelos de nowcasting en las pequeñas economías en desarrollo, principalmente debido a deficiencias en la disponibilidad de datos y, en algunos casos, debido a inestabilidad económica” (González-Astudillo y Baquero 2019).

Mientras que en países desarrollados se cuentan por decenas los estudios sobre modelos de nowcasting, en Ecuador son pocas las propuestas al respecto por ejemplo tenemos los trabajos de: Liu, Matheson, y Romeu (2012), Casares (2017), González-Astudillo y Baquero (2019), Yaselga (2019) y López, Yaselga, y Espinosa (2021). Todos estos trabajos caen dentro de lo que se puede catalogar como métodos tradicionales de nowcasting. No obstante, Bolhuis y Rayner (2020) mencionan que estos modelos a menudo dan como resultado grandes errores de pronóstico, particularmente cuando la variable que se va a predecir es volátil, como el crecimiento de la producción en muchas economías de mercados emergentes y en desarrollo.

Literatura reciente muestra que los modelos de aprendizaje automático, del inglés machine learning (ML), pueden superar a los métodos de pronóstico tradicionales porque enfatizan el desempeño fuera de la muestra (en lugar de dentro de la muestra) y manejan mejor las interacciones no lineales entre una gran cantidad de predictores. “Los métodos ML están diseñados específicamente para aprender relaciones complejas a partir de datos pasados mientras resisten la tendencia de los métodos tradicionales a sobre extrapolar relaciones históricas en el futuro” (Bolhuis y Rayner 2020). En ese sentido, mi investigación contribuye

a la literatura emergente sobre el pronóstico de variables macroeconómicas utilizando algoritmos de ML que se espera mejoren significativamente los pronósticos frente a los modelos tradicionales y que además no se ha hecho todavía para el caso ecuatoriano.

**Objetivo:** El presente trabajo tiene como objetivo evaluar la precisión de los modelos de aprendizaje automático (ML) en el nowcasting de la tasa de crecimiento del PIB real en Ecuador, comparando su desempeño con los métodos tradicionales.

**Hipótesis:** Se espera que los modelos de aprendizaje automático (ML) superen a los métodos tradicionales en términos de precisión de pronóstico, presentando una menor Raíz del Error Cuadrático Medio (RMSE).

Con respecto a la estructura del documento, empiezo con una revisión histórica de los pronósticos en economía, en la que indago sobre sus inicios y desarrollos recientes. Más adelante expongo de manera sucinta como los aportes teóricos sobre las expectativas y la incertidumbre influyen en los pronósticos. Para luego entender cómo se hacen predicciones en la práctica. La sección termina con una revisión de la literatura empírica sobre pronósticos inmediatos tradicionales y con aplicaciones de machine learning.

En el apartado metodológico, explico los distintos métodos que utilizo para realizar los pronósticos inmediatos, las fuentes de datos, las transformaciones efectuadas y la metodología para comparar los modelos. En términos generales, estimo los diferentes modelos y comparo la precisión de los pronósticos mediante la “Raíz del Error Cuadrático Medio (RMSE)”. Finalmente, en las últimas secciones, presento los resultados y conclusiones del estudio.

## **Capítulo 1. Marco teórico**

### **1.1. Pronósticos en economía**

De acuerdo con Elliott y Timmermann (2008), los pronósticos pueden verse en términos generales como el proceso de proporcionar información sobre valores futuros de una o más variables de interés. Para ello, se deben definir las variables de interés y el conjunto de información que contiene los datos conocidos que se considerarán para construir el pronóstico. Granger (2017) señala que proporcionar pronósticos oportunos y útiles es una de las tareas más relevantes de los economistas. Watson (2008) menciona que, en economía los pronósticos son conjeturas de los valores futuros de importantes variables económicas como el PIB, la inflación o la tasa de desempleo y que se construyen utilizando una variedad de métodos que pueden agruparse en cuatro categorías:

- a. Indicadores adelantados que pronostican el movimiento de la variable de interés antes de que ocurra, a través de un conjunto de variables clave relacionadas.
- b. Modelos econométricos que construyen pronósticos utilizando relaciones dinámicas sugeridas por la teoría económica y estimadas por métodos estadísticos.
- c. Modelos de series de tiempo que utilizan la correlación serial de las variables económicas para construir pronósticos.
- d. Modelos de juicio que son pronósticos basados en el juicio o experiencia de los pronosticadores profesionales.

#### **1.1.1 Breve historia de los pronósticos en economía**

Siguiendo a Köster, Lenel, y Fritsche (2020), “el estudio del ciclo económico desempeñó un papel importante en el desarrollo de los pronósticos en economía”. En la década de 1860 el médico y economista francés Clément Juglar estudió series de tiempo de datos económicos e identificó un ciclo de aproximadamente diez años de duración. Juglar distinguió diferentes fases de las fluctuaciones económicas, abandonando así la noción tradicional de eventos y choques aleatorios como la única causa de las crisis económicas. “Numerosas crisis a finales del siglo XIX y principios del XX parecieron dar testimonio del carácter periódico de las fluctuaciones económicas, lo que llevó a los economistas y empresarios a estudiar los ciclos económicos de una manera más sistemática” (Köster, Lenel, y Fritsche 2020).

Según Carnot et al (2011), los pronósticos económicos surgen a finales de los años treinta. El objetivo práctico era proporcionar nuevas herramientas económicas a los responsables de la formulación de políticas, en forma de instrumentos para evaluar la situación cíclica y medir el

impacto sobre la actividad agregada de sus posibles decisiones. El objetivo científico era probar la relevancia empírica de las teorías económicas, en particular la síntesis keynesiana que estaba despegando en ese momento, utilizando datos estadísticos generados por los incipientes sistemas de cuentas nacionales. “Los pronósticos estaban destinados a desempeñar el papel que juegan los experimentos en las ciencias duras: invalidar el modelo subyacente si no es confiable, o corroborarlo cuando sea acertado” (Carnot et al. 2011).

De acuerdo con Marion (2020), el keynesianismo difundió la idea de una controlabilidad de la economía y se generalizó el intervencionismo económico. Dos décadas de crecimiento económico relativamente estable desde fines de 1940, llevaron a los economistas de 1960 a preguntarse si la teoría del ciclo económico era obsoleta. Los economistas comenzaron a modelar la economía como un sistema de ecuaciones económicas simultáneas con choques estocásticos y fluctuaciones económicas que surgen endógenamente. Este procedimiento prometía producir conocimientos futuros de la economía, que parecían necesarios en un momento de creciente búsqueda de asesoramiento y planificación de la política económica.

Sin embargo, en la década siguiente la macroeconomía keynesiana fue atacada, los críticos la culpaban del fenómeno de la estanflación, como se denominó a la coexistencia aparentemente paradójica del estancamiento económico y una alta tasa de inflación (Köster, Lenel, y Fritsche 2020). Siguiendo a Watson (2008), los pronósticos empezaron a fallar en la década de 1970, lo que llevó a los investigadores a cuestionar tanto la teoría económica utilizada en los modelos como los procedimientos estadísticos utilizados. Un aporte teórico fundamental se da en 1976 con la llamada Crítica de Lucas. De acuerdo con Ljungqvist (2008), Robert Lucas critica el uso de modelos econométricos para pronosticar los efectos de adoptar una nueva política, porque los coeficientes estimados no son invariantes, sino que cambiarán junto con las reglas de decisión de los agentes en respuesta a una nueva política.

En ese sentido, el pobre desempeño predictivo de muchos modelos macro en la década de 1970 apoyó esta cuestión conceptual y condujo al desarrollo de los modelos de vectores autorregresivos (VAR) y luego a los modelos de equilibrio general dinámico estocástico (DSGE). Sims (1980) critica los modelos macro por no poder predecir la actividad económica y la inflación frente a las crisis del petróleo en la década de 1970. Además, argumenta que la identificación de estos modelos se basó en restricciones que no surgieron de la teoría económica o de los hechos institucionales. Sims propone como alternativa los VAR para estudiar datos y relaciones económicas sin imponer restricciones, el modelo se utiliza para obtener la función impulso respuesta de las variables económicas ante choques.

Otra respuesta al pobre desempeño de los grandes modelos macro fue la construcción de modelos estructurales basados en fundamentos microeconómicos (Chauvet y Potter 2013). Kydland y Prescott (1982) proponen el modelo Real Business Cycle (RBC) basado en los principios de los modelos de crecimiento neoclásicos, en los que los choques reales son fuentes de fluctuaciones económicas bajo precios flexibles y asume que las decisiones de optimización de los agentes siguen expectativas racionales y dinámicamente consistentes. Utilizando un marco similar, entre 1990 y 2000 aparecen los modelos DSGE, que se han convertido en el caballo de batalla de la macroeconomía convencional y que en la actualidad constituyen el paradigma dominante (De Vroey 2016). “Los modelos DSGE forman una clase de modelos que han demostrado ser particularmente populares entre los bancos centrales y los investigadores económicos que buscan bases económicas más sólidas para sus modelos de pronóstico” (Graham Elliott y Timmermann 2016a). Siguiendo a estos autores, los DSGE incorporan la optimización intertemporal de decisiones de hogares y empresas y las combinan con reglas de decisión de política monetaria y fiscal junto con supuestos sobre shocks a la tecnología y a la política monetaria y fiscal. Entonces, al apoyarse en gran medida en la teoría económica, estos modelos deberían asegurar buenos pronósticos.

No obstante, “los modelos DSGE hacen supuestos simplificadores en su representación de la dinámica económica, e inevitablemente esto puede afectar adversamente los pronósticos resultantes” (Graham Elliott y Timmermann 2016a). De hecho, varios estudios empíricos han encontrado que los pronósticos DSGE con frecuencia son superados por los pronósticos de encuestas o incluso por modelos simples de series de tiempo. Según Del Negro y Schorfheide (2013) la evidencia empírica sugiere que los pronósticos del modelo DSGE son comparables a los modelos de vectores autorregresivos (VAR), pero pueden ser superados por modelos de series de tiempo univariados o multivariados más sofisticados. No obstante, destacan que los DSGE presentan ventajas en relación con los otros modelos al utilizarlos como herramientas para analizar el efecto sobre cambios en la política económica.

De acuerdo con Chauvet y Potter (2013), el hallazgo general de la literatura es que los pronósticos del DSGE son comparables o ligeramente superiores a los obtenidos con los VAR, pero no significativamente diferentes con respecto a los procesos autorregresivos simples. También señalan que existe una gran diferencia en el rendimiento de las previsiones a lo largo de las fases del ciclo económico. En particular, es mucho más difícil pronosticar el crecimiento de la producción durante las recesiones que durante las expansiones. Aquí es importante reflexionar sobre qué tipo de modelo utilizar, uno para hacer pronósticos o uno

para evaluar cambios en la política económica. Hevia (2017) sugiere que “si queremos predecir en un contexto de incertidumbre, pero sin grandes cambios estructurales en la economía, no es necesario usar modelos con fundamentos microeconómicos o internamente consistentes. Regresiones de series de tiempo de una o más variables son suficientes”

Con todos los avances en las técnicas de pronóstico, sería razonable esperar que los pronósticos hayan mejorado con el tiempo. Sin embargo, Sinclair (2020) señala que hay poca evidencia de una mejora sustancial, particularmente en predecir recesiones, un ejemplo es la crisis financiera mundial de 2008 que tomó por sorpresa a los pronosticadores económicos. Por su parte, Carnot et al. (2011) señalan que muchas cosas han cambiado desde los primeros días de la previsión económica. Una es que ha quedado claro que pronosticar la economía no puede ser tan seguro como predecir la trayectoria de objetos inanimados utilizando las leyes de la física, ya que abundan las incertidumbres, algunas cuantificables y otras no.

## **1.2. El rol de las expectativas y la incertidumbre**

Siguiendo a Beckert (2016), dentro de las ciencias sociales, la economía es la disciplina en la que las expectativas juegan un papel más importante. Blanchard (2021) señala que, hasta la década de 1970, los macroeconomistas pensaban en las expectativas de una de dos maneras: 1) como espíritus animales, una expresión que Keynes introdujo en la Teoría General para referirse a los movimientos en la inversión que no podían explicarse por los movimientos en las variables actuales y 2) como expectativas adaptativas donde los agentes forman sus expectativas con la información del pasado.

Sin embargo, “a principios de la década de 1970, un grupo de macroeconomistas encabezado por Robert Lucas y Thomas Sargent argumentó que estos supuestos no hacen justicia a la forma en que la gente forma sus expectativas” (Blanchard 2021). Según estos autores, se debería asumir que las personas tienen expectativas racionales, que miran hacia el futuro y hacen lo mejor que pueden para predecirlo. Cómo los agentes forman las expectativas todavía es una cuestión muy debatida en economía, no obstante, la teoría de las expectativas racionales (RET) es el enfoque principal que utiliza la macroeconomía moderna para comprender cómo se percibe el futuro (Beckert 2016).

### **1.2.1 Expectativas racionales**

Con base en esta teoría, “las expectativas de las personas son predicciones informadas de eventos futuros y esencialmente iguales a las predicciones de la teoría económica relevante, además cualquier error en estas predicciones es esencialmente aleatorio” (Muth 1961, 316).

Bajo estas condiciones, el futuro puede predecirse, de hecho, es simplemente la sombra estadística del pasado (Davidson 2010, 17). Por ejemplo, la mejor predicción de la inflación de un agente se puede representar en la siguiente ecuación. Donde  $\pi^*$  es la expectativa racional de la inflación y  $\epsilon$  es el término de error aleatorio, que tiene un valor esperado de cero y es independiente de  $\pi^*$ :

$$\pi = \pi^* + \epsilon$$
$$\mathbb{E}(\pi) = \pi^*$$

Como afirma Sargent (2017), la RET tiene importantes implicaciones para la política económica, los agentes racionales no pueden ser engañados y cualquier política pública que intente manipular la economía haciendo que el público tenga sistemáticamente falsas expectativas está condenada al fracaso. Por ejemplo, los hogares pueden anticipar un aumento en el gasto público y predecir que los impuestos subirán en el futuro para pagar el déficit. Como resultado, los hogares reducirían sus propios gastos para ahorrar para los impuestos más altos por lo que esa acción frustraría el impacto expansivo del aumento del gasto público (Mitchell, Wray, y Watts 2019, 281).

### **1.2.2 Crítica a las expectativas racionales**

La RET ha sido cuestionada sobre todo por su historial para hacer predicciones correctas. Frydman y Goldberg (2007) mencionan que un supuesto problemático en la RET es el de la aleatoriedad de los errores, esta crítica ganó terreno significativo después de la crisis financiera de 2008 donde los actores económicos se equivocaron sistemáticamente, causando errores altamente correlacionados que fueron cualquier cosa menos aleatorios (Frydman y Goldberg 2007). Según Akerlof y Shiller (2009) “la macroeconomía ortodoxa ha impuesto una estructura y una disciplina de investigación que se basa en cómo sería el comportamiento de la economía si la gente solamente tuviera motivaciones económicas y su comportamiento fuera completamente racional”. Sin embargo, quienes toman las decisiones económicas suelen ser intuitivos, emocionales e irracionales, es decir, se guían por lo que Keynes denominó como “espíritus animales”.

En ese sentido, Akerlof y Shiller (2009) destacan que la teoría convencional ignora que la confianza o la falta de ella puede impulsar u obstaculizar el crecimiento económico. Que el sentido de justicia importa mucho en la fijación de salarios. Que la gente tiende a llegar a conclusiones irracionales sobre el dinero, por ejemplo, ignoran la inflación y creen que sus ahorros mantienen su valor. Y que la corrupción puede contribuir a las depresiones

económicas. Para los autores, todas estas supresiones de la explicación convencional sobre cómo funciona la economía son las principales causas de las crisis y sugieren que es necesario cambiar la teoría de los mercados racionales, eficientes y que se corrigen a sí mismos y prestar la debida atención a los espíritus animales.

Keen (2021) menciona que el significado de “racional” está más cerca de la definición del diccionario de “profético” y que cualquiera que acepte la definición neoclásica de “racional” ha perdido, hasta cierto punto, el contacto con la realidad. Para Keen, la economía abunda en suposiciones demasiado fantásticas y ha estado, una y otra vez, sujeta a anomalías que desafían el paradigma, pero en lugar de aceptar el desafío, los economistas han respondido haciendo suposiciones ridículas para proteger el paradigma de la crítica. El autor es muy crítico no solo de la RET sino de todo el paradigma ortodoxo, “considera a la economía neoclásica no solo como una mala metodología para el análisis económico, sino como una amenaza existencial para la existencia continua del capitalismo y la civilización humana en general” (Keen 2021). Cabe destacar que Steve Keen forma parte de un pequeño grupo de especialistas que predijeron la crisis de 2008.

### **1.2.3 Incertidumbre**

Para Beckert (2016), otro argumento en contra de la teoría de las expectativas racionales es que en condiciones de incertidumbre las expectativas son contingentes, es decir, más que ser pronósticos racionales son apuestas sobre un futuro que aún no se conoce. De acuerdo con King y Kay (2020) y Pilmis (2020) la incertidumbre se puede analizar desde al menos tres puntos de vista. Primero, la incertidumbre surge de las cualidades no observables de los bienes y productos. Akerlof (1970) muestra que la información asimétrica, puede conducir a una subóptima calidad y, eventualmente, al colapso de los mercados.

En segundo lugar, los actores “limitadamente racionales” enfrentan dificultades para analizar situaciones complejas y por lo tanto para discernir soluciones óptimas. La incertidumbre aquí surge de las capacidades computacionales limitadas de los actores: incapaces de alcanzar la “mejor” solución, los actores económicos buscan soluciones “satisfactorias”, en lugar de “optimizadoras” (Pilmis 2020).

En tercer lugar, la incertidumbre como una propiedad común de las situaciones del “mundo real”, donde es fundamental la distinción clásica de Knight (1921) entre el “riesgo” medible (que permite calcular las probabilidades) y la “incertidumbre” inconmensurable o radical (donde las probabilidades no se pueden calcular porque cada situación es única). Keynes

(1936) también vio la incertidumbre como una característica central de la vida económica. “El conocimiento de los factores que regirán el rendimiento de una inversión dentro de algunos años suele ser muy escaso y, a menudo, insignificante, ya que nuestro conocimiento existente no proporciona una base suficiente para una expectativa matemática calculada, simplemente no sabemos” (Keynes 1936).

Sin embargo, las ideas de Knight y Keynes de que las decisiones se basan en expectativas que no pueden calcularse racionalmente va en contra de la teoría económica dominante. Según Davidson (1996), la teoría económica neoclásica se basa en lo que Paul Samuelson ha llamado una visión ergódica” del mundo; es decir, la suposición de que la realidad está predeterminada y puede describirse completamente mediante funciones de probabilidad condicional objetivas inmutables. Si asumimos que el futuro es “ergódico” o “simplemente la sombra estadística del pasado”, entonces las expectativas pueden basarse legítimamente en probabilidades calculadas y se puede esperar que las presiones competitivas eliminen los errores sistemáticos de pronóstico (Davidson 2010).

### **1.3. Pronósticos en la práctica**

Blanchard (2021) destaca que en la actualidad la mayoría de los macroeconomistas utilizan expectativas racionales como supuesto en sus modelos y análisis de políticas. Pero no es porque crean que las personas realmente tienen expectativas racionales, pues seguramente hay momentos en que las expectativas adaptativas pueden ser una mejor descripción de la realidad. Sin embargo, al pensar en los efectos probables de una política económica específica, la mejor suposición que se puede hacer es que los mercados, las personas y las empresas harán todo lo posible para resolver las implicaciones de esa política.

Según Blanchard, está claro que el supuesto de expectativas racionales exagera la capacidad de las personas y las empresas para pensar en el futuro y que tenemos que ir más allá de este supuesto. De hecho, el mismo Robert Lucas dijo que la RET no es aplicable “en situaciones en las que uno no puede adivinar qué frecuencias observables son relevantes, situaciones que Knight llamaría incertidumbre” (Lucas 1983). Blanchard menciona que gran parte de la investigación actual se centra en cómo tener en cuenta algunos de los límites y sesgos conductuales que determinan cómo las personas forman expectativas. Sin embargo, aún no existe una alternativa viable y confiable y, por el momento, las expectativas racionales siguen siendo el supuesto predeterminado de la mayoría de los modelos macroeconómicos.

En ese sentido, las expectativas racionales son un supuesto clave para simplificar y hacer pronósticos en la práctica. Entonces utilizando este supuesto, no tan realista pero sí útil, se puede seguir un marco común como el que señala Watson (2008) donde los pronósticos se pueden derivar de conceptos elementales de la teoría de la probabilidad. Partiendo de que  $y_{T+1}$  es la variable por pronosticar y  $X_T$  es el conjunto de variables a utilizar. Una función  $f(X_T)$  sería el pronóstico de  $y_{T+1}$  construido a partir de  $X_T$ , donde buenas elecciones de  $f(\cdot)$  conducen a pronósticos más precisos. Una medida del error del pronóstico sería:

$$e_{T+1} = y_{T+1} - f(X_T)$$

Otra medida puede ser el error cuadrático medio:

$$ECM = E(e_{T+1}^2 | X_T)$$

“Un resultado fundamental de la teoría de la probabilidad es que el *ECM* se minimiza usando  $f(X_T) = E(y_{T+1} | X_T)$ ” (Watson 2008). No obstante, el autor destaca que, en la práctica, esta función debe estimarse utilizando datos muestrales. Entonces, al incluir muchas variables en  $X_T$  significa que se deben estimar muchos parámetros y estimar una gran cantidad de parámetros conduce a un mayor error de estimación lo que aumenta el *ECM*. Esto se traduce en uno de los principales problemas prácticos al hacer pronósticos, un trade-off entre incluir más variables en  $X_T$  para capturar más información sobre  $y_{T+1}$  y el mayor error estadístico asociado con la estimación de parámetros adicionales.

En ese sentido, Elliott y Timmermann (2016) mencionan que la teoría económica puede proporcionar una guía sobre qué variables considerar en la selección del modelo. Por ejemplo, la teoría del equilibrio general puede sugerir que los factores que determinan las condiciones de primer orden de los hogares y las empresas deberían influir en la dinámica económica. La teoría también puede ayudar a identificar la naturaleza de los shocks (por ejemplo, shocks tecnológicos o políticas del gobierno) que afectarán más el crecimiento económico.

Por último, Carnot et al. (2011) señalan que las variables económicas tienden a rebotar especialmente en horizontes cortos, por lo que el desafío del pronosticador es dar sentido a estos movimientos para predecir hacia dónde se dirigen las economías, ya sea en el curso del ciclo o en el largo plazo. Los pronósticos sirven a los responsables de las políticas económicas nacionales e internacionales, pero también a las empresas privadas y los hogares. “Ex post, las previsiones suelen resultar erróneas, a veces por grandes márgenes. Aun así, son indispensables ex ante, para proporcionar un marco cuantificado para la toma de decisiones ante un mundo incierto” (Carnot et al. 2011).

## **1.4. Nowcasting o pronósticos inmediatos**

Las innovaciones y refinamientos en los pronósticos no se detienen y hacer pronósticos en “tiempo real” o del presente es una cuestión que ha despertado el interés de muchos investigadores. “Los modelos de factores dinámicos (DFM) han surgido como una alternativa interesante para el pronóstico actual de la actividad real, ya que permiten extraer información de grandes conjuntos de datos de manera parsimoniosa” (Bańbura y Rünstler 2011). Otros avances en los métodos de pronóstico incluyen modelos de frecuencia mixta. “La idea es explorar información en indicadores más oportunos que estén disponibles con mayor frecuencia para mejorar el pronóstico del crecimiento de la producción presente” (Chauvet y Potter 2013b). Estos avances pertenecen a la literatura de lo que se conoce como nowcasting. “Nowcasting se define como la predicción del presente, el futuro muy cercano y el pasado muy reciente. El término es una contracción de now y forecasting y se ha utilizado durante mucho tiempo en meteorología y recientemente también en economía” (Bańbura et al. 2013). Siguiendo a Bańbura, Giannone, y Reichlin (2011) el nowcasting es particularmente relevante para aquellas variables macroeconómicas que se recopilan con baja frecuencia, generalmente de forma trimestral, y que se publican con un retraso sustancial. Para obtener “estimaciones tempranas” de estos indicadores económicos clave, se utiliza la información de los datos que están relacionados con la variable objetivo pero que se recopilan y publican con mayor frecuencia por ejemplo de manera mensual.

Bańbura et al. (2013) revisan la literatura sobre los modelos de nowcasting y plantean cuatro conclusiones generales. En primer lugar, destacan que las ganancias en los pronósticos son sustanciales solo en horizontes cortos. En segundo lugar, que funcionan tan bien como los pronósticos tradicionales. En tercer lugar, que los nowcasts se vuelven progresivamente más precisos a medida que se incorporaran nuevos datos tan pronto como se publican. Por último, señalan que la relevancia de varios tipos de datos no solo está determinada por la fuerza de su relación con la variable objetivo, sino también por su periodicidad.

### **1.4.1 Nowcasting con machine learning**

De acuerdo con Gogas y Papadimitriou (2021) el término machine learning (ML) fue introducido en 1959, principalmente para describir las tareas de reconocimiento de patrones en los sistemas pioneros de Inteligencia Artificial (AI). Por su parte, el ML aplicado a problemas económicos se remonta a finales de la década de 1970. Los autores dicen que, en un inicio se aplicó para pronosticar series de tiempo financieras. Hoy en día existen múltiples

aplicaciones macroeconómicas o microeconómicas, pero donde el ML ha sido especialmente útil, tiene que ver con los pronósticos, en los que parecen muy exitosos en comparación con los modelos empíricos tradicionales.

Con respecto al nowcasting, Bolhuis y Rayner (2020) señalan que las técnicas de ML pueden mejorar el rendimiento de las previsiones ya que las técnicas basadas en mínimos cuadrados ordinarios (MCO) luchan por superar varios problemas, incluida la colinealidad, la dimensionalidad, la relevancia del predictor y la no linealidad. “Como resultado, incluso los modelos más avanzados a menudo dan como resultado grandes errores de pronóstico, especialmente cuando la variable que se va a predecir es volátil, como el crecimiento de la producción en muchas economías emergentes y en desarrollo” (Bolhuis y Rayner 2020).

### **1.5. Pronósticos en Ecuador**

En Ecuador, la elaboración de pronósticos de variables macroeconómicas recae principalmente en dos instituciones: el Banco Central del Ecuador (BCE) y el Ministerio de Economía y Finanzas (MEF). Estas entidades, de acuerdo con lo establecido en el Código Orgánico Monetario y Financiero (COMF) y el Código Orgánico de Planificación y Finanzas Públicas (COPLAFIP), son responsables de realizar las proyecciones macroeconómicas oficiales que guían la política económica del país. Estas proyecciones incluyen estimaciones sobre la evolución del PIB, la inflación, el sector fiscal, entre otras variables clave.

El BCE y el MEF emplean una variedad de métodos econométricos y modelos estáticos de simulación para realizar estas proyecciones. De acuerdo con diferentes informes de “Programación Macroeconómica”, entre los modelos más utilizados destacan:

- Modelos de Vectores Autorregresivos Aumentados por Factores (FAVAR), que combinan análisis de componentes principales con modelos de vectores autorregresivos (VAR).
- Modelos de estado-espacio, que utilizan el Filtro de Kalman para resolver ecuaciones dinámicas y generar proyecciones macroeconómicas ajustadas.
- Modelos univariados, que siguen la metodología Box-Jenkins, aplicada a series temporales, lo que incluye procesos autorregresivos y de media móvil.

Además, los modelos estáticos de simulación se utilizan principalmente para realizar análisis de impacto en variables exógenas, como exportaciones, consumo, inversión y gasto público, a través de modelos de demanda de Leontief y oferta de Gosh, apoyados en la Matriz Insumo-Producto del BCE.

Sin embargo, los pronósticos macroeconómicos en Ecuador enfrentan importantes desafíos. La principal limitación es la disponibilidad reducida de datos históricos debido a cambios estructurales en la economía, como la adopción de la dolarización en el año 2000 y revisiones metodológicas en estadísticas clave como las del sector fiscal y empleo. Estas limitaciones reducen el número de observaciones disponibles para construir modelos, lo que afecta la capacidad predictiva de los modelos utilizados por el BCE y el MEF (Soria et al. 2023)

Por otro lado, la precisión de los pronósticos también se ve afectada por la volatilidad económica que caracteriza a las economías emergentes como la ecuatoriana. El crecimiento del PIB en Ecuador está sujeto a fluctuaciones abruptas debido a factores externos, como la evolución de los precios del petróleo, que es un componente fundamental de la balanza comercial del país. Esto añade una capa adicional de dificultad en los pronósticos, lo que a menudo resulta en errores significativos entre las estimaciones y los datos observados.

#### **1.6. Revisión de la literatura empírica**

En la primera parte de esta sección reviso trabajos aplicados en países en desarrollo con especial énfasis al caso ecuatoriano. En la segunda parte repaso trabajos empíricos que utilizan técnicas de ML. Cabe destacar que, la literatura es más limitada para países en desarrollo pues no hay tantas aplicaciones como en la primera parte de esta sección.

Manuelito (2017) analiza el uso de la metodología de nowcasting aplicada a los países de América Latina y el Caribe con el objetivo de generar pronósticos trimestrales de crecimiento del PIB más precisos. Los resultados muestran que, a corto plazo, esta metodología produce estimaciones precisas y confiables, aunque los resultados a nivel de país dependen mucho de la cantidad y calidad de los datos disponibles, así como de su oportunidad. Mientras que, Dahlhaus, Guénette, y Vasishtha (2017) utilizan modelos de factores dinámicos (DFM) para pronosticar ahora el crecimiento del PIB real de Brasil, Rusia, India, China y México. En general, encuentran que los DFM muestran una buena precisión y brindan pronósticos inmediatos confiables para el crecimiento del PIB.

Por su parte, Caruso (2018) propone un modelo de nowcasting para predecir el PIB de México con indicadores mexicanos y estadounidenses. El modelo produce pronósticos que tienen una mayor precisión que las encuestas de pronosticadores profesionales y muestra la gran relevancia de los datos de Estados Unidos en el proceso de actualización de pronósticos a corto plazo en economías pequeñas y abiertas. En el contexto de la pandemia, Sampi y Jooste (2020) proponen un indicador adelantado para predecir las tasas mensuales de

crecimiento de la producción industrial en economías seleccionadas de América Latina y el Caribe. El índice se construye utilizando la base de datos movilidad comunitaria de Google. Los resultados del ejercicio sugieren que este enfoque supera a los modelos AR en cuanto a pronósticos fuera de la muestra.

Entre los trabajos aplicados al caso ecuatoriano tenemos el de Liu, Matheson, y Romeu (2012) quienes utilizan cinco modelos para diez países de América Latina y entre otras cosas encuentran que los modelos que usan datos mensuales generalmente superan al modelo AR que usa solo datos trimestrales, además los pronósticos se vuelven más precisos a medida que llega más información. En segundo lugar, que el DFM produce pronósticos más precisos en relación con otras especificaciones consideradas. Por último, destacan que los indicadores externos, como los precios de las materias primas y las variables de Estados Unidos, son útiles para mejorar la precisión del pronóstico para la mayoría de los países latinoamericanos.

Por su parte, Casares (2017) considera 8 variables macroeconómicas entre las que incluye importaciones, depósitos a la vista, cuasidinero y gasto público. El modelo de nowcasting que propone sigue un procedimiento de dos pasos. Primero calcula los factores de las variables macroeconómicas mediante el análisis de componentes principales. Luego utiliza estos factores en un modelo de regresión donde la variable dependiente es la tasa de crecimiento del PIB. El modelo puede “generar proyecciones con 50 días de anticipación respecto a la publicación oficial del Banco Central” (Casares 2017).

Por otro lado, González-Astudillo y Baquero (2019) proponen un DFM con 30 variables macroeconómicas y financieras. La novedad de este trabajo es que el modelo incluye un intercepto variable en el tiempo que produce mejores pronósticos frente a un modelo que supone una tasa media constante de crecimiento del PIB real. Los autores mencionan que “el modelo puede ser adecuado para las economías en desarrollo que carecen de información macroeconómica oportuna y experimentan períodos sostenidos de crecimiento del PIB real bajo o alto” (González-Astudillo y Baquero 2019).

Mientras que Yaselga (2019) construye un modelo de factores dinámicos para el crecimiento del PIB con 11 variables macroeconómicas desde 2007 hasta 2016. Por último, un trabajo reciente de López, Yaselga, y Espinosa (2021) propone dos modelos nowcast mediante factores dinámicos y sugieren que la combinación de estimaciones conduce a mejoras en la precisión del pronóstico, lo que representa una mejora frente a un modelo único.

Una característica en común de estos trabajos aplicados en Ecuador es que utilizan modelos de factores dinámicos y como sugieren Bolhuis y Rayner (2020) este tipo de modelos tienen deficiencias cuando se trata de pronosticar el PIB de economías en desarrollo. De hecho, en el trabajo de López, Yaselga, y Espinosa (2021) una de las recomendaciones para futuras investigaciones, “es explotar la información proveniente de algoritmos de machine-learning, con lo que se podría actualizar con mayor periodicidad las estimaciones de crecimiento”

En ese sentido, Richardson, van Florenstein Mulder, y Vehbi (2020) evalúan el rendimiento en tiempo real de los algoritmos populares de ML para obtener nowcasts del crecimiento del PIB real de Nueva Zelanda. Los autores estiman varios modelos de ML durante el período 2009-2019 utilizando un conjunto de aproximadamente 600 variables nacionales e internacionales. Luego comparan los pronósticos obtenidos de estos modelos frente a la precisión de un simple AR y concluyen que todos los modelos ML pudieron producir pronósticos más precisos que los modelos tradicionales.

En un trabajo aplicado en Suecia, Jönsson (2020) investiga si las técnicas de ML, más específicamente el algoritmo del vecino más cercano, se pueden utilizar para pronosticar el crecimiento del PIB sueco utilizando datos de encuestas de opinión empresarial. Los resultados muestran que el algoritmo puede funcionar al menos tan bien como los modelos lineales. En trabajos más recientes, Yoon (2021) utiliza algoritmos de ML para pronosticar el crecimiento del PIB real de Japón y como punto de comparación utiliza las previsiones del Fondo Monetario Internacional (FMI) y el Banco de Japón. Este estudio encuentra que el uso de algoritmos de ML mejora los pronósticos y recomienda el aumento del uso de este tipo de modelos en la previsión macroeconómica. Soybilgen y Yazgan (2021) utilizan modelos de aprendizaje automático, en específico algoritmos de árboles y los resultados muestran que los modelos de ML superan a los modelos de factores dinámicos lineales.

Entre los trabajos aplicados a economías emergentes tenemos el de Cepni, Güney, y Swanson (2019), estos autores utilizan técnicas de ML para reducir las dimensiones de los datos y encuentran que producen predicciones superiores en relación con los modelos econométricos lineales de referencia. En otro trabajo aplicado a economías en desarrollo, Ranjan y Ghosh (2021) utilizan algunos métodos de ML junto con modelos de series de tiempo convencionales. Los resultados sugieren que una mejora en los pronósticos inmediatos del PIB al utilizar tanto métodos de aprendizaje automático como datos no convencionales. Por último, en un trabajo reciente aplicado a Belice y El Salvador, Barrios et al. (2021) muestran que las técnicas de aprendizaje automático pueden producir pronósticos de PIB trimestrales

precisos para dos economías diferentes dentro de contextos económicos marcados por grados extremos de volatilidad e incertidumbre tanto a nivel nacional como internacional.

La revisión teórica me permite concluir que los pronósticos son una parte medular de la economía. Estas conjeturas sobre valores futuros son inherentes a todos los agentes económicos, por ejemplo, los consumidores estarán pensando en cuanto consumir o ahorrar mañana o el próximo mes. Las firmas pronosticando los retornos de una inversión y los hacedores de política previendo cuánto crecerá la economía. Si bien las expectativas y la incertidumbre juegan un rol importante a la hora de hacer pronósticos, en la práctica es común utilizar supuestos simplificadores que dan “buenos” resultados a pesar de ser criticados. A partir de los años treinta, economistas, matemáticos, estadísticos y otros profesionales, han perfeccionado múltiples métodos para hacer predicciones. La literatura muestra que la rama de los pronósticos inmediatos o nowcasting puede ser bastante útil para estimar el crecimiento del PIB en “tiempo real” para atenuar el retraso en las publicaciones oficiales. Además, el uso de técnicas de machine learning puede mejorar todavía más los pronósticos inmediatos.

## Capítulo 2. Marco metodológico

En la primera parte de este capítulo presento los métodos que voy a utilizar para realizar los pronósticos. Luego describo las variables a utilizar, las fuentes de donde obtengo los datos y el proceso de transformación de los datos. Por último, expongo la metodología que utilizo para comparar los diferentes modelos.

### 2.1. Revisión de los métodos

#### 2.1.1. ARIMA

Siguiendo a Harvey (2006), un modelo de orden (p, d, q) de promedio móvil integrado autorregresivo es aquel en el que las observaciones siguen un proceso ARMA (p, q) estacionario e invertible después de haber sido diferenciadas d veces.

$$y_t = \theta_0 + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \xi_t + \theta_1 \xi_{t-1} + \dots + \theta_q \xi_{t-q}$$

Donde  $\phi_1, \dots, \phi_p$  son los coeficientes autorregresivos,  $\theta_1, \dots, \theta_q$  son los coeficientes de las medias móviles. De acuerdo con Elliott y Timmermann (2016b), los modelos ARIMA univariados han sido durante mucho tiempo el caballo de batalla en la previsión aplicada. Siempre que la duración de los rezagos se elija de manera razonable, los pronósticos ARIMA a menudo son difíciles de superar empíricamente para muchas variables macroeconómicas. El éxito de los modelos ARIMA se debe en gran medida a su sencillez de uso; estos modelos son fáciles de estimar e imponen requisitos mínimos en el conjunto de información utilizado.

#### 2.1.2. Machine Learning

Siguiendo a (Rebala, Ravi, y Churiwala 2019), “el ML es un campo de la informática que estudia algoritmos y técnicas para automatizar soluciones a problemas complejos que son difíciles de programar utilizando métodos de programación convencionales”. ML puede proporcionar información sobre estructuras y patrones dentro de grandes conjuntos de datos. Algunos ejemplos de problemas donde se puede aplicar ML incluyen: clasificar algo en una o más categorías (clases). Por ejemplo, identificar si un correo electrónico es spam o no. También se usa para crear modelos aprendiendo de conjuntos de datos existentes para pronosticar resultados o comportamientos. Por ejemplo, la demanda de un producto en particular durante la temporada navideña.

#### 2.1.3. Ridge, lasso y elastic net

Los métodos de regresión de ridge, lasso y red elástica son técnicas de regularización de uso común para ayudar a reducir la complejidad del modelo cuando tenemos una gran cantidad de

variables en nuestro conjunto de datos (Richardson, van Florenstein Mulder, y Vehbi 2020). La regresión ridge reduce los coeficientes de cada una de las características en el conjunto al imponer una penalización a su tamaño en forma de regularización, donde la penalización está en la magnitud al cuadrado de los coeficientes:

$$\beta = \operatorname{argmin} \left[ \sum_{i=1}^l \left( y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right]$$

La regresión lasso es muy similar a la ridge, excepto que utiliza una penalización igual al valor absoluto de la magnitud de los coeficientes. El coeficiente de los parámetros también se puede llevar a cero durante el proceso de regularización:

$$\beta = \operatorname{argmin} \left[ \sum_{i=1}^l \left( y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \lambda \sum_{j=1}^p |\beta_j| \right]$$

La regresión de red elástica contiene el parámetro de penalización como una suma de las penalizaciones de ridge y lasso, y los pesos relativos de las dos penalizaciones se determinan mediante una variable de ajuste adicional  $\alpha$ :

$$\beta = \operatorname{argmin} \left[ \sum_{i=1}^l \left( y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \lambda \sum_{j=1}^p (1 - \alpha) \beta_j^2 + (\alpha) |\beta_j| \right]$$

#### 2.1.4. Decision Tree Regression

Según Basuchoudhary, Bang, y Sen (2017), este algoritmo sirve para diagnosticar y predecir resultados mediante la división de manera óptima de la muestra en submuestras. Siguiendo a Sosa (2019), si tenemos un vector  $X$  de  $p$  variables con  $n$  observaciones, el algoritmo decide cual variable ( $j$ ) usar para la partición y que punto ( $s$ ) de esa variable usar para la partición:

$$\min_{j,s} \left[ \min_{c_1} \sum_{x_i \in R_1(j,s)} (y_i - c_1)^2 + \min_{c_2} \sum_{x_i \in R_2(j,s)} (y_i - c_2)^2 \right]$$

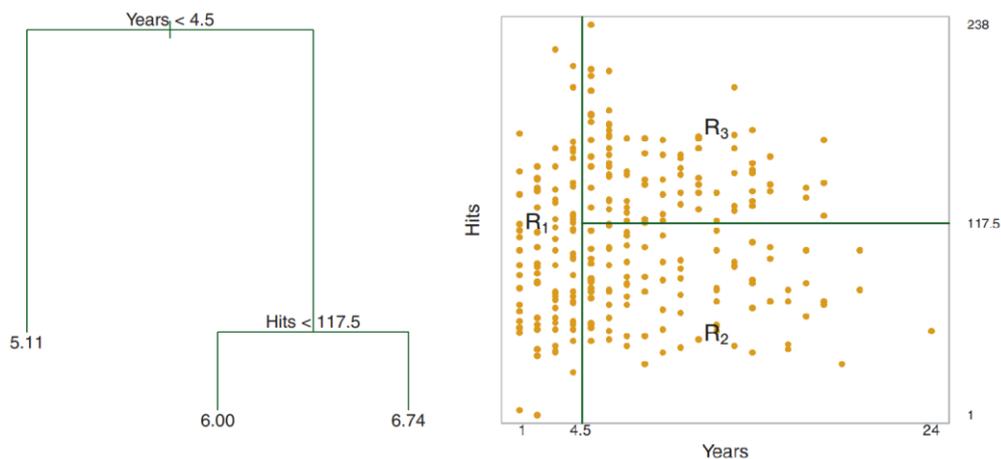
$$R_1(j, s) = \{X | X_j \leq s\} \text{ y } R_2(j, s) = \{X | X_j > s\}$$

Luego, “para cada variable de partición y punto de partición, la minimización interna se corresponde con las medias dentro de cada región. El proceso se repite dentro de las regiones y si el árbol final tiene  $M$  regiones” (Basuchoudhary, Bang, y Sen 2017).

$$\hat{y} = \sum_{m=1}^M \hat{c}_m I(x \in R_m)$$

Donde  $c_m$  es el promedio de los  $y_i$  para todas las observaciones en la región  $R_m$ . Un buen ejemplo para entender lo que hace el algoritmo es el presentado por James et al. (2013), los autores predicen el salario de un jugador de béisbol en función de “Years” (la cantidad de años que ha jugado) y los “Hits” (la cantidad de aciertos que hizo el jugador). En este caso, el árbol estratifica o segmenta a los jugadores en tres regiones: R1 jugadores que han jugado durante cuatro años o menos, R2 jugadores que han jugado durante cinco años o más y que hicieron menos de 118 aciertos el año pasado y R3 jugadores que han jugado durante cinco años o más y que hicieron al menos 118 hits el año pasado, como se observa en la parte derecha del Gráfico 1.

**Figura 2.1 Funcionamiento de los árboles**



*Fuente:* James et al. (2013)

Por su parte, la figura izquierda muestra un árbol de regresión ajustado a estos datos. La división superior asigna observaciones que tienen menos de 4,5 años a la rama izquierda, para tales jugadores el salario logarítmico predicho es de 5,11 que equivale a USD 165.174. Los jugadores con más de 4,5 años se asignan a la rama derecha y luego ese grupo se subdivide según un umbral de aciertos.

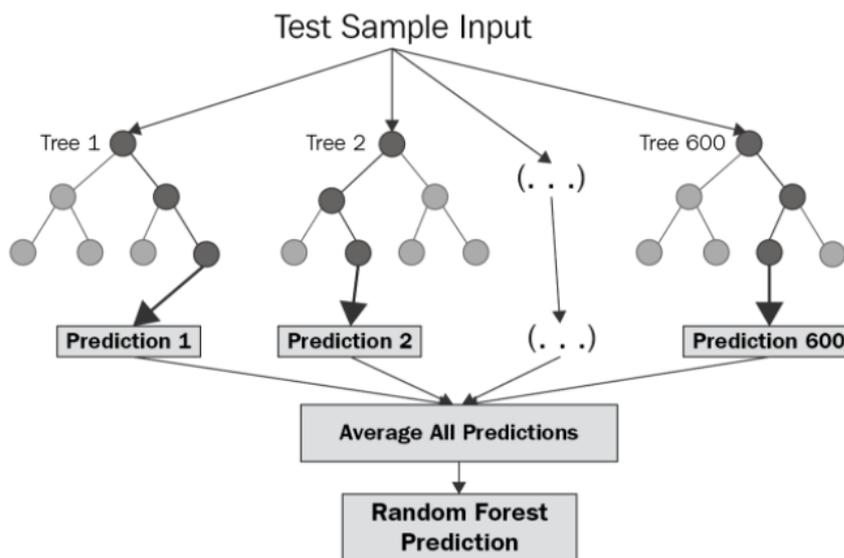
### 2.1.5. Random Forest

De acuerdo con James et al. (2013), “los árboles de decisión sufren de una gran variación, esto significa que si dividimos los datos en dos partes al azar y ajustamos un árbol a ambas mitades, los resultados que obtengamos podrían ser bastante diferentes”. En ese sentido, la combinación de árboles a menudo puede mejorar la precisión predictiva, la idea básica de

estos predictores es mejorar la fuerza predictiva de un “aprendiz débil” iterando el algoritmo del árbol muchas veces. El algoritmo random forest (RF) o bosques aleatorios funciona bajo esta lógica y opera construyendo varios árboles de decisión y generando la predicción a través de la media de todos los árboles, como muestra el Gráfico2. Siguiendo a Bakshi (2020), el procedimiento del RF consta de cuatro pasos:

1. Seleccionar al azar  $k$  puntos de datos.
2. Construir un árbol asociado a estos  $k$  puntos de datos.
3. Elegir el número  $N$  de árboles que desea construir y repetir los pasos 1 y 2.
4. Encontrar el pronóstico final con el promedio de todos los pronósticos anteriores.

**Figura 2.2. Funcionamiento del random forest**



*Fuente:* Bakshi (2020)

### 2.1.6. Support Vector Machine (SVM)

El algoritmo SVM construye hiperplanos para particionar combinaciones de variables explicativas y hace un pronóstico puntual para cada una de las secciones. En otras palabras, tiene como objetivo encontrar una función que tenga una desviación máxima  $\epsilon$  de los objetivos  $y_i$ , para todos los datos, mientras sea lo más plana posible. El término constante  $C$ , se conoce como parámetro de regularización y controla el equilibrio entre minimizar los errores y penalizar el sobreajuste (Richardson, van Florenstein Mulder, y Vehbi 2020).

$$\min \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*)$$

$$\text{suje}to\ a\ \begin{cases} y_i - (w, x_i) - b \leq \varepsilon + \xi_i \\ (w, x_i) + b - y_i \leq \varepsilon + \xi_i^* \end{cases}$$

### 2.1.7. Gradient Boosting, XGBoost y LGBM

Gradient Boosting (GB) es un método utilizado para construir un predictor de alta calidad a partir de una serie de modelos débiles individuales denominados “aprendices (learners)”.

Según Friedman (2001), estos algoritmos comienzan ajustando un modelo inicial  $f_1(x)$  para predecir  $y$ , luego se calculan los residuos  $y - f_1(x)$ . Después se ajusta un nuevo modelo  $f_2$ , que intenta corregir los errores del modelo  $f_1$ .

$$f_1(x) \approx y$$

$$f_2(x) \approx y - f_1(x)$$

A continuación, se calculan los residuos de los dos modelos de forma conjunta y se ajusta un tercer modelo  $f_3$  para tratar de corregirlos.

$$f_3(x) \approx y - f_1(x) - f_2(x)$$

Este proceso se repite  $N$  veces, de forma que el algoritmo asegura que cada nuevo modelo minimice los residuos del anterior. El algoritmo GB tiene varias versiones mejoradas y optimizadas, para la presente disertación utilizo dos de las más populares: eXtreme Gradient Boosting (XGBoost) y Light Gradient Boosting Machine (LGBM). En términos generales estas versiones adaptan el algoritmo GB para hacerlo más eficiente, flexible y portátil.

### 2.1.8. Interpretabilidad

Uno de los desafíos más importantes en el uso de métodos de aprendizaje automático es el dilema entre flexibilidad y la interpretabilidad de los modelos. En general, a medida que aumenta la flexibilidad de un modelo, es decir, su capacidad para adaptarse a diferentes formas o patrones complejos en los datos, la capacidad para interpretar cómo esos patrones generan las predicciones disminuye (James et al. 2013).

Los modelos inflexibles, como la regresión lineal, son fáciles de interpretar porque suposiciones como la linealidad hacen que la relación entre los predictores y la respuesta sea clara. Estos modelos generan una forma simple y restrictiva de la función  $f$ , como una línea recta o un plano, que es relativamente fácil de explicar y comprender.

Por el contrario, modelos flexibles, como las máquinas de soporte vectorial (SVM) o las redes neuronales profundas, pueden ajustarse a relaciones mucho más complejas y no lineales entre los predictores y la variable de respuesta. Sin embargo, esta flexibilidad conlleva una

desventaja: es difícil entender exactamente cómo cada predictor influye en el resultado final, lo que convierte a estos modelos en cajas negras.

**Figura 2.3. Interpretabilidad vs Flexibilidad**



*Fuente:* James et al. (2013)

Cuando la interpretación del modelo es crucial para la toma de decisiones, un modelo más restrictivo (menos flexible) puede ser preferible. Por ejemplo, en situaciones donde se busca entender cómo ciertos factores influyen en una variable económica, un modelo lineal permite extraer fácilmente conclusiones sobre la relación entre los predictores y el resultado. Pero en contextos donde la precisión del pronóstico es más importante que la interpretación, los modelos flexibles pueden ser una mejor opción. Esto sucede, por ejemplo, en la predicción del PIB a corto plazo. Modelos como las redes neuronales o SVM pueden generar pronósticos más ajustados, pero a expensas de una mayor complejidad y menor transparencia sobre cómo se generan esos resultados (James et al. 2013).

## **2.2. Datos y metodología**

La idea básica del nowcasting es explotar un conjunto diverso de información oportuna que está disponible antes del lanzamiento oficial de una variable objetivo. Como tal, la selección y transformación de datos es clave para el éxito de la predicción inmediata. Varios de los métodos explicados en la sección anterior, penalizan la introducción de variables adicionales y algunos de ellos tienen la capacidad de excluir completamente variables de la muestra y así reducir el tamaño del conjunto de datos original. Si bien esta es una característica importante

que facilita la tarea del pronosticador, la selección cuidadosa de variables oportunas e informativas sigue siendo fundamental para el nowcast.

En ese sentido la siguiente tabla resume las variables utilizadas en los modelos, la elección de estas se basa en las que se utilizaron en otros estudios aplicados al caso ecuatoriano y a la disponibilidad en fuentes oficiales como el Banco Central del Ecuador (BCE), el Instituto Nacional de Estadística y Censos (INEC), el Servicio de Rentas Internas (SRI) y la Agencia de Regulación y Control de Energía y Recursos Naturales no Renovables (ARC).

**Tabla 2.1. Variables utilizadas en los modelos**

<b>Variable</b>	<b>Unidad</b>	<b>Frecuencia</b>	<b>Fuente</b>
Producto Interno Bruto Real	USD millones	Trimestral	BCE
Índice de precios al consumidor (IPC)	Índice	Mensual	INEC
Índice de precios al productor (IPP)	Índice	Mensual	INEC
Índice de precios a la construcción (IPCO)	Índice	Mensual	INEC
Índice de actividad económica coyuntural (IDEAC)	Índice	Mensual	BCE
Exportaciones petroleras	USD millones	Mensual	BCE
Exportaciones no petroleras	USD millones	Mensual	BCE
Importaciones bienes de consumo	USD millones	Mensual	BCE
Importaciones bienes de capital	USD millones	Mensual	BCE
Importaciones materias primas	USD millones	Mensual	BCE
Importaciones combustibles	USD millones	Mensual	BCE
Precio promedio de exportación de crudo	USD por barril	Mensual	BCE
Recaudación del impuesto a la renta	USD millones	Mensual	SRI
Recaudación del impuesto al valor agregado	USD millones	Mensual	SRI
Demanda de energía eléctrica	GWh	Mensual	ARC
Cuasidineró	USD millones	Mensual	BCE
Liquidez (M2)	USD millones	Mensual	BCE
Depósitos a la vista	USD millones	Mensual	BCE
Gasto del Gobierno	USD millones	Mensual	BCE

Elaborado por el autor.

Con excepción del PIB, todas las variables tienen una periodicidad mensual y la base cuenta con información completa desde enero de 2001 hasta marzo de 2022. Una primera transformación que realizo a los datos es la de transformar el PIB con frecuencia trimestral a mensual mediante el método de Denton-Cholette que viene incorporado en el paquete “tempdisagg”. Cabe destacar que “los métodos de desagregación temporal se utilizan para desagregar series de tiempo de baja frecuencia a series de mayor frecuencia, donde la suma, el promedio, el primer o el último valor de la serie de alta frecuencia resultante es consistente con la serie de baja frecuencia” (Sax y Steiner 2013).

Por otro lado, cuando trabajas con series de tiempo es recomendable que las series sean estacionarias. López, Yaselga, y Espinosa (2021b) recomiendan “utilizar las tasas de crecimiento ya que suelen revertir las series a su promedio incondicional relativamente rápido, eliminando la parte tendencial de las series”. Entonces, una segunda transformación que aplico a las variables es convertirlas a tasas de crecimiento anual. Finalmente aplico la Prueba de Dickey-Fuller aumentada (ADF) para testear la estacionariedad de las series y en 5 casos (IPCO, IDEAC, exportaciones no petroleras, importación de combustibles, y cuasidinero) no se puede rechazar la hipótesis nula de que la serie presenta raíz unitaria. Este inconveniente se resuelve al transformar estas series a su primera diferencia (véase el anexo).

Una vez que los datos fueron recopilados y transformados, implemento los diferentes modelos explicados en la sección anterior, en Python con las librerías “Scikit-learn” y “Skforecast”. Cabe destacar que ejecuto el código en la herramienta gratuita Google Colab que brinda suficientes recursos computacionales para correr los algoritmos sin problemas desde un navegador. Una vez que los modelos fueron estimados, calculo la precisión de los pronósticos de cada modelo mediante la raíz del error cuadrático medio (RMSE):

$$RMSE = \sqrt{\frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{T}}$$

Donde:

- $y_t$  son los valores reales del crecimiento del PIB
- $\hat{y}_t$  son los valores pronosticados del crecimiento del PIB
- $T$  es el número total de pronósticos.

En términos sencillos la RMSE cuantifica los errores de pronóstico comparando los valores reales y estimados de la variable objetivo. Al elevar al cuadrado los términos de error, la RMSE asigna mayor peso a los errores grandes. Por lo tanto, es un indicador útil para comparar el poder predictivo de diferentes modelos, particularmente cuando hay grandes errores. Además, utilizo un modelo ARIMA<sup>1</sup> como punto de referencia o benchmark por varias razones:

- **Simplicidad y Transparencia:** es un modelo sencillo, lo que facilita su interpretación y la comprensión de los resultados. Esto es especialmente útil cuando se desea comparar el desempeño con modelos más complejos.
- **Establecido en la literatura:** ARIMA ha sido utilizado ampliamente en la literatura económica y es el modelo de referencia en muchas aplicaciones de series temporales, incluyendo estudios oficiales de bancos centrales como el BCE.
- **Probar la hipótesis:** Al ser un modelo tradicional, permite una comparación con métodos más avanzados de Machine Learning (ML), y su uso es crucial para probar la hipótesis de esta investigación.

Para concluir, en esta sección expliqué los diferentes métodos que utilizo para hacer pronósticos inmediatos, las fuentes de los datos, las transformaciones efectuadas y la metodología para comparar los modelos. De manera muy resumida lo que hago es estimar los diferentes modelos y luego comparar la precisión de los pronósticos mediante la RMSE. Cabe destacar que se prefiere los resultados con menor RMSE ya que este estadístico informa sobre qué tan cerca los modelos predicen los datos reales.

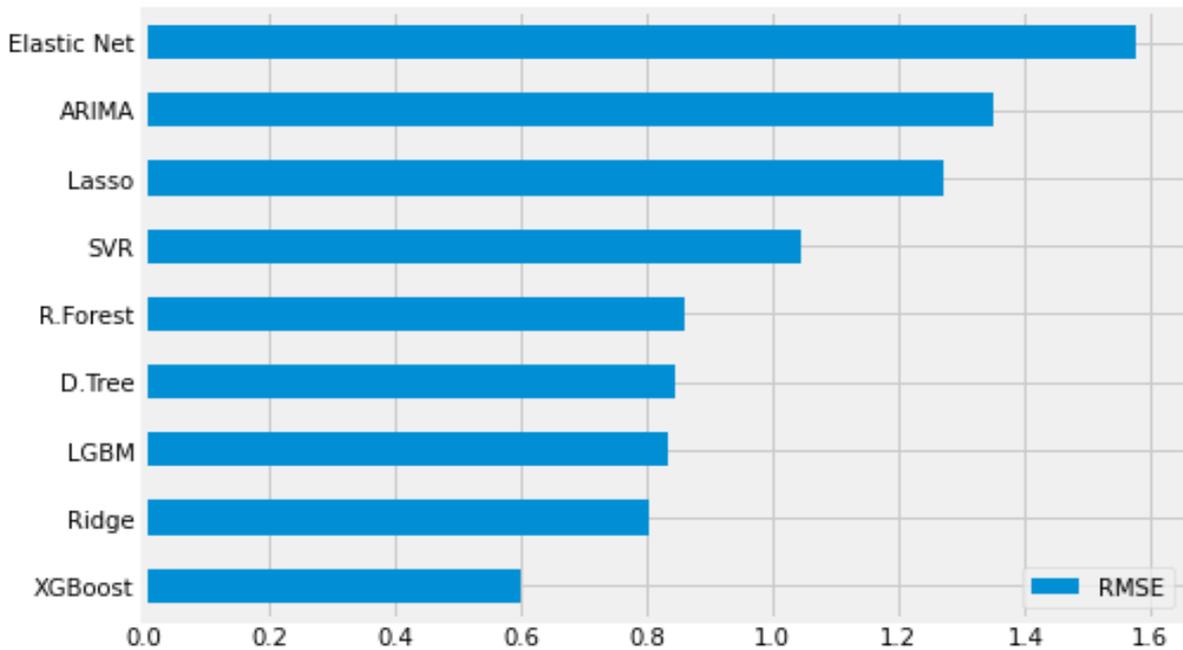
---

<sup>1</sup> Para el modelo ARIMA, utilizo la función “auto\_arima” que encuentra los mejores parámetros de p, I, y q a través de un proceso iterativo en el que busca minimizar el criterio de información de Akaike (AIC). De este modo el mejor modelo sería un ARIMA (5,1,1). Ver anexo para mayor detalle.

### Capítulo 3. Resultados

En general todos los modelos de machine learning, exceptuando el Elastic Net, superan al modelo ARIMA ya que producen pronósticos que tienen una RMSE más baja. Este resultado está en línea con lo encontrado en otros trabajos revisados en la literatura empírica.

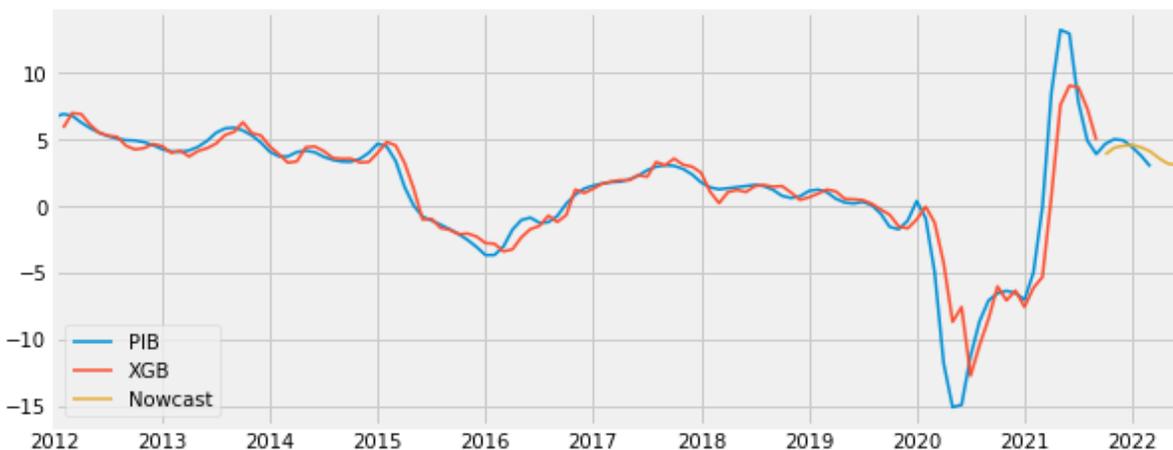
**Gráfico 3.1. Comparación de los modelos**



Elaborado por el autor.

El modelo que produce mejores pronósticos es el XGBoost que pertenece a la familia de los modelos Gradient Boosting. Cabe destacar que este modelo se ajusta bastante bien a los datos reales, aunque subestima la crisis de la pandemia en 2020 y también la recuperación de 2021.

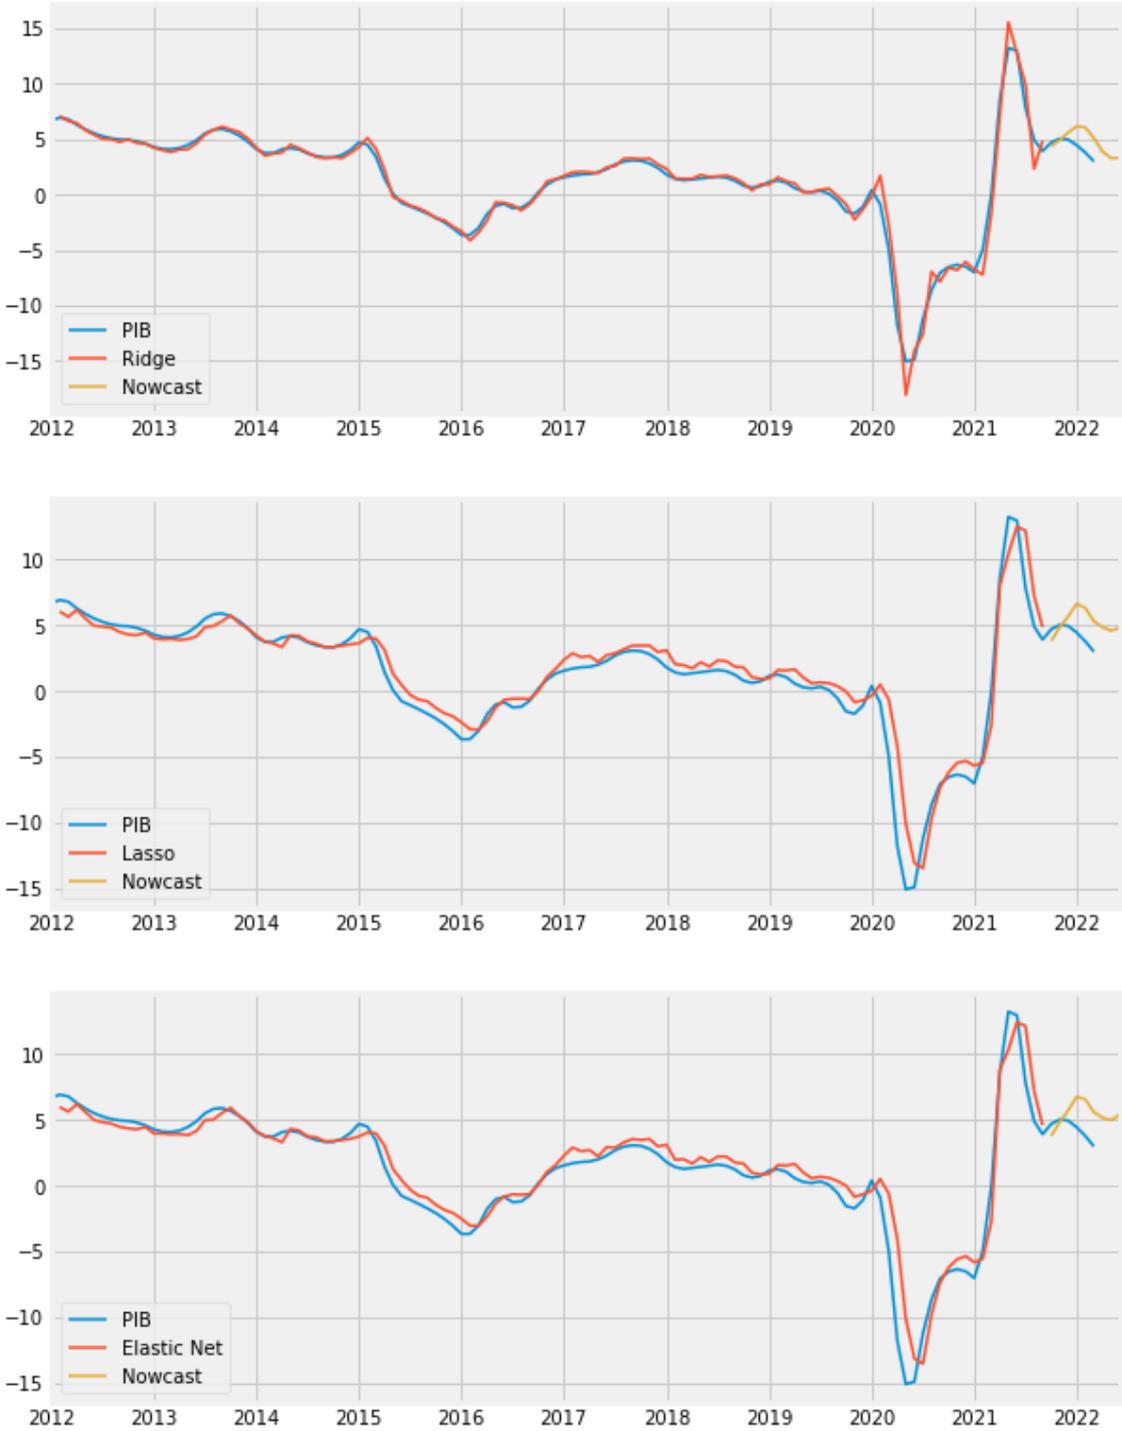
**Gráfico 3.2. XGboost**



Elaborado por el autor.

El segundo modelo con mejor ajuste es Ridge, algo a destacar es que parece hacer un mejor trabajo en el caso de la crisis y la recuperación. Como mencioné en el Capítulo 2, este modelo pertenece a la misma familia con Lasso y Elastic Net, no obstante, estos dos últimos son los peores modelos de ML con respecto al ARIMA.

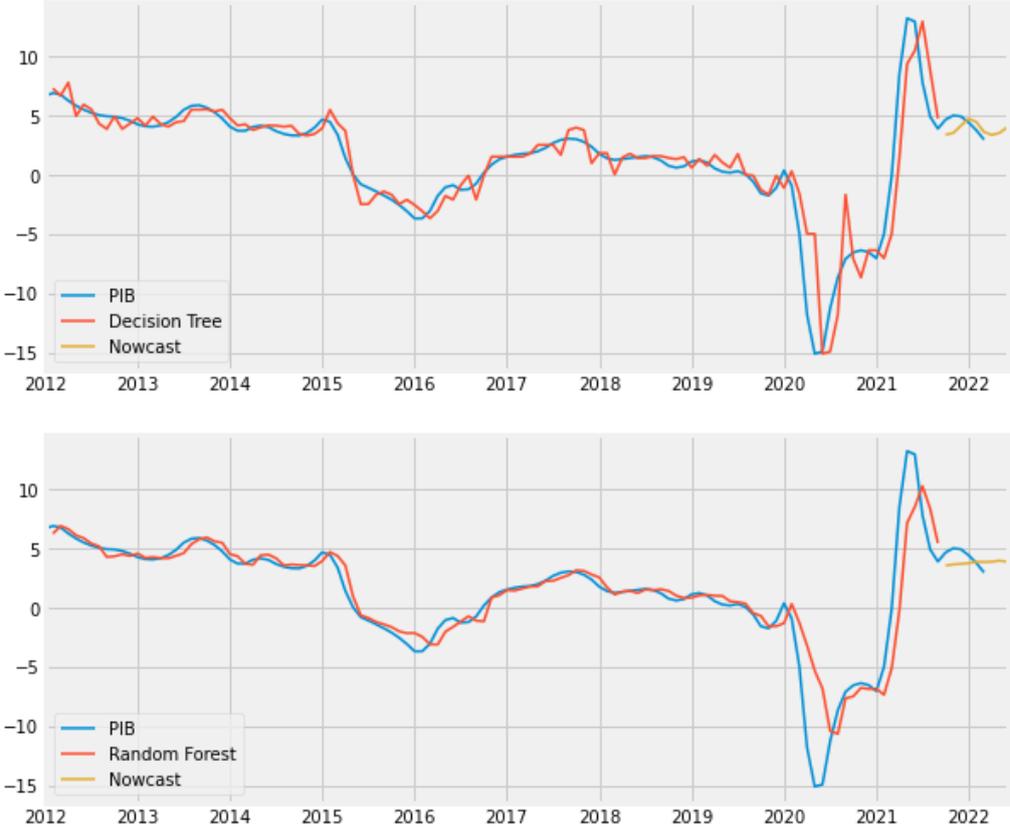
**Gráfico 3.3. Ridge, Lasso y Elastic Net**



Elaborado por el autor.

En el caso de los modelos de árboles, el Decision Tree Regression muestra un patrón menos suavizado que el resto de los modelos, además sobrestimó un repunte en el tercer trimestre de 2020. Por otro lado el RF subestimó la caída del PIB en 2020 y el crecimiento de 2021.

**Gráfico 3.4. Decision Tree Regression y Random Forest**



Elaborado por el autor.

Por último, el SVM tiene un mal ajuste con los datos reales durante todo el período estudiado, véase lo mal que estima la caída de 2020 y el crecimiento de 2021.

**Gráfico 3.5. Support Vector Machine (SVM)**



Elaborado por el autor.

En términos generales, los métodos de Machine Learning muestran un desempeño superior al modelo ARIMA. En casi todos los casos, los modelos de ML presentan una RMSE más baja, lo que indica una mejora significativa en la precisión del pronóstico. Estos hallazgos no solo confirman la hipótesis inicial de esta investigación, sino que también están en consonancia con la literatura existente en economías emergentes, donde se ha demostrado que los modelos de ML pueden superar los métodos tradicionales en contextos macroeconómicos.

Sin embargo, es importante destacar que los modelos de ML tienden a ser más efectivos en períodos de crecimiento estable, mientras que, durante eventos de alta volatilidad, como la pandemia de COVID-19, estos modelos tienden a subestimar o sobrestimar las fluctuaciones económicas. Esto plantea una oportunidad para mejorar los modelos actuales y explorar nuevos enfoques que puedan manejar mejor los eventos extremos y las fluctuaciones abruptas en las economías emergentes.

## Conclusiones

El uso de Machine Learning (ML) tiene un enorme potencial para mejorar y superar los modelos de nowcasting tradicionales. En el caso ecuatoriano, los resultados obtenidos en esta tesis demuestran que la aplicación de algoritmos de ML permite una mejora sustancial en los pronósticos inmediatos del PIB, reduciendo significativamente los errores de predicción, como lo refleja la Raíz del Error Cuadrático Medio (RMSE). El principal hallazgo de esta investigación es que la implementación de modelos de ML no solo mejora la precisión de las proyecciones, sino que también permite una actualización continua de los modelos a medida que se dispone de nueva información.

Gracias a herramientas gratuitas y accesibles como Scikit-Learn y Google Colab, el desarrollo e implementación de estos sofisticados modelos se simplifica notablemente, lo que hace posible automatizar el proceso de nowcasting. Este es un beneficio crucial para el contexto ecuatoriano, donde las cifras oficiales del PIB se publican con un retraso de tres meses. Utilizando variables macroeconómicas que se actualizan con mayor frecuencia, como la inflación, la recaudación de impuestos o el consumo eléctrico, es posible superar este desfase y generar estimaciones en tiempo real del crecimiento económico.

Entre las fortalezas de los modelos de ML destaca su capacidad para manejar grandes volúmenes de datos y captar relaciones no lineales complejas que los modelos tradicionales no logran detectar. Esta flexibilidad es especialmente valiosa en la predicción de variables macroeconómicas en entornos volátiles o cuando los datos disponibles son limitados, como ocurre en muchas economías emergentes.

Otro aspecto destacado es que la implementación de estos modelos puede automatizarse, lo que permite una actualización continua conforme se dispone de nueva información. Esta característica es especialmente valiosa en el contexto ecuatoriano, donde los datos oficiales suelen estar retrasados. La capacidad de estos modelos para generar pronósticos más oportunos reduce considerablemente los tiempos de espera, lo que resulta clave para los responsables de la política económica y los actores privados.

No obstante, pese a de las múltiples ventajas de los modelos de ML, uno de los principales desafíos que se identificó en esta tesis es el problema de la interpretabilidad. Estos algoritmos, aunque eficaces, operan como una especie de “caja negra”, lo que significa que proporcionan resultados sin ofrecer una explicación clara sobre cómo se llegó a ellos. Este es un aspecto

crucial en aplicaciones económicas, ya que los responsables de la política necesitan no solo conocer el pronóstico, sino también entender los factores que influyen en él.

Además del problema de interpretabilidad, otro desafío es su sensibilidad a eventos extremos o cambios estructurales en la economía, como se observó durante la pandemia de COVID-19. En estos casos, los modelos tendieron a subestimar la magnitud de la caída económica y la posterior recuperación, lo que indica que, aunque los modelos de ML son efectivos en condiciones de crecimiento estable, necesitan ajustes o combinaciones con otros enfoques para manejar mejor las fluctuaciones extremas.

Para abordar el problema de la interpretabilidad, en futuras investigaciones sería recomendable integrar técnicas de explicativas dentro de los modelos de ML, como los métodos de SHAP (Shapley Additive Explanations) o LIME (Local Interpretable Model-agnostic Explanations), que permiten descomponer las predicciones de los modelos y ofrecer una mayor comprensión de cómo cada variable influye en los resultados.

Otra recomendación es seguir explorando algoritmos más complejos, como las redes neuronales o los modelos híbridos, que podrían mejorar la capacidad predictiva durante períodos de volatilidad extrema. Además, sería beneficioso incorporar nuevas variables explicativas, como los índices de movilidad o los datos de búsquedas en Google, que han demostrado ser valiosos en otros estudios recientes sobre nowcasting. Estas nuevas fuentes de datos de alta frecuencia pueden mejorar la capacidad de los modelos de ML para capturar cambios rápidos en la actividad económica.

Por último, es fundamental fomentar el acceso a datos abiertos y mejorar la calidad y disponibilidad de las bases de datos en el país. Esto permitirá una mayor adopción de técnicas de ML y facilitará la implementación de modelos predictivos en tiempo real, algo crucial en un mundo cada vez más marcado por la inmediatez y donde el uso de inteligencias artificiales se vuelve más común en muchas de las actividades que realizan las personas.

## Referencias

Akerlof, George A. 1970. The Market for “Lemons”: Quality Uncertainty and the Market Mechanism. *The Quarterly Journal of Economics* 84 (3): 488-500.  
<https://doi.org/10.2307/1879431>.

- Akerlof, George A., y Robert J. Shiller. 2009. *Animal Spirits: How Human Psychology Drives the Economy, and Why It Matters for Global Capitalism*. Princeton University Press.
- Bakshi, Chaya. 2020. Random Forest Regression. Medium. 2020.  
<https://levelup.gitconnected.com/random-forest-regression-209c0f354c84>.
- Bañbura, Marta, Domenico Giannone, Michele Modugno, y Lucrezia Reichlin. 2013. Chapter 4 - Now-Casting and the Real-Time Data Flow. Editado por Graham Elliott y Allan Timmermann. *Handbook of Economic Forecasting 2*:195-237.  
<https://doi.org/10.1016/B978-0-444-53683-9.00004-9>.
- Bañbura, Marta, Domenico Giannone, y Lucrezia Reichlin. 2011. Nowcasting. *The Oxford Handbook of Economic Forecasting*.  
<https://doi.org/10.1093/oxfordhb/9780195398649.013.0008>.
- Bañbura, Marta, y Gerhard Rünstler. 2011. A Look into the Factor Model Black Box: Publication Lags and the Role of Hard and Soft Data in Forecasting GDP. *International Journal of Forecasting* 27 (2): 333-46.  
<https://doi.org/10.1016/j.ijforecast.2010.01.011>.
- Barrios, Juan José, Julia Escobar, Janelle Leslie, Lucia Martin, y Werner Peña. 2021. *Nowcasting to Predict Economic Activity in Real Time: The Cases of Belize and El Salvador*. Inter-American Development Bank. <https://doi.org/10.18235/0003699>.
- Basuchoudhary, Atin, James T Bang, y Tinni Sen. 2017. *Machine-Learning Techniques in Economics: New Tools for Predicting Economic Growth*. 1.<sup>a</sup> ed. Basel, Switzerland: Springer International Publishing.
- Beckert, Jens. 2016. *Imagined Futures: Fictional Expectations and Capitalist Dynamics*. Cambridge, Massachusetts: Harvard University Press.
- Blanchard, Olivier. 2021. *Macroeconomics*. Eighth edition, Global edition. Harlow, England London New York Boston San Francisco Toronto Sydney Dubai Singapore Hong Kong Tokyo Seoul Taipei New Delhi Cape Town São Paulo Mexico City Madrid Amsterdam Munich Paris Milan: Pearson.
- Bolhuis, Marijn, y Brett Rayner. 2020. Deus Ex Machina? A Framework for Macro Forecasting with Machine Learning. *IMF Working Papers* 2020 (045): 1.  
<https://doi.org/10.5089/9781513531724.001>.
- Carnot, Nicolas, Vincent Koen, Bruno Tissot, y Nicolas Carnot. 2011. *Economic Forecasting and Policy*. 2nd ed. Houndmills, Basingstoke Hampshire ; New York: Palgrave Macmillan.
- Caruso, Alberto. 2018. Nowcasting with the Help of Foreign Indicators: The Case of Mexico. *Economic Modelling* 69 (enero):160-68.  
<https://doi.org/10.1016/j.econmod.2017.09.017>.
- Casares, Felix Francisco. 2017. Nowcasting: Modelos de Factores Dinámicos y Ecuaciones Puente para la Proyección del PIB del Ecuador. *Compendium: Cuadernos de Economía y Administración* 4:22.
- Cepni, Oguzhan, I. Ethem Güney, y Norman R. Swanson. 2019. Nowcasting and Forecasting GDP in Emerging Markets Using Global Financial and Macroeconomic Diffusion Indexes. *International Journal of Forecasting* 35 (2): 555-72.  
<https://doi.org/10.1016/j.ijforecast.2018.10.008>.
- Chauvet, Marcelle, y Simon Potter. 2013. Forecasting Output. En *Handbook of Economic Forecasting*, 2:141-94. Elsevier. <https://doi.org/10.1016/B978-0-444-53683-9.00003-7>.
- Dahlhaus, Tatjana, Justin-Damien Guénette, y Garima Vasishtha. 2017. Nowcasting BRIC+M in Real Time. *International Journal of Forecasting* 33 (4): 915-35.  
<https://doi.org/10.1016/j.ijforecast.2017.05.002>.

- Davidson, Paul. 1996. Reality and Economic Theory. *Journal of Post Keynesian Economics* 18 (4): 479-508. <https://doi.org/10.1080/01603477.1996.11490083>.
- . 2010. Risk and Uncertainty. En *The Economic Crisis and the State of Economics*, editado por Robert Skidelsky y Christian Westerlind Wigström, 13-29. New York: Palgrave Macmillan US. [https://doi.org/10.1057/9780230105690\\_2](https://doi.org/10.1057/9780230105690_2).
- De Vroey, Michel. 2016. *A History of Macroeconomics from Keynes to Lucas and Beyond*. Cambridge: Cambridge University Press. <https://doi.org/10.1017/CBO9780511843617>.
- Del Negro, Marco, y Frank Schorfheide. 2013. DSGE Model-Based Forecasting. En *Handbook of Economic Forecasting*, 2:57-140. Elsevier. <https://doi.org/10.1016/B978-0-444-53683-9.00002-5>.
- Elliott, Graham, y Allan Timmermann. 2008. Economic Forecasting. *Journal of Economic Literature* 46 (1): 3-56. <https://doi.org/10.1257/jel.46.1.3>.
- . 2016a. Forecasting in Economics and Finance. *Annual Review of Economics* 8 (1): 81-110. <https://doi.org/10.1146/annurev-economics-080315-015346>.
- Elliott, Graham, y Allan G Timmermann. 2016b. *Economic forecasting*. Princeton, NJ: Princeton University Press.
- Friedman, Jerome H. 2001. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics* 29 (5): 1189-1232. <https://doi.org/10.1214/aos/1013203451>.
- Frydman, Roman, y Michael Goldberg. 2007. *Imperfect Knowledge Economics: Exchange Rates and Risk*. Princeton: Princeton University Press.
- Gogas, Periklis, y Theophilos Papadimitriou. 2021. Machine Learning in Economics and Finance. *Computational Economics* 57 (1): 1-4. <https://doi.org/10.1007/s10614-021-10094-w>.
- González-Astudillo, Manuel, y Daniel Baquero. 2019. A Nowcasting Model for Ecuador: Implementing a Time-Varying Mean Output Growth. *Economic Modelling* 82:250-63. <https://doi.org/10.1016/j.econmod.2019.01.010>.
- Granger, Clive. 2017. Forecasting. En *The New Palgrave Dictionary of Economics*, 1-4. London: Palgrave Macmillan UK. [https://doi.org/10.1057/978-1-349-95121-5\\_416-2](https://doi.org/10.1057/978-1-349-95121-5_416-2).
- Harvey, Andrew. 2006. Chapter 7 Forecasting with Unobserved Components Time Series Models. En *Handbook of Economic Forecasting*, editado por G. Elliott, C.W.J. Granger, y A. Timmermann, 1:327-412. Elsevier. [https://doi.org/10.1016/S1574-0706\(05\)01007-4](https://doi.org/10.1016/S1574-0706(05)01007-4).
- Hevia, Constantino. 2017. Modelos macroeconómicos. ¿De dónde venimos y hacia dónde vamos? *Foco Económico* (blog). 4 de octubre de 2017. <http://focoeconomico.org/2017/10/04/modelos-macroeconomicos-de-donde-venimos-y-hacia-donde-vamos/>.
- James, Gareth, Daniela Witten, Trevor Hastie, y Robert Tibshirani. 2013. *An Introduction to Statistical Learning: With Applications in R*. 2013.<sup>a</sup> ed. New York, NY: Springer.
- Jönsson, Kristian. 2020. Machine Learning and Nowcasts of Swedish GDP. *Journal of Business Cycle Research*, 12.
- Keen, S. 2021. *The new economics - A manifesto the new economics - A manifesto: A manifesto*. Oxford, England: Polity Press.
- Keynes, John Maynard, 1883-1946. 1936. *The general theory of employment, interest and money*. London : Macmillan, 1936. <https://search.library.wisc.edu/catalog/999623618402121>.
- King, Mervyn, y John Kay. 2020. *Radical Uncertainty: Decision-Making for an Unknowable Future*.
- Knight, Frank H. 1921. *Risk, Uncertainty and Profit*. Houghton Mifflin Co. <http://www.econlib.org/library/Knight/knRUP.html>.

- Köster, Roman, Laetitia Lenel, y Ulrich Fritsche, eds. 2020. *Futures Past. Economic Forecasting in the 20th and 21st Century*. Peter Lang International Academic Publishers. <https://doi.org/10.3726/b16817>.
- Kydland, Finn E., y Edward C. Prescott. 1982. Time to Build and Aggregate Fluctuations. *Econometrica* 50 (6): 1345-70. <https://doi.org/10.2307/1913386>.
- Liu, Philip, Troy Matheson, y Rafael Romeu. 2012. Real-Time Forecasts of Economic Activity for Latin American Economies. *Economic Modelling* 29 (4): 1090-98. <https://doi.org/10.1016/j.econmod.2012.03.020>.
- Ljungqvist, Lars. 2008. Lucas Critique. En *The New Palgrave Dictionary of Economics*, editado por Palgrave Macmillan, 1-5. London: Palgrave Macmillan UK. [https://doi.org/10.1057/978-1-349-95121-5\\_2784-1](https://doi.org/10.1057/978-1-349-95121-5_2784-1).
- López, Francisco, Emanuel Yaselga, y Francisco Espinosa. 2021a. Modelo nowcast con factores dinámicos para la estimación trimestral del PIB real para el Ecuador. *Cuestiones Económicas* 31 (1).
- . 2021b. Modelo nowcast con factores dinámicos para la estimación trimestral del PIB real para el Ecuador. *Cuestiones Económicas* 31 (1).
- Lucas, Robert E. 1983. *Studies in Business-Cycle Theory*. Cambridge, MA, USA: MIT Press.
- Manuelito, Sandra. 2017. The Use of High-Frequency Indicators in Short-Term Forecasting Models: The Case of Latin American and Caribbean Countries. *CEPAL Serie Macroeconomía del Desarrollo* No. 188. <https://repositorio.cepal.org/handle/11362/41956>.
- Marion, Ronca. 2020. The Economist as Futurologist: The Making and the Public Reception of the Perspektivstudien in Switzerland, 1964–1975. En *Futures Past. Economic Forecasting in the 20th and 21st Century*. Peter Lang International Academic Publishers.
- Mitchell, William, Randall L. Wray, y Martin J. Watts. 2019. *Macroeconomics*. London: Macmillan International Higher Education.
- Muth, John F. 1961. Rational Expectations and the Theory of Price Movements. *Econometrica* 29 (3): 315-35. <https://doi.org/10.2307/1909635>.
- Pilmis, Olivier. 2020. The Dynamics of Expectations: A Sequential Perspective on Macroeconomic Forecasting. En *Futures Past. Economic Forecasting in the 20th and 21st Century*. Peter Lang. <http://resolver.sub.uni-goettingen.de/purl?fidaac-11858/999>.
- Ranjan, Abhishek, y Saurabh Ghosh. 2021. A Machine Learning (ML) Approach to GDP Nowcasting: An Emerging Market Experience. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3980188>.
- Rebala, Gopinath, Ajay Ravi, y Sanjay Churiwala. 2019. *An Introduction to Machine Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-15729-6>.
- Richardson, Adam, Thomas van Florenstein Mulder, y Tuğrul Vehbi. 2020. Nowcasting GDP Using Machine-Learning Algorithms: A Real-Time Assessment. *International Journal of Forecasting* 37 (2): 941-48. <https://doi.org/10.1016/j.ijforecast.2020.10.005>.
- Sampi, James, y Charl Jooste. 2020. *Nowcasting Economic Activity in Times of COVID-19: An Approximation from the Google Community Mobility Report*. World Bank, Washington, DC. <https://doi.org/10.1596/1813-9450-9247>.
- Sargent, Thomas J. 2017. Rational Expectations. En *The New Palgrave Dictionary of Economics*, 1-7. London: Palgrave Macmillan UK. [https://doi.org/10.1057/978-1-349-95121-5\\_1684-2](https://doi.org/10.1057/978-1-349-95121-5_1684-2).
- Sax, Christoph, y Peter Steiner. 2013. Temporal Disaggregation of Time Series. *The R Journal* 5 (2): 80-87. <https://doi.org/10.32614/RJ-2013-028>.

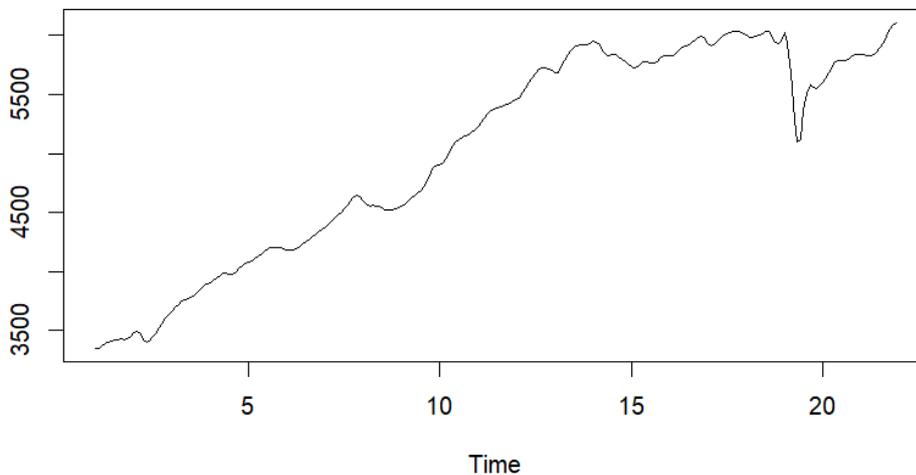
- Sims, Christopher A. 1980. Macroeconomics and Reality. *Econometrica* 48 (1): 1-48.  
<https://doi.org/10.2307/1912017>.
- Sinclair, Tara. 2020. Continuities and Discontinuities in Economic Forecasting. En *Futures Past. Economic Forecasting in the 20th and 21st Century*. Peter Lang International Academic Publishers.
- Sosa, Walter. 2019. *Big data: Breve manual para conocer la ciencia de datos que ya invadió nuestras vidas*. Siglo XXI Editores.
- Soybilgen, Barış, y Ege Yazgan. 2021. Nowcasting US GDP Using Tree-Based Ensemble Models and Dynamic Factors. *Computational Economics* 57 (1): 387-417.  
<https://doi.org/10.1007/s10614-020-10083-5>.
- Watson, Mark W. 2008. Macroeconomic Forecasting. En *The New Palgrave Dictionary of Economics*, editado por Palgrave Macmillan, 1-3. London: Palgrave Macmillan UK.  
[https://doi.org/10.1057/978-1-349-95121-5\\_2434-1](https://doi.org/10.1057/978-1-349-95121-5_2434-1).
- Yaselga, Emanuel. 2019. Un Indicador de Factores Dinámicos para la Evolución del PIB a Corto Plazo para el Ecuador. *Cuestiones Económicas* 29 (1).  
<https://doi.org/10.47550/RCE/29.1.1>.
- Yoon, Jaehyun. 2021. Forecasting of Real GDP Growth Using Machine Learning Models: Gradient Boosting and Random Forest Approach. *Computational Economics* 57 (1): 247-65. <https://doi.org/10.1007/s10614-020-10054-w>.

## Anexos

### Transformar PIB trimestral a mensual

```
import pandas as pd
import numpy as np
%load_ext rpy2.ipython

%%R
pib <- read.csv("pib.csv")
pib <- ts(data = pib, start = 1, frequency = 4)
pibt <- td(pib~1, to = "monthly", method = "denton-cholette")
pibm <- data.frame(pibt$values)
```



### Estacionariedad de las series

```
Series: IPC
ADF Statistic: -3.893557
p-value: 0.002083
Critical Values:
  1%: -3.458
  5%: -2.874
 10%: -2.573
```

**Sí se rechaza H<sub>0</sub>, la serie es estacionaria**

```
Series: IPP
ADF Statistic: -3.638092
p-value: 0.005073
Critical Values:
  1%: -3.458
  5%: -2.874
 10%: -2.573
```

**Sí se rechaza H<sub>0</sub>, la serie es estacionaria**

Series: IPCO  
ADF Statistic: -2.283696  
p-value: 0.177280  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**No se rechaza H0, la serie no es estacionaria**

Series: IDEAC  
ADF Statistic: -2.643806  
p-value: 0.084277  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**No se rechaza H0, la serie no es estacionaria**

Series: EXPP  
ADF Statistic: -3.199234  
p-value: 0.020029  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: EXPN  
ADF Statistic: -2.627942  
p-value: 0.087359  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**No se rechaza H0, la serie no es estacionaria**

Series: IMPCON  
ADF Statistic: -4.957735  
p-value: 0.000027  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IMPMP  
ADF Statistic: -2.892330  
p-value: 0.046247  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IMPCAP  
ADF Statistic: -3.658381  
p-value: 0.004738  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IMPCOM  
ADF Statistic: -2.558175  
p-value: 0.101953  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**No se rechaza H0, la serie no es estacionaria**

Series: PPETRO  
ADF Statistic: -3.230182  
p-value: 0.018303  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: RENTA  
ADF Statistic: -4.584623  
p-value: 0.000138  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IVA  
ADF Statistic: -4.192308  
p-value: 0.000679  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: ENERG  
ADF Statistic: -4.411608  
p-value: 0.000283  
Critical Values:  
1%: -3.458

5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: CUASID  
ADF Statistic: -2.745491  
p-value: 0.066492  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**No se rechaza H0, la serie no es estacionaria**

Series: M2  
ADF Statistic: -3.916897  
p-value: 0.001914  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: DVISTA  
ADF Statistic: -3.560206  
p-value: 0.006569  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: GOB  
ADF Statistic: -3.486246  
p-value: 0.008347  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

### **Aplicando primeras diferencias**

Series: IPC  
ADF Statistic: -5.375197  
p-value: 0.000004  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IPP  
ADF Statistic: -5.236347  
p-value: 0.000007  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IPCO  
ADF Statistic: -6.011927  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IDEAC  
ADF Statistic: -6.469197  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: EXPP  
ADF Statistic: -7.990897  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: EXPN  
ADF Statistic: -9.549306  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IMPCON  
ADF Statistic: -4.909366  
p-value: 0.000033  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IMPMP  
ADF Statistic: -6.183208  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IMPCAP  
ADF Statistic: -5.975912  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IMPCOM  
ADF Statistic: -6.637406  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: PPETRO  
ADF Statistic: -7.582615  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: RENTA  
ADF Statistic: -6.050783  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: IVA  
ADF Statistic: -6.682249  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: ENERG  
ADF Statistic: -5.888686  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: CUASID  
ADF Statistic: -7.715869  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: M2  
ADF Statistic: -7.202087  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: DVISTA  
ADF Statistic: -5.685540  
p-value: 0.000001  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

Series: GOB  
ADF Statistic: -6.016474  
p-value: 0.000000  
Critical Values:  
1%: -3.458  
5%: -2.874  
10%: -2.573

**Sí se rechaza H0, la serie es estacionaria**

## ARIMA

Performing stepwise search to minimize aic

ARIMA(1,1,1) (0,0,0) [0] intercept	: AIC=546.095, Time=0.32 sec
ARIMA(0,1,0) (0,0,0) [0] intercept	: AIC=783.976, Time=0.07 sec
ARIMA(1,1,0) (0,0,0) [0] intercept	: AIC=611.983, Time=0.15 sec
ARIMA(0,1,1) (0,0,0) [0] intercept	: AIC=615.315, Time=0.21 sec
ARIMA(0,1,0) (0,0,0) [0]	: AIC=781.991, Time=0.04 sec
ARIMA(2,1,1) (0,0,0) [0] intercept	: AIC=472.662, Time=0.29 sec
ARIMA(2,1,0) (0,0,0) [0] intercept	: AIC=470.733, Time=0.34 sec
ARIMA(3,1,0) (0,0,0) [0] intercept	: AIC=472.560, Time=0.35 sec
ARIMA(3,1,1) (0,0,0) [0] intercept	: AIC=443.097, Time=0.65 sec
ARIMA(4,1,1) (0,0,0) [0] intercept	: AIC=364.895, Time=0.77 sec
ARIMA(4,1,0) (0,0,0) [0] intercept	: AIC=399.001, Time=0.57 sec
ARIMA(5,1,1) (0,0,0) [0] intercept	: AIC=341.245, Time=2.68 sec
ARIMA(5,1,0) (0,0,0) [0] intercept	: AIC=343.719, Time=0.86 sec
ARIMA(5,1,2) (0,0,0) [0] intercept	: AIC=inf, Time=2.71 sec
ARIMA(4,1,2) (0,0,0) [0] intercept	: AIC=inf, Time=2.08 sec
ARIMA(5,1,1) (0,0,0) [0]	: AIC=339.251, Time=0.61 sec
ARIMA(4,1,1) (0,0,0) [0]	: AIC=362.896, Time=0.16 sec
ARIMA(5,1,0) (0,0,0) [0]	: AIC=341.730, Time=0.16 sec
ARIMA(5,1,2) (0,0,0) [0]	: AIC=inf, Time=0.85 sec
ARIMA(4,1,0) (0,0,0) [0]	: AIC=397.001, Time=0.09 sec
ARIMA(4,1,2) (0,0,0) [0]	: AIC=inf, Time=0.66 sec

Best model: ARIMA(5,1,1) (0,0,0) [0]

Total fit time: 14.708 seconds

RMSE Score = 1.3509378546437676

## Comparativa de todos los modelos

