

**UNIVERSIDAD DE LA REPÚBLICA**  
**FACULTAD DE CIENCIAS SOCIALES**  
**DEPARTAMENTO DE ECONOMÍA**  
**Tesis de Maestría en Economía**

**Pronósticos de inflación con métodos de aprendizaje  
automático**

**Zelmar Romero**  
Tutores: Rodrigo Lluberas y Victoria Landaberry

## Resumen

El objetivo de este trabajo es evaluar el desempeño de un conjunto de técnicas de aprendizaje automático supervisado a la hora de predecir la inflación interanual de Uruguay. En particular, se utilizan los métodos Regresión Ridge, Lasso, adaptive-Lasso y Random Forest y se toma como insumo las expectativas de inflación recogidas en una encuesta realizada a unas quinientas empresas entre octubre 2009 y junio 2020. Para evaluar el desempeño predictivo de estos métodos se calculan los errores de predicción fuera de la muestra para cada método y se comparan con los errores de predicción de cinco métodos alternativos de referencia. Como resultado se tiene que todos los métodos de aprendizaje automático, así como combinaciones de los mismos, presentan menor error de predicción que los de referencia. Los resultados son promisorios y dan cuenta del potencial que tienen tanto las técnicas de aprendizaje automático como la encuesta de expectativas de las empresas a la hora de predecir la inflación.

## Agradecimientos

Quiero agradecer a quienes me ayudaron y guiaron en la realización de este trabajo. En especial: a mis tutores Rodrigo y Victoria; a Agustina Affonso y Pablo Picardo, con quienes realicé un trabajo preliminar sobre pronósticos de inflación; a Jorge Ponce; al Banco Central del Uruguay por permitirme acceder a la base de datos utilizada en este trabajo; a la UdelaR; y a mi familia.

## Tabla de contenidos

1. Introducción .....	1
2. Revisión de literatura .....	3
3. Datos .....	6
4. Metodología .....	10
5. Resultados.....	20
6. Comentarios finales .....	23
7. Referencias .....	25
8. Anexo .....	29

## 1. Introducción

El principal objetivo de este trabajo es contribuir en la exploración de nuevos métodos para la predicción de la tasa de inflación en Uruguay, una variable económica trascendente para muchos de los agentes del país y en especial para uno de sus actores más relevantes como lo es el Banco Central del Uruguay (BCU). Con este objetivo, se evalúa el desempeño de cuatro técnicas que comúnmente se denominan métodos de aprendizaje automático (o de aprendizaje estadístico) en la predicción de la inflación de Uruguay a 12 meses, comparando dicho desempeño con el de algunos métodos de referencia, los cuales utilizan técnicas más clásicas o tradicionales. Como base de datos se utilizan expectativas de inflación recogidas en una encuesta realizada a un conjunto de empresas uruguayas. Tal como señala Bernanke (2007), el estado de las expectativas de inflación influye en gran medida en la inflación real y, por lo tanto, en la capacidad del banco central para lograr la estabilidad de precios. El hecho de contar con expectativas de inflación de empresas cobra una relevancia aún mayor, dada la incidencia directa que tienen estas en el nivel de precios y la influencia que pueden tener sus expectativas a la hora de fijar los precios de sus productos<sup>1</sup>. Adicionalmente, es muy posible que existan asimetrías de información entre estas empresas y otros agentes para la formación de expectativas y que su explotación permita obtener pronósticos de inflación más acertados. De hecho, como se muestra en este trabajo, por un lado, tanto la media como la mediana de las expectativas de las firmas son un mejor predictor de la inflación que la media y mediana de los analistas profesionales consultados por BCU, y, por otro lado, todos los métodos de predicción que se basan en las expectativas de empresas son los que presentan menor error de predicción.

Tal como describe Athey (2018), en la econometría clásica generalmente un investigador especifica un modelo, estima sus parámetros utilizando el conjunto de datos y luego se basa en la teoría estadística para obtener intervalos de confianza de los parámetros estimados. La atención suele centrarse principalmente en la estimación de los parámetros del modelo y en las relaciones de causalidad. Este enfoque tradicional presenta algunas desventajas referidas a la sistematización y al chequeo de especificaciones alternativas que pueden ser subsanadas con métodos de aprendizaje

---

<sup>1</sup> Según muestran Boneva et al. (2016) en un trabajo realizado con datos a nivel micro en Reino Unido, las expectativas de las empresas juegan un papel clave en la fijación de precios, dado que los aumentos de precios de cada empresa durante el año anterior está relacionado a sus expectativas de aumentos de precios con un coeficiente estadísticamente indistinguible de uno.

automático, tales como los utilizados en este trabajo. Estos métodos, a diferencia de las técnicas de la econometría clásica, ponen foco en la bondad de ajuste del modelo fuera de la muestra, y no hacen tanto hincapié en la fundamentación teórica del mismo o la estimación de efectos causales. Por este motivo es que son métodos muy útiles para realizar predicciones sobre los valores que pueden tomar ciertas variables, y en general suelen mostrar mejor desempeño en este campo que los enfoques tradicionales (Chakraborty y Joseph (2017)). Sin embargo, hay que tener cautela a la hora de realizar interpretaciones o inferencias de causalidad cuando se utilizan estos métodos, dado que los predictores seleccionados no tienen por qué presentar efectos causales y los modelos especificados no necesariamente están respaldados por un enfoque teórico, quedando este segundo paso a juicio de quien investiga, siempre y cuando sea algo factible de realizar.

En este trabajo, se evalúan las siguientes cuatro técnicas de aprendizaje automático: regresión Ridge, Lasso, adaptive-Lasso y Random Forest. Los datos a utilizar corresponden a una encuesta realizada a unas quinientas empresas donde se les consulta, entre otras cosas, las expectativas de inflación a 12 meses. Se dispone de dicha información desde octubre 2009 hasta junio 2020 y con frecuencia mensual. El horizonte de previsión de la inflación considerado en este trabajo es de 12 meses debido principalmente a la estructura de los datos disponible, ya que este es el único horizonte fijo que cuenta con proyecciones desde que se comenzó la encuesta en octubre 2009 hasta el último dato disponible.

La evaluación del desempeño de los diferentes métodos de aprendizaje automático se realiza comparando los pronósticos que surgen de estos con los que surgen de cinco métodos más tradicionales: i) modelo autoregresivo de orden 1 (AR(1)); ii) modelo autorregresivo integrado de media móvil (ARIMA); iii) modelo RB\*, que consiste en una constante más un ruido blanco; iv) mediana de los pronósticos realizados por las empresas en la encuesta ya mencionada; y v) mediana de las expectativas de analistas profesionales consultados por BCU<sup>2</sup>. El objetivo específico es identificar qué método arroja menor error de predicción cuando se evalúa el valor pronosticado frente al valor observado fuera de la muestra de entrenamiento, utilizando como medida de comparación el error cuadrático medio y su raíz (ECM y

RECM).

---

<sup>2</sup> El BCU consulta y publica mensualmente las expectativas de inflación para diferentes horizontes temporales de instituciones y profesionales independientes que considera formadores de opinión en la materia. Dicha encuesta se puede consultar en: <https://www.bcu.gub.uy/Estadisticas-e-Indicadores/Paginas/Encuesta-Inflacion.aspx>.

Los resultados indican que adaptive-Lasso es el método de aprendizaje automático que muestra mejor desempeño a la hora de la predicción, lo sigue el método Random Forest, que presenta el mismo RECM pero un ECM apenas inferior, y por último Lasso y Ridge, que proporcionan predicciones equivalentes. Comparado con los métodos de referencia, todos los métodos de aprendizaje automático son más eficientes para predecir. También se observa que realizando combinaciones de distintos métodos, se puede reducir levemente la RECM. Por otra parte, el método que arroja mayor RECM es RB\*, aunque con un valor apenas superior a la mediana de los analistas (3,9%).

Al no haber aún trabajos publicados que exploren la predicción de la inflación en Uruguay mediante métodos de aprendizaje automático, este trabajo representa una ampliación original a los estudios sobre inflación preexistentes. A su vez, los resultados obtenidos son alentadores y motivan a seguir por este camino de investigación a efectos de ampliar la caja de herramientas utilizadas hoy en día por los distintos agentes.

## **2. Revisión de literatura**

La inflación es una de las variables más relevantes dentro de la política económica y su pronóstico es de especial interés para muchos agentes, lo que motiva la existencia de una vasta literatura sobre el tema a nivel internacional, tanto a nivel teórico como empírico. Una introducción sobre inflación y su pronóstico puede encontrarse en Tallman (1995), quien también realiza un trabajo empírico para Estados Unidos. Tal como destaca el autor, los costos de la inflación inesperada son sustanciales, incluso a bajos niveles de inflación, por lo que la precisión en la predicción se torna relevante tanto para empresas como consumidores. Por otra parte, la importancia de los pronósticos y expectativas de inflación para los bancos centrales con metas de inflación queda explícita en el trabajo de Svensson (1996). El autor argumenta que las metas de inflación afrontan problemas de implementación y monitoreo, especialmente debido a que los bancos centrales no tienen un control perfecto sobre la misma. Esto implica que las expectativas de inflación sean una meta intermedia implícita, dado que es la variable más correlacionada con el objetivo y sobre la cual los bancos tienen mayor control. En otras palabras, los bancos centrales tienen mayor responsabilidad sobre un desvío entre las expectativas de inflación y la meta fijada para un horizonte determinado que sobre un desvío entre dicha meta y la

inflación efectivamente observada ex post. Por lo tanto, disponer de herramientas que permitan en base a información de alta frecuencia obtener predicciones de inflación más precisas puede orientar las decisiones de política monetaria de forma que las mismas sean más efectivas y eficientes. Para el caso uruguayo, existen algunos estudios que analizan la influencia de la política del banco central (y su comunicación) sobre las expectativas de inflación (recogida en la encuesta a nivel de empresas ya mencionada). Por ejemplo, Mello y Ponce (2020) evidencian que la política monetaria ha sido efectiva para compensar las distorsiones introducidas por la política fiscal sobre las expectativas de inflación, resultado consistente con Licandro y Mello (2014), quienes encuentran una relación negativa y estadísticamente significativa entre la política monetaria y las expectativas de inflación. Por otra parte, Borraz y Mello (2020) identifican diferencias en la formación de expectativas inflacionarias, credibilidad y errores de predicción, según las comunicaciones del BCU y el nivel de información de los agentes fijadores de precios. En líneas generales, encuentran que las empresas no informadas tienen un mayor error de pronóstico y mayor volatilidad en sus expectativas que las empresas informadas.

En lo que refiere a estudios que utilizan métodos de aprendizaje automático para predecir inflación la literatura no es tan abundante pero igualmente se han realizado diversos trabajos para distintos países en los últimos años. Garcia et al. (2017) realizan un estudio para la inflación en Brasil aplicando métodos de aprendizaje automático a cincuenta y nueve variables macroeconómicas y treinta y cuatro asociadas a la encuesta de expectativas realizada por el Banco Central de Brasil. Allí encuentran que estos métodos se desempeñan mejor que las predicciones de referencia. En particular, Lasso y Flex-adaLasso muestran menor error de predicción para los horizontes  $t+1$  y  $t+2$  respectivamente, mientras Complete Subset Regression tiene un mejor desempeño para plazos mayores. Liao (2017) pronostica PIB e inflación para Estados Unidos utilizando el método Artificial Neural Network pero no encuentra un resultado contundente, ya que el método es superior a la predicción de referencia cuando se trata del PIB pero no cuando se trata de inflación. Por su parte, Küçükefe (2018) utiliza los métodos Regresión Ridge (en dos versiones), Random Forest y Support Vector Machines para mejorar las predicciones recogidas en la encuesta de expectativas de inflación del Banco Central de Turquía. Las predicciones obtenidas a partir de estos métodos son mejores que las predicciones obtenidas a partir del método de referencia. Baybuza (2018) utiliza los métodos LASSO, Ridge, Elastic Net, Random Forest y Boosting y demuestra que el modelo Random Forest y el modelo Boosting son al menos tan buenos como los modelos más tradicionales (Random Walk

y autorregresión) para pronosticar la inflación en Rusia. Por último, Rodríguez (2020) evalúa la capacidad de métodos de aprendizaje automático para predecir la inflación en Costa Rica, para ello utiliza una base de datos de diecinueve variables macroeconómicas con sus rezagos y los métodos K-Nearest Neighbours (KNN; en dos variantes), Random Forest, Extreme gradient boosting y un modelo de tipo long/short-term memory (LSTM). Los pronósticos obtenidos los compara con el promedio de los pronósticos univariados actualmente en uso en el Banco Central de Costa Rica y observa que los pronósticos con mejor desempeño son los resultantes de aplicar LSTM, KNN univariado y en menor medida Random Forest. Usar una combinación de estos tres métodos mejora el desempeño con respecto a los pronósticos individuales a todos los horizontes y también respecto al promedio de los pronósticos univariados actualmente en uso en el Banco Central de Costa Rica.

A nivel local, distintos estudios se han centrado en la predicción de la inflación en Uruguay mientras que otros se han focalizado en explotar de diversas maneras la base de datos de las firmas utilizada en este trabajo. Sin embargo, no se han publicado trabajos que realicen predicciones de inflación utilizando métodos de aprendizaje automático, ya sea utilizando dicha base de datos o alguna otra.

En cuanto a predicción de inflación de Uruguay, uno de los trabajos pioneros a destacar es el de Canelo et al. (1994), quienes utilizan modelos univariados con análisis de intervención a efectos de caracterizar el fenómeno inflacionario de Uruguay en el período 1986-1994, estimar el componente permanente de la serie de precios y realizar proyecciones de corto plazo. Dichas proyecciones se realizan únicamente a un mes y sobre bienes transables y no transables, las cuales se combinan luego para obtener una predicción general e indirecta del Índice de Precios de Consumo (IPC). Los autores encuentran errores porcentuales del orden del 1% para el paso especificado, no descartando la hipótesis de que la capacidad predictiva del modelo se mantiene fuera de la muestra. Por otra parte, uno de los primeros trabajos que evalúa la capacidad de predicción de expectativas de inflación en Uruguay es el de Lanzilotta et al. (2007). Los autores realizan una evaluación de las proyecciones de los analistas consultados por BCU entre 2004 y 2007 y, entre otras cosas, comparan el error de predicción de la media y mediana, encontrando que dicho error es menor al de un modelo autorregresivo simple de la inflación. En otro trabajo posterior, Cuitiño et al. (2010) construyen distintos modelos univariados de predicción del IPC y sus componentes para una muestra que va desde 1997 a 2009 y evalúan los errores de predicción para 2009-2010. Dentro de los análisis que realizan, comparan la predicción a un paso del mejor modelo univariado estimado (al cual denominan M2) con dos

pronósticos de referencia, uno que surge de un modelo *naif* (que repite el valor anterior) y el otro de la mediana de las expectativas de analistas publicadas por el BCU. Los autores encuentran que, en términos generales, el modelo M2 genera predicciones fuera de la muestra superiores a los dos modelos de referencia. En otro trabajo, Brum et al. (2013) presentan un conjunto de modelos multivariados de función de transferencia mediante los cuales se proyecta la inflación agregando pronósticos de componentes. Los autores encuentran que la agregación de componentes genera proyecciones con buen poder predictivo, especialmente en plazos cortos e intermedios, generalmente superando a sus dos referencias (mediana de expectativas de encuesta a expertos y paseo aleatorio). El desempeño resultó particularmente bueno para el núcleo duro de la inflación y para horizontes más lejanos. A su vez, estos modelos superan algunas limitaciones de los modelos univariados para el corto plazo al incorporar información externa y permitir un análisis más desagregado que los modelos macroeconómicos en plazos más largos.

Repasando la literatura existente para el caso uruguayo, no se encuentran publicaciones que realicen predicciones de inflación utilizando métodos de aprendizaje automático, por lo que este trabajo es una primera aproximación al problema utilizando algunas de estas técnicas. También es una novedad la aplicación de métodos de aprendizaje automático a la encuesta realizada a las firmas, la cual cuenta con otros datos que también pueden ser explotados mediante este tipo de metodología.

### **3. Datos**

La variable de interés es la variación interanual del IPC que publica mensualmente el Instituto Nacional de Estadística (INE)<sup>3</sup>. Dicha variación es comúnmente considerada como la medida de la inflación anual en Uruguay, y así es considerada en este trabajo.

Los datos utilizados en este trabajo surgen de una encuesta realizada por el INE bajo encargo del BCU. Esta encuesta se realiza mensualmente desde 2009 sobre unas quinientas empresas uruguayas con más de cincuenta empleados, las cuales cuentan con un mes para enviar sus respuestas. Si bien la encuesta no es obligatoria, los ratios de respuesta oscilan entre el 54% y 88%, resultando en un panel no balanceado y representativo de todos los sectores de la economía, excepto el financiero, el agrícola y el público (Frache y Lluberas (2019)). Se trata de una encuesta novedosa y poco común en el mundo, en donde se consultan las expectativas del IPC

---

<sup>3</sup> “El Instituto Nacional de Estadística es un organismo público que tiene por objetivo la elaboración, supervisión y coordinación de las estadísticas nacionales.” (INE (2020)).

y costos propios (entre otros datos) a muchas empresas formadoras de precios en el país. Esto la convierte en una herramienta diferente a las encuestas de expectativas de analistas profesionales, quienes también realizan proyecciones pero no son agentes fijadores de precios como las empresas.

De los datos recogidos por la encuesta, para el presente trabajo se utiliza únicamente la correspondiente a las expectativas de inflación a 12 meses. Concretamente, la respuesta a la pregunta “¿Cuál cree usted que será la variación del IPC (Índice de Precios del Consumo) en los próximos 12 meses?” es el dato que se toma como expectativa de inflación de las empresas.

Las respuestas de las empresas consideradas para este trabajo van desde octubre 2009 hasta junio 2020, resultando en una base de datos de panel con un total de 129 meses (observaciones) y 99 empresas. Las empresas seleccionadas para el análisis son aquellas que reportan pronósticos de inflación a 12 meses para al menos un 95% de los meses, resultando en 99, las cuales representan un 36% del total de firmas que presentaron pronósticos de forma regular<sup>4</sup>. Dicha depuración pretende dejar dentro de la muestra solo aquellas empresas que contestan la encuesta asiduamente y que han estado presente tanto al inicio como al final del período considerado, a fin de contar con una muestra relativamente estable para todo el horizonte temporal.<sup>5</sup>

De las 99 firmas que integran la base de datos depurada, 90 no reportaron pronósticos para al menos uno de los 129 meses, siendo 2,6 el promedio de meses que las firmas no realizaron pronósticos. Por otra parte, ninguna empresa omitió informar pronósticos para más de 6 meses en todo el período, siendo solo 9 empresas (9%) las que alcanzaron ese máximo. Debido a que es necesario contar con un panel sin datos faltantes para poder utilizar los métodos adaptive-Lasso, Lasso y Ridge, dichos faltantes fueron completados imputando el último dato disponible. Es decir, para cada mes donde alguna firma no realizó el pronóstico, se repitió el valor del pronóstico inmediato anterior<sup>6</sup>.

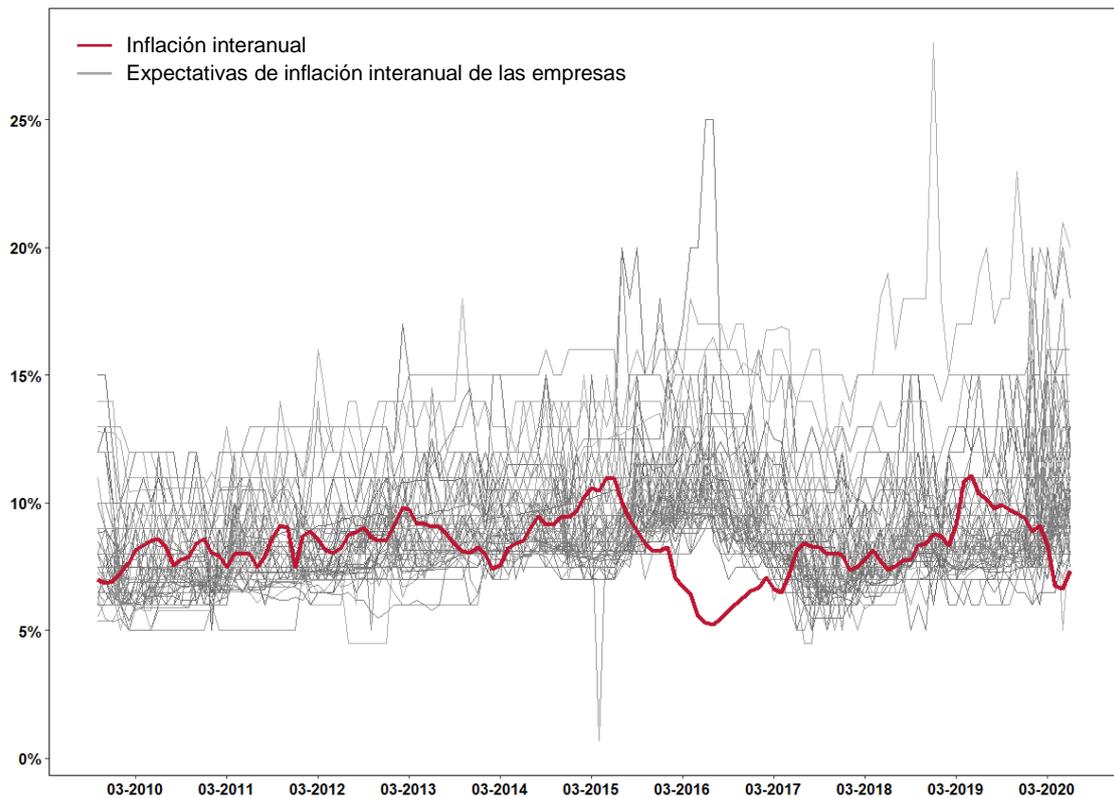
---

<sup>4</sup> Estas son definidas como aquellas empresas que presentan respuestas para más de tres cuartas partes del período considerado.

<sup>5</sup> Si bien la depuración realizada puede modificar la representatividad de la muestra, esta no es un requisito necesario para seleccionar los predictores.

<sup>6</sup> Solo para una firma no fue posible realizar este procedimiento debido a que no participó del primer mes de la encuesta. En ese caso, se imputó el dato del mes siguiente.

**Figura 1. Expectativas de empresas vs Inflación observada**



Fuente: Elaboración propia en base a datos de INE-BCU.

Como se muestra en la Figura 1, a lo largo del período existe una creciente discrepancia entre las expectativas de las empresas y la inflación efectivamente observada, un hecho estilizado que ha sido estudiado por Borraz y Zacheo (2018) y Frache y Lluberas (2019). Otras conclusiones de estos trabajos son que las empresas muestran un grado de atención muy alto sobre las condiciones actuales de la inflación y que las proyecciones de las empresas son más precisas que las de los analistas profesionales que recoge el BCU, lo que justifica explotar aún más la información proporcionada por estas empresas, tal como se intenta hacer en este trabajo.

**Tabla 1. Estadísticos de los pronósticos de inflación interanual de las empresas por mes**

Fecha	Media	Mediana	Moda	Desvío Estándar	Mín.	Máx.	Fecha	Media	Mediana	Moda	Desvío Estándar	Mín.	Máx.
2009-10	8,26	8,00	8,00	1,87	5,40	15,00	2015-03	9,12	8,50	8,00	1,73	7,00	16,00
2009-11	8,12	7,50	7,00	1,90	5,40	15,00	2015-04	9,10	8,50	8,00	1,86	0,70	16,00
2009-12	7,78	7,00	7,00	1,70	5,35	14,00	2015-05	9,09	8,50	8,00	1,72	7,00	16,00
2010-01	7,16	7,00	6,00	1,42	5,00	13,00	2015-06	9,20	9,00	8,00	1,66	7,00	16,00
2010-02	7,30	7,00	6,00	1,56	5,00	12,00	2015-07	9,46	9,00	9,00	1,96	7,50	20,00
2010-03	7,44	7,00	6,00	1,61	5,00	12,00	2015-08	9,54	9,00	9,00	1,66	7,50	18,00
2010-04	7,50	7,00	7,00	1,60	5,00	12,00	2015-09	10,20	9,60	9,00	1,95	8,00	20,00
2010-05	7,51	7,00	7,00	1,50	5,00	12,00	2015-10	9,99	9,50	9,00	1,63	7,00	15,00
2010-06	7,71	7,00	7,00	1,62	5,00	12,00	2015-11	9,95	9,50	9,00	1,55	8,00	16,00
2010-07	7,65	7,00	7,00	1,45	5,00	12,00	2015-12	10,13	10,00	9,00	1,74	8,00	18,00
2010-08	7,67	7,00	7,00	1,42	5,00	12,00	2016-01	10,24	10,00	10,00	1,54	8,00	16,00
2010-09	7,67	7,00	7,00	1,35	5,00	11,00	2016-02	10,24	10,00	9,00	1,73	7,00	16,00
2010-10	7,62	7,25	7,00	1,29	5,00	12,00	2016-03	10,66	10,00	10,00	1,74	8,00	17,00
2010-11	7,80	7,50	7,00	1,37	5,00	12,00	2016-04	10,76	10,00	10,00	1,98	8,00	20,00
2010-12	7,60	7,00	7,00	1,22	5,00	11,00	2016-05	10,77	10,00	10,00	1,85	8,50	20,00
2011-01	7,49	7,00	7,00	1,15	5,00	11,20	2016-06	11,07	11,00	10,00	2,15	9,00	25,00
2011-02	7,68	7,00	7,00	1,28	5,00	12,00	2016-07	10,98	10,00	10,00	2,22	8,50	25,00
2011-03	7,84	7,50	7,00	1,31	5,00	13,00	2016-08	10,59	10,00	10,00	1,76	8,00	17,00
2011-04	8,46	8,00	8,00	1,35	5,00	12,00	2016-09	10,32	10,00	10,00	1,73	7,00	16,00
2011-05	8,48	8,00	8,00	1,43	5,00	12,00	2016-10	10,17	10,00	10,00	1,68	7,50	17,00
2011-06	8,55	8,00	8,00	1,51	5,00	13,00	2016-11	9,97	9,50	10,00	1,73	7,50	17,00
2011-07	8,52	8,00	8,00	1,48	5,00	13,00	2016-12	9,72	9,30	10,00	1,70	7,50	15,20
2011-08	8,55	8,20	8,00	1,54	5,00	13,00	2017-01	9,55	9,00	9,00	1,66	7,00	16,00
2011-09	8,55	8,20	8,00	1,44	5,00	13,00	2017-02	9,58	9,00	9,00	1,70	7,00	16,80
2011-10	8,60	8,00	8,00	1,56	5,00	14,00	2017-03	9,36	9,00	9,00	1,85	6,15	16,80
2011-11	8,56	8,00	8,00	1,48	5,00	13,00	2017-04	9,29	9,00	9,00	1,92	6,50	16,90
2011-12	8,51	8,00	8,00	1,47	5,00	13,00	2017-05	9,13	9,00	9,00	1,86	6,00	16,80
2012-01	8,40	8,00	8,00	1,24	6,20	13,00	2017-06	8,78	8,50	9,00	1,77	5,00	15,00
2012-02	8,47	8,00	8,00	1,47	6,00	13,00	2017-07	8,65	8,40	8,00	1,92	4,50	15,00
2012-03	8,52	8,00	8,00	1,72	6,00	16,00	2017-08	8,48	8,00	9,00	2,05	4,50	16,00
2012-04	8,44	8,00	8,00	1,54	6,00	14,00	2017-09	8,32	8,00	9,00	1,94	5,50	16,00
2012-05	8,53	8,00	8,00	1,50	6,00	13,00	2017-10	8,29	8,00	9,00	1,89	5,00	15,00
2012-06	8,69	8,50	8,00	1,45	6,00	13,00	2017-11	8,21	8,00	7,00	1,78	5,00	15,00
2012-07	8,70	8,50	8,00	1,47	4,50	14,00	2017-12	8,21	8,00	7,00	1,87	5,00	15,00
2012-08	8,59	8,50	8,00	1,45	4,50	14,00	2018-01	8,06	8,00	7,00	1,54	5,50	14,00
2012-09	8,66	8,50	8,00	1,38	4,50	13,00	2018-02	8,25	8,00	7,00	1,72	5,00	15,00
2012-10	8,83	8,80	8,00	1,53	4,50	13,00	2018-03	8,32	8,00	7,00	1,71	5,85	15,00
2012-11	9,01	9,00	8,00	1,54	4,50	14,00	2018-04	8,31	8,00	7,00	1,73	6,00	15,00
2012-12	9,10	9,00	8,00	1,58	4,50	14,00	2018-05	8,50	8,00	8,00	1,88	6,00	18,00
2013-01	8,76	8,50	8,00	1,36	6,00	14,00	2018-06	8,59	8,00	8,00	1,91	6,00	19,00
2013-02	8,98	9,00	9,00	1,66	6,00	17,00	2018-07	8,65	8,00	8,00	1,68	6,00	16,00
2013-03	8,98	9,00	9,00	1,60	6,00	15,00	2018-08	8,86	8,50	8,00	1,86	6,50	18,00
2013-04	9,03	9,00	9,00	1,57	6,00	15,00	2018-09	9,31	9,00	8,00	2,04	5,00	18,00
2013-05	8,97	8,50	8,00	1,63	6,00	15,00	2018-10	9,15	9,00	8,00	1,87	6,00	18,00
2013-06	8,95	8,50	8,00	1,65	5,80	15,00	2018-11	8,98	8,50	8,00	1,74	5,00	18,00
2013-07	8,93	8,50	8,00	1,50	6,00	15,00	2018-12	9,01	8,50	8,00	2,35	6,00	28,00
2013-08	8,98	8,50	8,00	1,39	6,00	15,00	2019-01	8,68	8,00	8,00	1,46	7,00	18,00
2013-09	9,07	9,00	9,00	1,44	6,00	15,00	2019-02	8,81	8,30	8,00	1,65	6,00	15,00
2013-10	9,33	9,00	9,00	1,70	6,00	18,00	2019-03	8,78	8,20	8,00	1,75	6,00	17,00
2013-11	9,26	9,00	9,00	1,57	6,00	15,00	2019-04	8,86	8,40	8,00	1,75	6,00	17,00
2013-12	9,16	9,00	9,00	1,44	6,00	15,00	2019-05	8,94	8,50	8,00	1,80	6,00	17,00
2014-01	9,09	9,00	9,00	1,29	7,00	15,00	2019-06	9,10	8,50	8,00	2,00	6,00	19,00
2014-02	9,38	9,00	9,00	1,42	7,00	15,00	2019-07	8,93	8,30	8,00	2,01	6,00	20,00
2014-03	9,44	9,00	9,00	1,41	7,00	15,00	2019-08	8,89	8,38	8,00	1,83	6,00	17,00
2014-04	9,49	9,00	9,00	1,39	7,00	15,00	2019-09	9,03	8,50	8,00	1,97	6,00	18,00
2014-05	9,41	9,00	9,00	1,35	7,00	15,00	2019-10	9,03	8,50	8,00	1,77	6,00	18,00
2014-06	9,43	9,00	9,00	1,47	7,30	15,00	2019-11	9,13	8,50	8,00	2,12	6,50	23,00
2014-07	9,48	9,00	9,00	1,44	7,50	15,00	2019-12	9,07	8,50	8,00	1,75	6,50	19,00
2014-08	9,57	9,00	9,00	1,43	7,50	15,00	2020-01	9,75	9,00	9,00	2,67	6,00	20,00
2014-09	9,59	9,00	9,00	1,66	7,50	16,00	2020-02	9,24	9,00	9,00	1,99	6,00	20,00
2014-10	9,50	9,00	9,00	1,49	7,40	15,00	2020-03	9,94	9,00	9,00	2,46	6,50	20,00
2014-11	9,42	9,00	9,00	1,53	7,00	15,00	2020-04	10,47	10,00	9,00	2,19	6,50	18,00
2014-12	9,10	9,00	9,00	1,55	7,00	16,00	2020-05	10,47	10,00	9,00	2,52	5,00	21,00
2015-01	9,06	9,00	9,00	1,44	7,00	16,00	2020-06	10,40	10,00	10,00	2,14	7,50	20,00
2015-02	9,07	8,50	8,00	1,68	7,00	16,00							

Fuente: Elaboración propia en base a datos de INE-BCU.

En la Tabla 1. Estadísticos de los pronósticos de inflación interanual de las empresas se presentan estadísticos para el conjunto de empresas para cada mes de la encuesta mientras que en la Tabla 2 se muestran estadísticos para cinco series que abarcan todo el período analizado: inflación anual, media y mediana de los pronósticos de las empresas y media y mediana de los pronósticos de los analistas. Tal como se puede apreciar, la media y mediana de los analistas se encuentran por debajo de la

media y mediana de inflación, mientras que con las empresas ocurre lo contrario. Adicionalmente, la inflación es la variable que presenta más amplitud de rango en sus valores, así como el mayor desvío sobre su media.

**Tabla 2. Estadísticos período completo (octubre 2009 a junio 2020)**

<b>Variable</b>	<b>Media</b>	<b>Mediana</b>	<b>Desvío Estándar</b>	<b>Mín.</b>	<b>Máx.</b>
Inflación 12 meses	8,29	8,27	1,18	5,24	11,05
Media Empresas	8,97	8,98	0,83	7,16	11,07
Mediana Empresas	8,55	8,50	0,84	7,00	11,00
Media Analistas	7,66	7,69	0,86	5,98	9,85
Mediana Analistas	7,65	7,60	0,86	6,00	9,80

Fuente: Elaboración propia en base a datos de INE-BCU.

#### **4. Metodología**

En este trabajo se utilizan cuatro de los métodos de aprendizaje automático más conocidos en la literatura. Estos son: Least Absolute Shrinkage and Selection Operator (Lasso), adaptive-Lasso, Regresión Ridge y Random Forest (también denominado Bosques Aleatorios). En este caso se trata de métodos de aprendizaje automático supervisados, en los cuales, a diferencia de los no supervisados, se cuenta con los datos tanto de los predictores ( $X_i$ ) como del resultado ( $Y_i$ ) para todas las observaciones. Con estos datos en cuenta, se entrena un modelo cuyo objetivo principal consiste en realizar predicciones fuera de la muestra y con la mayor precisión posible. Es importante destacar que estos métodos no presuponen que la distribución condicional de los resultados dada las covariables siga un modelo paramétrico particular, ya que los pronósticos los realizan “aprendiendo” de los propios datos.

Uno de los aspectos más desafiantes de este trabajo es aplicar estos modelos a series temporales, dado que resulta más complejo y la literatura sobre este tema está menos extendida. Tal como indican Chakraborty y Joseph (2017), los enfoques de aprendizaje automático son en su mayoría de naturaleza transversal, es decir, no tienen en cuenta explícitamente el tiempo. Un muestreo aleatorio para estimar y testear un modelo puede ser un problema cuando se enfrenta una dimensión temporal, dado que el muestreo aleatorio no permite manejar adecuadamente la información presente en una serie temporal, como la estacionalidad o tendencia, pudiendo llevar a errores en las interpretaciones y conclusiones. Para solucionar esta dificultad se utiliza un enfoque de ventana corrediza, el cual se detalla más adelante, cuya ventaja principal es que mantiene las observaciones ordenadas en el tiempo, aprovechando así la información histórica de la serie.

En el presente análisis se divide la muestra en dos partes: i) la muestra de entrenamiento, donde se estiman los modelos para pronosticar; y ii) la muestra de testeo, donde se evalúa la capacidad de predicción. Tanto para los pronósticos realizados con los métodos de aprendizaje automático como para los pronósticos de referencia, se utiliza el mismo período de testeo a efectos de hacer comparable la precisión de cada método. Concretamente, se considera el período que va desde octubre de 2017 hasta junio de 2020 (33 meses) como muestra de testeo. Esto corresponde aproximadamente al 25% del total de la muestra, lo que implica un ratio de 75:25 entre entrenamiento y testeo<sup>7</sup>. Al realizar el testeo se calcula el Error Cuadrático Medio y su raíz para cada método y en base a esto se determinan los mejores métodos de predicción.

Cada modelo utilizado para pronosticar se entrena con información disponible hasta el período  $t^8$ , realizando así la selección de variables y la estimación de parámetros correspondientes. Luego, con las variables seleccionadas y sus valores para el período  $t$  se realiza la predicción de la inflación a un paso, es decir, a  $t+12$  (12 meses). Este procedimiento se realiza para todos los meses dentro del período de testeo, utilizando el enfoque de la ventana corrediza<sup>9</sup>. Esta técnica implica que el conjunto de datos de entrenamiento se expanda progresivamente a lo largo del tiempo, de forma que  $t$  se va “corriendo” mes a mes tal como se observa en la Figura 2. Por su parte, el testeo se realiza para cada  $t+12$  del horizonte restante, el cual se va reduciendo a medida que aumenta  $t$  y finaliza cuando  $t$  alcanza en junio 2020. En ese momento se compara la predicción realizada en dicho mes con la inflación observada en junio 2021. De esta forma se obtiene un error de predicción diferente para cada mes dentro de los 33 meses correspondientes al período de testeo. Estos errores de predicción son utilizados para calcular la RECM y así evaluar la capacidad de predicción de los diferentes métodos.

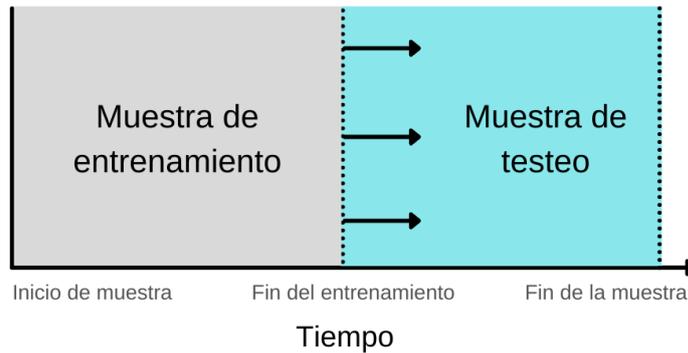
---

<sup>7</sup> Si bien no hay un ratio estándar o definitivo, la mayor parte de los trabajos consultados así como algunas recomendaciones sugieren ratios que varían entre 60:40 y 80:20. Aquí se presentan resultados para el ratio 75:25 pero también se probó con los ratios 65:35 y 85:15, encontrando resultados similares.

<sup>8</sup> El mes  $t$  corresponde al mes en que las empresas revelan sus expectativas. Para la estimación del modelo se utilizan dichas expectativas hasta  $t-12$  y el dato de inflación en  $t$ .

<sup>9</sup> El enfoque utilizado aquí es una variante del *Sliding window approach* descrito en Chakraborty y Joseph (2017).

Figura 2. Ventana corrediza

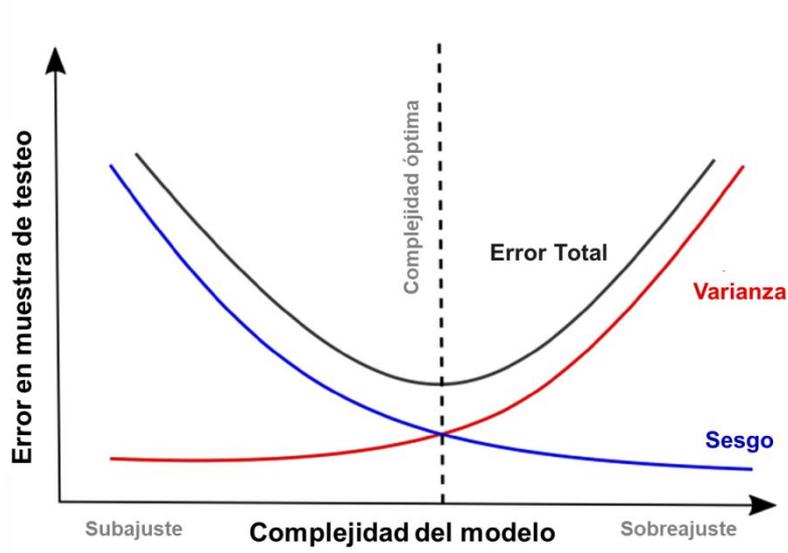


Fuente: Elaboración propia en base a Chakraborty y Joseph (2017).

### a. Lasso, adaptive-Lasso y Regresión Ridge

En este trabajo se utilizan tres técnicas de regularización muy conocidas para ajustar modelos lineales, como son Lasso, adaptive-Lasso y regresión Ridge. Se conocen como métodos de contracción, porque los coeficientes estimados se reducen hacia cero en comparación con la estimación de mínimos cuadrados ordinarios (MCO). De este modo, la varianza puede reducirse significativamente a costa de aceptar cierto grado de sesgo en la estimación. Esto igualmente es útil, porque un estimador sesgado pero con menos varianza puede resultar más eficiente para predecir que uno no sesgado, en especial cuando el criterio para medir la eficiencia es la RECM. Tal como se muestra en la Figura 3, el error total en la muestra de testeo puede ser reducido encontrando un equilibrio entre sesgo y varianza que evite un sobreajuste o subajuste del modelo. Otra ventaja que poseen estos métodos es que no son computacionalmente costosos en la actualidad, lo que ha contribuido a popularidad en los últimos años.

Figura 3. Trade off: Sesgo – Varianza



Fuente: Elaboración propia en base a Chakraborty y Joseph (2017).

i. *Regresión Ridge*

La técnica de regresión Ridge fue propuesta inicialmente por Hoerl y Kennard (1970). Utilizando esta técnica es posible estimar un modelo que incluya todos los predictores (variables) pero que reduzca sus coeficientes a valores más cercanos a cero (en relación con los de MCO). A su vez, la regresión Ridge reduce los coeficientes de los predictores correlacionados entre sí, lo que resulta conveniente cuando hay muchos predictores y todos tienen coeficientes distintos de cero (Friedman et al. (2010)).

La ecuación de la regresión Ridge es bastante similar a la de los mínimos cuadrados, con la salvedad de que la ecuación a minimizar contiene un término adicional a la tradicional suma del cuadrado de los residuos (SCR) que minimiza MCO. En particular, los coeficientes de Ridge son el resultado de minimizar la siguiente ecuación:

$$\hat{\beta}^R = \arg \min_{\hat{\beta}^R} \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p \beta_j^2 = \arg \min_{\hat{\beta}^R} \text{SCR} + \lambda \sum_{j=1}^p \beta_j^2 \quad (1)$$

donde  $i$  denota el período de tiempo (de 1 a  $n$ ),  $j$  indica el predictor (de 1 a  $p$ ),  $y_i$  es la variable de interés,  $x_{ij}$  corresponde al valor del predictor  $j$  en  $i$ ,  $\beta_j$  es el coeficiente asociado a  $x_{ij}$  y  $\lambda \geq 0$  es un parámetro de ajuste que debe determinarse por separado.

Al igual que en MCO, es importante que los coeficientes se ajusten bien a los datos y reduzcan la suma de cuadrado de los errores (SCE), pero a diferencia de este, se incluye un término de penalización  $(\lambda \sum_{j=1}^p \beta_j^2)^{10}$ . Por lo tanto, la capacidad predictiva puede mejorarse evitando un sobreajuste del modelo a los datos. Una vez que lambda ( $\lambda$ ) está determinado, la penalización disminuye a medida que los coeficientes se acercan a cero y aumenta a la inversa. Es importante destacar que cuando  $\lambda = 0$  el resultado es el mismo que MCO, pero cuando crece  $\lambda$  aumenta la penalización y los coeficientes se aproximan a cero.

El parámetro de ajuste  $\lambda$  puede ser determinado de varias maneras. El procedimiento completo utilizado en este trabajo se puede encontrar en Hastie y Qian (2016)<sup>11</sup>, pero esencialmente consiste en construir una secuencia de muchos  $\lambda$  (1000 en este caso) en un rango predefinido y estimar un modelo para cada valor de ese  $\lambda$ . Asociado a cada valor de  $\lambda$  hay un vector de coeficientes que minimiza la ecuación de la regresión Ridge. Una vez que tenemos todos los pares de  $\lambda$  y vector de coeficientes asociados, se selecciona para la predicción el par que conduce a la RECM más baja.

## ii. Lasso

El método Lasso fue introducido por Robert Tibshirani en 1996 como una alternativa a Regresión Ridge y Subset Selection (selección de subconjuntos), conservando una característica principal (y ventajosa) de cada método: la interpretabilidad de Subset Selection y la estabilidad de Regresión Ridge (Tibshirani (1996)). El objetivo principal de este método es descartar las variables irrelevantes reduciendo a cero sus coeficientes en la regresión. Esa es la principal diferencia entre Lasso y Ridge, ya que este último no descarta ningún predictor (excepto en el caso hipotético en que  $\lambda = \infty$ ). Un atributo notable de Lasso es que, con una alta

---

<sup>10</sup> Notar que la penalización no se aplica al intercepto  $\beta_0$ .

<sup>11</sup> Se utiliza la función `glmnet` (disponible en el paquete `glmnet`) en el software RStudio, el cual minimiza las ecuaciones de Ridge y Lasso para una grilla de  $\lambda$  seleccionada de forma automática.

probabilidad, se seleccionan todas las variables importantes, incluso si el número de predictores es muy superior al número de observaciones (Meinshausen y Yu (2009)).

Si observamos la función que se debe minimizar (ecuación 2) notamos que la diferencia con la función de Ridge radica en el término de penalización. Este último incluye el valor absoluto de  $\beta_j$  en lugar de su cuadrado, y este cambio en la penalización hace que algunos coeficientes estimados sean exactamente cero cuando  $\lambda$  es lo suficientemente grande.

$$\hat{\beta}^L = \arg \min_{\hat{\beta}^L} \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p |\beta_j| = \arg \min_{\hat{\beta}^L} \text{SCR} + \lambda \sum_{j=1}^p |\beta_j| \quad (2)$$

Tanto el valor de  $\lambda$  como los coeficientes  $\hat{\beta}$  son calculados de la misma forma que para el método Regresión Ridge.

### iii. *Adaptive-Lasso*

El método adaptive-Lasso (ada-Lasso) es una variante del método Lasso. Este último método permite realizar simultáneamente selección de variables y estimación de parámetros, a efectos de lograr predicciones óptimas. Sin embargo, tal como señala Zou (2006), hay escenarios en los que Lasso puede no ser consistente debido al conflicto que existe entre el  $\lambda$  óptimo para la predicción y aquel para la selección de variables. Concretamente, como demuestran Leng et al. (2006), cuando  $\lambda$  es fijado basándose en la precisión de predicción, en general el modelo no es consistente en términos de selección de variables, por lo que el set de variables relevantes seleccionadas no tiene alto grado de probabilidad de ser asintóticamente identificado. En otras palabras, los autores muestran que la probabilidad de seleccionar el conjunto verdadero de variables relevantes en la regresión lineal no necesariamente aumenta al aumentar el número de observaciones, pudiendo esta probabilidad tener un valor inferior a 1 y constante (independiente del número de observaciones).

Para solucionar este problema de inconsistencia Zou (2006) desarrolla el método adaptive-Lasso, el cual, a diferencia de Lasso, cumple con las propiedades del oráculo. Es decir, produce un estimador  $\hat{\beta}^{al}$  tal que, de forma asintótica, i) identifica el

modelo correcto y ii) estima los coeficientes de forma óptima<sup>12</sup>. Medeiros y Mendes (2015) muestran que estas propiedades se mantienen aún cuando los errores son no gaussianos y condicionalmente heterocedásticos. La solución que propone el autor implica modificar la ecuación de Lasso introduciendo un ponderador en el segundo término a efectos de que el peso de la penalización sea distinto para cada variable incluida en el modelo. En particular, esta generalización de Lasso busca imponer mayores penalizaciones sobre las variables menos relevantes. De esta forma, la función a minimizar pasa a ser la siguiente:

$$\hat{\beta}^{aL} = \arg \min_{\hat{\beta}^{aL}} \sum_{i=1}^n \left( y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p w_j |\beta_j| = \arg \min_{\hat{\beta}^{aL}} SCR + \lambda \sum_{j=1}^p w_j |\beta_j| \quad (3)$$

donde  $w_j = 1/|\hat{\beta}_j^*|^\gamma$ . Esta ecuación se resuelve en dos etapas, dado que primero deben escogerse  $\gamma > 0$  y  $\hat{\beta}_j^*$  para luego minimizar la función. El valor  $\gamma$  determina qué tanto se enfatiza en los ponderadores las diferencias entre los distintos  $\hat{\beta}_j^*$ , valores superiores a 1 amplifican la ponderación mientras que inferiores a 1 la disminuyen. Por otra parte, los valores de  $\hat{\beta}_j^*$  pueden ser estimados mediante, por ejemplo, MCO o Ridge, tal como sugiere el propio autor del método. En esta construcción, las variables relevantes tienden a tener coeficientes  $\hat{\beta}_j^*$  mayores, lo que resulta en un  $w_j$  más bajo, y lo mismo ocurre a la inversa (Konzen y Ziegelmann (2016)).

Es importante notar que adaptive-Lasso también presenta sesgo hacia cero en la estimación de los coeficientes no nulos, aunque este sesgo es mucho menor que el que presenta Lasso, en especial en los coeficientes grandes.

Por otra parte, si bien la inconsistencia de Lasso a priori no presenta un problema para el alcance de este trabajo, igualmente pueden lograrse mejoras en términos de predicción utilizando esta adaptación de Lasso. Por este motivo, resulta conveniente presentar el método y explicar las diferencias con el Lasso original para luego aplicarlo y comparar los resultados empíricos de este caso concreto.

---

<sup>12</sup> Más formalmente: con  $\lambda / \sqrt{n} \rightarrow 0$  y  $\lambda n^{(\gamma-1)/2} \rightarrow \infty$  se cumple i)  $\lim_{n \rightarrow \infty} P(A_n = A) \rightarrow 1$  con

$A_n = \{j : \hat{\beta}_j \neq 0\}$  y  $A = \{j : \beta_j \neq 0\}$  y ii)  $\sqrt{n}(\hat{\beta}_A - \beta_A) \rightarrow_d N(0, \Sigma^*)$  donde  $\Sigma^*$  es la matriz de covarianzas conociendo el modelo correcto.

## **b. Random Forest**

Este es un método introducido por Breiman et al. (1984) que se basa en la construcción de predictores utilizando como base el método Classification And Regression Tree (CART). Este método también se utiliza para predecir y es aplicable tanto a una regresión (si estamos modelando una variable continua) como a una clasificación (si la variable objetivo es categórica). CART parte de un nodo raíz (muestra) el cual se divide de forma binaria y recursiva hasta llegar a los nodos terminales, los cuales servirán para realizar las predicciones. La división del nodo terminal se realiza en base a una regla de decisión aplicada a una de las variables explicativas  $X_i$ , lo cual genera dos nuevos nodos de decisión, donde se vuelve a realizar el mismo procedimiento hasta llegar a los nodos terminales.

CART es un método no paramétrico, por lo que no se hacen suposiciones sobre la distribución de los valores de las variables de predicción, y además tiene la virtud de ser transparente y fácil de interpretar y comunicar. Sin embargo, dicho método presenta algunos inconvenientes, principalmente asociados a la inestabilidad que surge debido a la forma en que se realiza cada división. Por un lado, la elección de la variable en base a la cual realizar la división no siempre es inequívoca y, por otro, un pequeño cambio en la muestra puede generar grandes cambios en el árbol de decisión y, por ende, en las predicciones, reflejando un problema de sobreajuste (Li y Belford (2002)).

Para superar los inconvenientes que surgen del método CART se puede utilizar el método Random Forest. Esta técnica desarrollada por Breiman (2001) consiste básicamente en la agregación de muchos árboles elaborados en base a CART y, para el caso de las regresiones, realiza predicciones en base al promedio de las predicciones individuales de cada árbol. Random Forest construye los  $n$  árboles realizando bootstrap en la muestra de entrenamiento pero limitando la cantidad de predictores a ser utilizados en cada árbol y seleccionándolos de manera aleatoria. Por un lado, la creación de varios árboles de decisión permite reducir la varianza presente en CART y, por otro lado, la selección aleatoria de predictores ayuda a evitar altos niveles de autocorrelación entre los distintos árboles. De esta forma, se mejoran las predicciones obtenidas mediante CART y se superan las debilidades presentes en otros métodos alternativos a este tales como Bagging o Bootstrap Aggregation.

Más formalmente, Random Forest para problemas de regresión puede describirse de la siguiente manera: considerando que hay  $p$  predictores ( $X_1, X_2, \dots, X_p$ ) y una variable de respuesta continua a ser pronosticada ( $Y$ ), un árbol de regresión divide un conjunto de valores posibles de  $X_1, X_2, \dots, X_p$  en dos regiones diferentes y no superpuestas. Para realizar dicha división se selecciona un predictor  $j$  y un valor determinado de dicho predictor como punto de división ( $s$ ) de forma tal se minimice la siguiente expresión:

$$\sum_{i: x_i \in R1(j,s)} (y_i - \bar{y}_{R1})^2 + \sum_{i: x_i \in R2(j,s)} (y_i - \bar{y}_{R2})^2 \quad (4)$$

donde  $R1(j,s) = \{X / X_j < s\}$ ,  $R2(j,s) = \{X / X_j \geq s\}$ ,  $\bar{y}_{R1}$  es el promedio de las observaciones de  $Y$  en la región 1 y  $\bar{y}_{R2}$  en la región 2. El predictor  $j$  se selecciona de un subconjunto de  $m < p$  predictores elegidos aleatoriamente (generalmente  $m \cong p/3$ ).

Seguidamente se realiza el mismo procedimiento sobre todas las regiones subsiguientes hasta llegar a los nodos terminales. Estos son alcanzados cuando se cumple un criterio determinado previamente, por ejemplo, cuando la región tenga menos de cierto número de observaciones.

Este procedimiento se repite varias veces hasta obtener un “bosque” de muchos árboles construidos en base a distintos sub-conjuntos de predictores seleccionados de forma aleatoria. De ahí el nombre de “bosques aleatorios” o Random Forest.

Para la implementación de Random Forest en este análisis se utiliza la función *randomForest* incluida en el paquete con mismo nombre<sup>13</sup>. Tal como se indica en Rodríguez (2020) para la implementación de Random Forest los parámetros que usualmente deben determinarse son:

- Número árboles que se van a crear: se necesita un número lo suficientemente grande para mejorar los resultados de la predicción pero que no sea

---

<sup>13</sup> Para una descripción completa sobre el paquete ver Liaw y Wiener (2002).

computacionalmente muy costoso. En base a la argumentación y conclusiones de Probst y Boulesteix (2018) en el presente trabajo se crean 100 árboles<sup>14</sup>.

- Número mínimo de observaciones admisibles en los nodos terminales: 5 (valor por defecto del paquete *randomForest*).
- Número de predictores que se van a incluir para la división en cada árbol: se calibra para cada pronóstico, seleccionando número de predictores que resulte en el mínimo error out-of-bag (es decir, error de predicción calculado usando las observaciones que quedaron fuera de la muestra al realizar bootstrap)<sup>15</sup>.

Considerando el término  $\pi_{t+12}$  como la inflación observada en  $t+12$  y  $P_t^i \pi_{t+12}$  como el pronóstico de inflación a 12 meses del método  $i$  en el momento  $t$ , se define el error de predicción ( $EP_{t,t+12}^i$ ) del método  $i$  sobre la inflación en  $t+12$  como:

$$EP_{t,t+12}^i = \pi_{t+12} - P_t^i \pi_{t+12} \quad (5)$$

Por lo tanto, el ECM/RECM utilizado para comparar la capacidad de predicción de las distintas metodologías es calculada en base a  $EP_{t,t+12}^i$ . Notar que si bien los dos términos refieren al mismo período ( $t+12$ ),  $P_t^i \pi_{t+12}$  es un dato que está disponible en  $t$ , mientras que  $\pi_{t+12}$  recién se observa en  $t+12$ .

La estimación del modelo utilizado para hacer la predicción final se realiza con las proyecciones de las firmas dentro de la muestra de entrenamiento, la cual no es fija, dado que para cada predicción final se agrega un mes a la muestra de entrenamiento tal como ya se describió. Concretamente, para la primera predicción, el período que abarca la muestra de entrenamiento comienza en octubre 2009 y finaliza en octubre 2017. Se estima un modelo en base a las proyecciones realizados hasta octubre 2016 y los valores de inflación observados. A ese modelo estimado se le imputan las proyecciones de inflación a 12 meses realizados por las empresas en octubre 2017, obteniendo así el pronóstico de inflación a 12 meses. Luego, se realiza el testeo comparando este valor contra el efectivamente observado en octubre 2018 y se obtiene un error de predicción. Para la segunda predicción se repite el procedimiento, pero esta vez la muestra de entrenamiento se amplía, dado que incluye

<sup>14</sup> Los autores muestran que si bien un mayor número de árboles puede mejorar las predicciones, la mayor ganancia en estas generalmente se obtiene al entrenar los primeros 100 árboles.

<sup>15</sup> Se fija 5 como valor inicial y se procede automáticamente con la búsqueda de valores menores y mayores que reduzcan el error out of bag a efectos de seleccionar el óptimo.

también noviembre 2017. Realizando sucesivamente este procedimiento para los meses subsiguientes se obtienen 33 predicciones (hechas entre octubre 2017 y junio 2020), por lo que hay 33 errores de predicción. En base a esos errores se calcula luego el ECM/RECM. Es importante notar que como para cada proyección hay un modelo diferente (entrenado con los datos disponibles hasta el momento), hay 33 modelos diferentes utilizados para predecir. Por lo tanto, lo que luego se comparará es la capacidad de predicción del método utilizado y no la de un modelo específico

## 5. Resultados

En la Tabla 3 se presentan los valores del ECM y RECM para cada uno de los métodos analizados en el período de testeo. Adicionalmente se presenta algunos estadísticos para la serie de inflación interanual así como para las series formadas por las predicciones de cada método durante dicho período. Tal como se puede apreciar, todos los métodos que utilizan la encuesta de empresas como base de datos realizan mejores pronósticos que los métodos que no lo hacen. Asimismo, promediando el pronóstico de estos métodos se obtiene un ECM inferior que utilizando cualquier método individual (*Media Base Encuesta*), y el resultado mejora aún más cuando se promedian solo los 2 mejores métodos (*Media 2MM*): *ada-Lasso* y *Random Forest*. Por otro lado, cuando se considera *Lasso/Ridge*<sup>16</sup> y se calcula la media de los métodos de aprendizaje automático (*Media MAA*), no se logra un mejor resultado que utilizando *ada-Lasso* o *Random Forest* de forma individual. De todas maneras, las diferencias entre las combinaciones mencionadas y los dos mejores métodos considerados individualmente son mínimas, cosa que se puede apreciar en base a los valores de RECM.

---

<sup>16</sup> Para el cálculo de la media se considera uno solo de estos métodos dado que en este trabajo resultaron ser equivalentes.

**Tabla 3. ECM, RECM y Estadísticos**

Método	ECM	RECM	Media	Desvío Estándar	Mín.	Máx.
Ada-Lasso	1.32	1.15	8.38	0.09	8.10	8.62
Random Forest	1.34	1.16	8.32	0.33	7.40	8.66
Lasso	1.47	1.21	8.19	0.04	8.14	8.31
Ridge	1.47	1.21	8.19	0.04	8.14	8.31
Mediana Empresas	1.87	1.37	8.52	0.58	8.00	10.00
Auto-Arima	2.04	1.43	7.91	0.42	7.21	9.07
AR(1)	2.39	1.54	7.90	0.64	6.83	9.67
Mediana Analistas	2.47	1.55	7.70	0.66	6.45	9.28
RB*	2.58	1.61	8.41	1.22	5.54	10.72
<b>Combinaciones de métodos</b>						
Media 2MM	1.29	1.14	8.35	0.15	7.93	8.55
Media Base Encuesta	1.31	1.15	8.47	0.10	8.24	8.67
Media MAA	1.34	1.16	8.30	0.11	8.03	8.45
<b>Inflación 12 meses</b>	-	-	<b>8.57</b>	<b>1.14</b>	<b>6.64</b>	<b>11.05</b>

Fuente: Elaboración propia en base a datos de INE-BCU.

Muestra de entrenamiento: ventana corrediza desde 10/2009-10/2017 hasta 10/2009-06/2020.

Muestra de testeo: ventana corrediza desde 10-2017 hasta 06-2020.

Todos los métodos de aprendizaje automático superan a los de referencia. En particular, el método que arroja un menor RECM, y por tanto mayor eficiencia en la predicción, es *ada-Lasso*. Para este resultado se probaron distintas combinaciones de  $\gamma$ ,  $\hat{\beta}_j^*$  y  $\lambda$ , siendo la siguiente combinación la que logró mejor desempeño en la predicción:  $\gamma = 1$ <sup>17</sup>,  $\hat{\beta}_j^*$  estimados mediante regresión Ridge y  $\lambda$  seleccionados en base al modelo que arroja menor ECM dentro de la muestra. Este mismo criterio se utilizó para seleccionar  $\lambda$  en los métodos *Ridge* y *Lasso*. Para el caso de *Lasso* y *ada-Lasso*, ampliar la grilla de  $\lambda$  fijada por defecto (100 valores) no mejora los resultados de predicción, cosa que sí ocurre para el caso de *Ridge*. Al utilizar una grilla con 1000 valores de  $\lambda$ , el método *Ridge* mejora sus resultados de predicción y se vuelve equivalente a *Lasso*, produciendo ambos el mismo pronóstico para cada período.

Al igual que con los métodos de aprendizaje automático, en los métodos de referencia también se aplicó el mecanismo de la *ventana corrediza*. Para el método *Auto-ARIMA*, se utilizó la función *auto.arima* del paquete *forecast*<sup>18</sup> en RStudio, el cual busca automáticamente el mejor modelo ARIMA que se ajuste a los datos. Para el caso de *AR(1)* se utilizó la función *Arima* del mismo paquete. Por su parte, *RB\** se construyó fijando una constante igual a la media de la inflación en la muestra de entrenamiento, a la que se le suma un ruido blanco simulado con la función *arima.sim* del paquete *stats*<sup>19</sup>, cuya media es cero y su desvío estándar es el observado en la inflación durante el período de entrenamiento. Tanto para la encuesta de analistas

<sup>17</sup> Siguiendo a Zou (2006) se calculan distintos  $w_j$  utilizando los valores {0,5; 1; 2} para el parámetro  $\gamma$ .

<sup>18</sup> Ver Hyndman (2017) y Hyndman y Khandakar (2008).

<sup>19</sup> R Core Team (2013)

como para la de empresas, se presentan los resultados de la mediana de los pronósticos, dado que arrojan un mejor resultado que la media<sup>20</sup>. Dentro de los métodos de referencia, *Mediana Firmas* fue el que mostró mejor desempeño, seguido por los modelos ARIMA. Por su parte, *Mediana Analistas* presentó un ECM apenas inferior que *RB\**, y se destaca por ser el método que presenta la menor media en la serie de pronósticos.

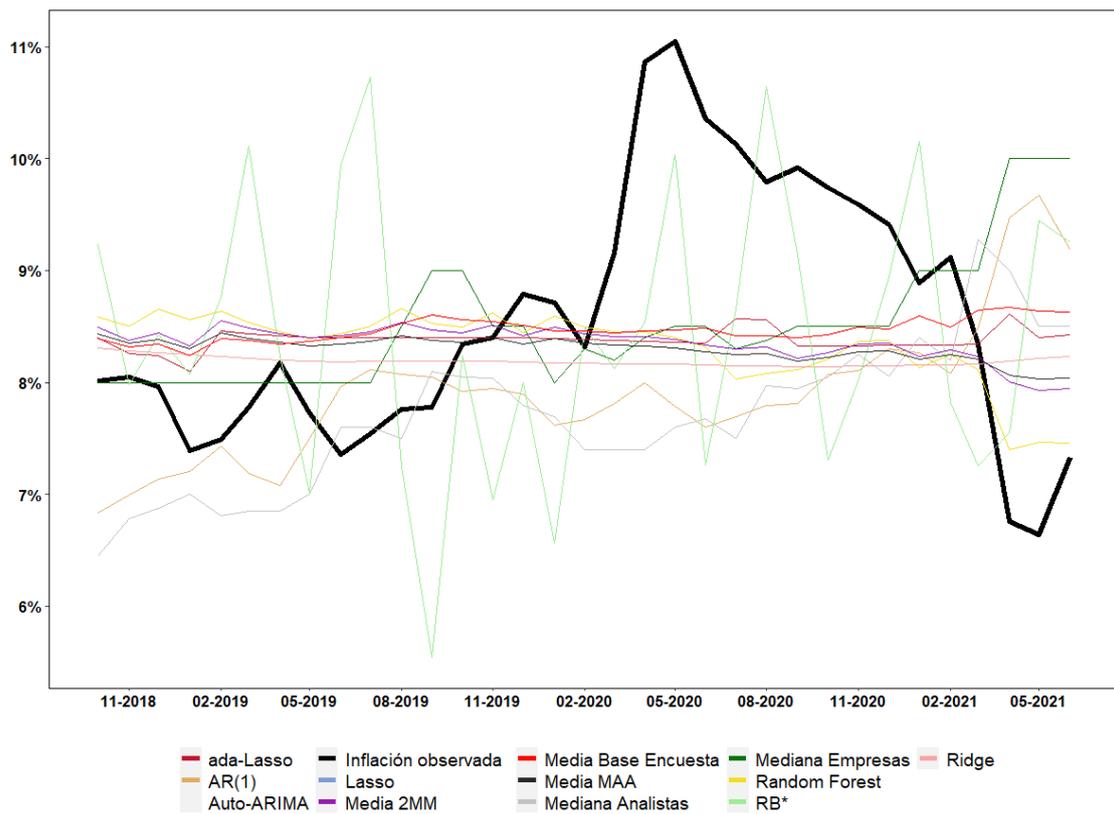
En la Figura 4 se presenta gráficamente el valor de la inflación efectivamente observada en el mes correspondiente y los pronósticos realizados por cada método 12 meses antes. Adicionalmente se presentan las predicciones de cada método para cada mes en la Tabla 4 del Anexo. Tal como se puede apreciar, tanto en el gráfico como en la Tabla 3, los métodos más eficientes (*Media Top 2*, *Media Base Encuesta* y *ada-Lasso*) se mantienen relativamente estables en valores cercanos a su media durante todo el periodo. El método *Ridge/Lasso* es el que menos se desvía de su media, pero también presenta una media inferior que los mejores predictores y de la propia inflación. Por otra parte, los tres métodos con mayor desvío estándar son los que presentan mayor error en la predicción.

Tal como se observa en el gráfico, hay dos momentos donde la inflación se aleja de su media, con picos en mayo 2020 y mayo 2021. En el primer momento, ningún método (excepto *RB\**) logra predecir una suba significativa dado que las predicciones un año antes se mantenían estables. Por otro lado, la baja registrada en abril-mayo 2021 fue pronosticada por *Random Forest* y en menor medida por *Mediana Analistas*, aunque en ambos casos la magnitud de la caída fue subestimada.

---

<sup>20</sup> Para calcular la *Media Base Encuesta* se utiliza la media del pronóstico de empresas en lugar de la mediana, ya que así se obtiene una predicción más precisa.

Figura 4. Comparación de pronósticos



Fuente: Elaboración propia en base a datos de INE-BCU.

Por último, es importante destacar que los principales hallazgos de este trabajo son robustos a cambios en las muestras de entrenamiento y testeo. En particular, cambiar los ratios de entrenamiento y testeo de 75:25 a 65:35 o 85:15 no altera el hecho estilizado de que los mejores predictores son los métodos de aprendizaje automático y las combinaciones realizadas con estos. Considerando los métodos individualmente, *ada-Lasso* es el más eficiente en dos escenarios y el segundo en el escenario restante, en el cual *Random Forest* es el método con menor error de predicción. Existe un único caso donde un método de referencia supera a uno de aprendizaje automático, y se da en el escenario con ratio de entrenamiento/testeo 65:35, donde *Auto-ARIMA* supera a *Random Forest* con una RECM 2,8% menor. En la Tabla 5 y Tabla 6 del Anexo se presentan los resultados resumidos para los otros dos escenarios analizados.

## 6. Comentarios finales

La inflación interanual en Uruguay presenta un grado considerable de volatilidad, lo que dificulta la previsión de su valor. Sin embargo, dada la importancia de dicha

variable, ahondar en alternativas que permitan lograr una mayor precisión en la predicción resulta por demás oportuno. En este trabajo se utilizaron solo cuatro de una amplia variedad de métodos de aprendizaje automático disponibles, y las cuatro técnicas mostraron ser más eficientes en la predicción que los cinco predictores de referencia. Esto da cuenta del potencial de estas técnicas y hace promisoría la exploración otras técnicas alternativas, algunas de las cuales ya han mostrado su potencial en trabajos para otros países tal como se ilustró en la sección 2. Por otra parte, la mediana de las proyecciones de las empresas también mostró mejor desempeño que los otros métodos de referencia, lo que, sumado a los resultados obtenidos con los métodos de aprendizaje automático, permite deducir que la encuesta realizada a las empresas es una fuente de datos que, además de original, puede resultar muy fructífera.

Por otra parte, en lo que respecta a los métodos de aprendizaje automático, es importante destacar que considerando las características ya comentadas de estos métodos y que se utiliza una serie de expectativas como base de datos, no resulta fiable realizar análisis de causalidad o inferencia. De hecho, aunque pueda resultar contra intuitivo, las empresas seleccionadas en los modelos utilizados para la predicción no necesariamente son las mejores realizando predicciones. Esto ocurre debido a que la minimización del error de predicción resulta de una combinación lineal de las empresas, pudiendo quedar incluidas algunas empresas que consideradas individualmente presentan errores de predicción mayores.

Finalmente, al ser este uno de los primeros trabajos que aplica métodos de aprendizaje automático para predecir la inflación en Uruguay y dado que los resultados preliminares son promisorios, queda una puerta abierta para seguir explorando y analizando el tema. Algunas extensiones a considerar serían, por ejemplo, una mayor explotación de la información que brinda la encuesta mediante el uso de otras técnicas de aprendizaje automático, el análisis de otros horizontes de inflación o la utilización de otras variables que resulten relevantes. También resultaría conveniente aplicar estas y otras técnicas de aprendizaje automático sobre otras bases de datos y realizar combinaciones de distintas bases de datos que puedan ser de utilidad, tanto para predecir inflación como cualquier otra variable que resulte de interés.

## 7. Referencias

- Athey, S. (2018). The Impact of Machine Learning on Economics. *University of Chicago Press, The Economics of Artificial Intelligence: An Agenda*, 507-547.
- Athey, S., & Imbens, G. (2019). Athey, S., & Imbens, G. W. ,2019. Machine Learning Methods Economists Should Know About. *arXiv:1903.10075*.
- Banco Central del Uruguay. (s.f.). *Encuesta de Expectativas de Inflación*. Obtenido de Encuesta de Expectativas de Inflación: <https://www.bcu.gub.uy/Estadisticas-e-Indicadores/Paginas/Encuesta-Inflacion.aspx>
- Baybuza, I. (2018). Inflation Forecasting Using Machine Learning Methods. (B. o. Russia, Ed.) *Russian Journal of Money and Finance*, 77(4), 42-59.
- Bernanke, B. (2007). "Inflation Expectations and Inflation Forecasting. *Discurso en Summer Institute, Cambridge, Massachusetts*.
- Boneva, L., Cloyne, J., Weale, M., & Wieladek, T. (2016). Firms' expectations and price-setting: evidence from micro data. (E. M. England, Ed.) *Discussion Paper No. 48*.
- Borraz, F., & Mello, M. (2020). Communication, Information and Inflation Expectations. *Documento de trabajo del Banco Central del Uruguay(005)*.
- Borraz, F., & Zacheo, L. (2018). Inattention, Disagreement and Internal (In)Consistency of Inflation Forecasts. *Documentos de trabajo 2018007, Banco Central del Uruguay*.
- Breiman, L. (2001). Random forests. *Machine learning* 45 (1), 5–32.
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and regression trees*. Routledge.
- Brum, C., Cuitiño, F., Mourelle, J., & Vicente, L. (2013). Pronósticos de inflación en horizontes intermedios: ¿qué aportan los modelos multivariados? Una aplicación para Uruguay. (U. C. Uruguay, Ed.) *Cuaderno de Economía - Segunda época(2)*, 85.
- Cancelo, J. R., Fernández, A., Grosskoff, R., Selves, R., & Villamonte, G. (1994). Precios transables y no transables un enfoque ARIMA-IA. *Documento presentado en las IX Jornadas Anuales de Economía*.
- Chakraborty, C., & Joseph, A. (2017). Machine learning at central banks. (B. o. England, Ed.) *Bank of England - Staff Working Paper(674)*.
- Cuitiño, F., Ganón, E., Tiscordio, I., & Vicente, L. (2010). Modelos univariados de series de tiempo para predecir la inflación de corto plazo. *Documento de trabajo(008)*.
- Frache, S., & Lluberas, R. (2019). *New information and inflation expectations among firms*.

- Friedman, J., Hastie, T., & Tibshirani, R. (2010). Regularization Paths for Generalized Linear Models via Coordinate Descent. *Journal of Statistical Software*.
- Garcia, M., Medeiros, M., & Vasconcelos, G. (2011). Real-time inflation forecasting with high-dimensional. *International Journal of Forecasting*, 33, 679–693.
- Garcia, M., Medeiros, M., & Vasconcelos, G. (2017). Real-time inflation forecasting with high-dimensional. *International Journal of Forecasting*, 33, 679-693.
- Genuer, R., & Poggi, J.-M. (2017). Arbres CART et Forêts aléatoires, Importance et sélection de variables. *arXiv preprint arXiv:1610.08203*.
- Hastie, T., & Qian, J. (2016). *An Introduction to glmnet*.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer.
- Hoerl, A., & Kennard, R. (1970). Ridge Regression: Biased Estimation for Nonorthogonal Problems. *Technometrics*, 55-67.
- Hyndman et al. (2020). *Forecasting Functions for Time Series and Linear Models*. Retrieved from Package 'forecast': <http://pkg.robjhyndman.com/forecast,%20https://github.com/robjhyndman/forecast>
- Hyndman, R. (2017). *forecast: Forecasting functions for time series and linear models*. Obtenido de R package version 8.2: <https://pkg.robjhyndman.com/forecast/>
- Hyndman, R., & Khandakar, Y. (2008). Automatic time series forecasting: the forecast package for R. *Journal of Statistical Software*, 27(3), 1-22.
- INE. (2020). *Instituto Nacional de Estadística*. Obtenido de <http://www.ine.gub.uy/la-institucion>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning with Applications in R*. Springer.
- Konzen, E., & Ziegelmann, F. (2016). LASSO-type penalties in covariate selection in time series. *Journal of Forecasting*, 35, 592-612.
- Küçükefe, B. (2018). Forecasting Inflation Using Summary Statistics of Survey Expectations: A Machine-Learning Approach. *Ekonomi-tek*, 7(1), 1-16.
- Lanzilotta, B., Fernández, A., & Zunino, G. (2007). Evaluación de las proyecciones de analistas: la encuesta de expectativas de inflación del banco central. *Revista de Economía - Segunda Epoca*, XIV(2), 70-96.
- Leng, C., Lin, Y., & Wahba, G. (2006). A note on the lasso and related procedures in model selection. *Statistica Sinica*, 16, 1273-1284.
- Li, R.-H., & Belford, G. (2002). Instability of Decision Tree Classification Algorithms. *Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining*, 570-575.

- Liao, Y. (2017). Machine Learning in Macro-Economic Series Forecasting. *International Journal of Economics and Finance*, 9(12), 71-76.
- Liaw, A., & Wiener, M. (2002). Classification and Regression by randomForest. *R News*, 18-22.
- Liaw, A., & Wiener, M. (2002). Classification and Regression by randomForest. R package. *R News* 2 (3), 18–22.
- Licandro, G., & Mello, M. (2014). Firm Inflation Expectations and Monetary Policy in Uruguay. *Documento de trabajo del Banco Central del Uruguay*(006).
- Medeiros, M., & Mendes, E. (2015).  $\ell_1$ -Regularization of high-dimensional time-series models with flexible innovations. *Textos para discussão*, 636.
- Medeiros, M., Vasconcelos, G., & H. de Freitas, E. (2016). Forecasting Brazilian Inflation with High Dimensional Models. *Brazilian Review of Econometrics*, 36(2), 223{254.
- Meinshausen, N., & Yu, B. (2009). Lasso-Type Recovery Of Sparse Representations For High-Dimensional Data. *The Annals of Statistics*, 37(1), 246–270.
- Mello, M., & Ponce, J. (2020). Fiscal policy and inflation expectations. *Documento de trabajo del Banco Central del Uruguay*(004).
- Mordecki, G., & Szarfman, E. (2011). *La inflación en Uruguay en 2011. Diferentes mediciones e impactos*. II Jornadas Académicas de la Facultad de Ciencias Económicas y de Administración, UdelaR.
- Probst, P., & Boulesteix, A.-L. (2018). To Tune or Not to Tune the Number of Trees in Random Forest. *Journal of Machine Learning Research*(18), 1-18.
- R Core Team. (2013). *R: A language and environment for statistical computing*. (R. F. Computing, Ed.) Obtenido de <http://www.R-project.org/>
- Rodríguez, A. (2020). Forecasting Costa Rican Inflation with Machine Learning Methods. *Banco Central de Costa Rica - Documentos de trabajo*(2).
- Svensson, L. (1996). Inflation Forecast Targeting: Implementing and Monitoring Inflation Targets. *NBER Working Papers*, 5797.
- Tallman, E. (1995). Inflation and inflation forecasting: an introduction. *Economic Review*, 80, 13-27.
- Tibshirani, R. (1996). Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, Vol. 58(1), 267-288.
- Vasconcelos, G. (2020). *R package version 0.1.0*. Obtenido de HDeconometrics: Implementation of several econometric models in high-dimension.: <https://github.com/gabrielrvsc/HDeconometrics>
- Wang, H., Li, G., & Tsai, C. (2007). *Regression Coefficient and Autoregressive Order Shrinkage and Selection via Lasso*.

Zhao, P., & Yu, B. (2006). On Model Selection Consistency of Lasso. *Journal of Machine Learning Research*, 7, 2541-2563.

Zou, H. (2006). The Adaptive Lasso and Its Oracle Properties. *Journal of the American Statistical Association*, 101, 1418-1429.

## 8. Anexo

Tabla 4. Pronósticos por método y por mes<sup>21</sup>

Fecha	Inflación 12 meses	Media 2MM	Media Base Encuesta	Ada-Lasso	Random Forest	Media MAA	Lasso	Ridge	Mediana Empresas	Auto-Arima	AR(1)	Mediana Analistas	RB*
2017-10	8,01	8,50	8,40	8,40	8,60	8,43	8,31	8,31	8,00	7,21	6,83	6,45	9,24
2017-11	8,05	8,38	8,31	8,26	8,50	8,35	8,29	8,29	8,00	7,31	6,99	6,79	7,98
2017-12	7,96	8,45	8,34	8,24	8,65	8,39	8,27	8,27	8,00	7,41	7,14	6,88	8,42
2018-01	7,39	8,33	8,24	8,10	8,59	8,30	8,25	8,25	8,00	7,43	7,20	7,00	8,07
2018-02	7,49	8,55	8,40	8,46	8,62	8,45	8,23	8,23	8,00	7,63	7,43	6,81	8,77
2018-03	7,78	8,49	8,38	8,44	8,59	8,40	8,22	8,22	8,00	7,34	7,19	6,85	10,11
2018-04	8,17	8,44	8,34	8,42	8,46	8,36	8,20	8,20	8,00	7,32	7,08	6,85	8,23
2018-05	7,73	8,40	8,37	8,40	8,43	8,33	8,19	8,19	8,00	7,70	7,50	7,00	7,01
2018-06	7,36	8,42	8,40	8,40	8,43	8,34	8,19	8,19	8,00	8,03	7,97	7,60	9,95
2018-07	7,54	8,45	8,43	8,40	8,52	8,36	8,19	8,19	8,00	8,07	8,12	7,60	10,72
2018-08	7,76	8,53	8,53	8,40	8,67	8,42	8,19	8,19	8,50	8,02	8,07	7,50	7,25
2018-09	7,78	8,47	8,61	8,40	8,54	8,37	8,19	8,19	9,00	8,01	8,05	8,10	5,54
2018-10	8,34	8,45	8,56	8,40	8,52	8,36	8,19	8,19	9,00	7,91	7,92	8,05	8,24
2018-11	8,4	8,51	8,55	8,40	8,61	8,40	8,19	8,19	8,50	7,96	7,94	8,04	6,95
2018-12	8,79	8,42	8,51	8,40	8,45	8,34	8,19	8,19	8,50	7,90	7,90	7,79	8,00
2019-01	8,71	8,50	8,46	8,39	8,59	8,39	8,18	8,18	8,00	7,67	7,62	7,69	6,57
2019-02	8,32	8,44	8,46	8,38	8,51	8,35	8,17	8,17	8,30	7,78	7,66	7,40	8,49
2019-03	9,16	8,41	8,44	8,37	8,50	8,33	8,17	8,17	8,20	7,87	7,81	7,40	8,12
2019-04	10,86	8,41	8,46	8,37	8,44	8,33	8,17	8,17	8,40	8,01	8,00	7,40	8,54
2019-05	11,05	8,38	8,47	8,36	8,40	8,31	8,16	8,16	8,50	7,79	7,79	7,60	10,04
2019-06	10,36	8,33	8,48	8,35	8,35	8,27	8,15	8,15	8,50	7,70	7,60	7,68	7,26
2019-07	10,13	8,30	8,42	8,57	8,02	8,25	8,15	8,15	8,30	7,80	7,69	7,50	8,66
2019-08	9,79	8,32	8,42	8,56	8,05	8,26	8,15	8,15	8,38	7,86	7,80	7,97	10,64
2019-09	9,92	8,22	8,40	8,32	8,11	8,19	8,14	8,14	8,50	7,85	7,81	7,95	9,15
2019-10	9,74	8,26	8,43	8,32	8,21	8,22	8,14	8,14	8,50	8,08	8,08	8,05	7,31
2019-11	9,59	8,34	8,49	8,33	8,35	8,28	8,15	8,15	8,50	8,04	8,11	8,25	8,02
2019-12	9,41	8,35	8,48	8,33	8,38	8,29	8,15	8,15	8,50	8,22	8,30	8,06	8,94
2020-01	8,89	8,24	8,60	8,34	8,13	8,21	8,16	8,16	9,00	8,14	8,27	8,40	10,16
2020-02	9,12	8,29	8,50	8,34	8,26	8,25	8,16	8,16	9,00	8,00	8,08	8,20	7,82
2020-03	8,34	8,23	8,64	8,35	8,12	8,21	8,17	8,17	9,00	8,40	8,49	9,28	7,25
2020-04	6,76	8,01	8,67	8,62	7,40	8,07	8,19	8,19	10,00	9,07	9,47	9,00	7,55
2020-05	6,64	7,93	8,64	8,40	7,47	8,03	8,22	8,22	10,00	8,94	9,67	8,50	9,44
2020-06	7,33	7,94	8,63	8,43	7,51	8,04	8,23	8,23	10,00	8,62	9,18	8,50	9,25

Fuente: Elaboración propia en base a datos de INE-BCU.

Tabla 5. ECM, RECM y Estadísticos para el ratio entrenamiento/testeo 65:35

Método	ECM	RECM	Media	Desvío Estándar	Mín.	Máx.
Ada-Lasso	1.79	1.34	8.42	0.10	8.10	8.62
Lasso	1.91	1.38	8.28	0.16	8.14	8.61
Ridge	1.91	1.38	8.28	0.16	8.14	8.61
Auto-Arima	2.11	1.45	7.83	0.48	6.82	9.07
Random Forest	2.24	1.50	8.50	0.40	7.41	9.16
AR(1)	2.49	1.58	7.75	0.72	6.28	9.67
Mediana Analistas	2.69	1.61	7.73	0.69	6.45	9.28
Mediana Empresas	2.99	1.73	8.65	0.63	8.00	10.00
RB*	3.65	1.91	8.29	1.25	5.27	10.81
<b>Combinaciones de métodos</b>						
Media MAA	1.94	1.39	8.40	0.19	8.03	8.77
Media 2MM	1.98	1.41	8.46	0.22	7.94	8.85
Media Base Encuesta	2.16	1.47	8.57	0.22	8.25	9.16
<b>Inflación 12 meses</b>	-	-	<b>8.14</b>	<b>1.27</b>	<b>5.75</b>	<b>11.05</b>

Fuente: Elaboración propia en base a datos de INE-BCU.

Muestra de entrenamiento: ventana corrediza desde 10/2009-09/2016 hasta 10/2009-06/2020.

Muestra de testeo: ventana corrediza desde 09-2016 hasta 06-2020.

<sup>21</sup> Para el caso de la Inflación 12 meses, el dato corresponde a la inflación observada 12 meses después al mes indicado, a efectos de comparar el valor pronosticado dicho mes con el observado.

**Tabla 6. ECM, RECM y Estadísticos para el ratio entrenamiento/testeo 85:15**

Método	ECM	RECM	Media	Desvío Estándar	Mín.	Máx.
Random Forest	1.79	1.34	8.19	0.36	7.43	8.63
Ada-Lasso	1.91	1.38	8.40	0.09	8.32	8.62
Lasso	2.25	1.50	8.17	0.02	8.14	8.23
Ridge	2.25	1.50	8.17	0.02	8.14	8.23
Media Empresas	2.79	1.67	9.28	0.59	8.68	10.47
Auto-Arima	3.20	1.79	8.09	0.39	7.67	9.07
Mediana Analistas	3.48	1.86	8.03	0.52	7.40	9.28
AR(1)	3.65	1.91	8.16	0.60	7.60	9.67
RB*	3.73	1.93	8.30	1.24	5.65	10.56
<b>Combinaciones de métodos</b>						
Media 2MM	1.80	1.34	8.29	0.16	7.93	8.52
Media Base Encuesta	1.88	1.37	8.51	0.09	8.40	8.68
Media MAA	1.94	1.39	8.25	0.11	8.02	8.41
<b>Inflación 12 meses</b>	-	-	<b>9.07</b>	<b>1.22</b>	<b>6.64</b>	<b>11.05</b>

Fuente: Elaboración propia en base a datos de INE-BCU.

Muestra de entrenamiento: ventana corrediza desde 10/2009-11/2018 hasta 10/2009-06/2020.

Muestra de testeo: ventana corrediza desde 11-2018 hasta 06-2020.