

DOCUMENTO DE TRABAJO N°7

Modelos de *Nowcasting* para el pronóstico de la actividad económica mensual argentina

Gonzalo Carrera

Resumen

Existe consenso en la teoría económica actual acerca de que el Producto Bruto Interno es la mejor medida para cuantificar la riqueza flujo de una nación. Sin embargo, en Argentina el conocimiento de esta información se divulga con una demora de entre 70 y 80 días luego de finalizar el trimestre analizado. El INDEC construyó como indicador provisorio el Estimador Mensual de Actividad Económica (EMAE), el cual converge a las mismas cifras que el PBI, pero su difusión también tiene un retardo de entre 50 y 60 días concluido el mes de referencia, lo que en la Argentina actual es mucho tiempo por el acortamiento del horizonte de decisión producto de la inestabilidad económica. El objetivo central de este trabajo es obtener una estimación, con 30 días de antelación a lo publicado por el INDEC, de la variación interanual del EMAE y del EMAE pero excluyendo el sector Agropecuario (por la volatilidad de este sector). Para esto, se usaron técnicas de *Nowcasting*: estimaciones de cómo se movió la actividad económica mediante modelos econométricos y *machine learning*, utilizando 44 variables predictoras de la economía argentina del período de referencia. Los métodos utilizados para pronosticar fueron: modelo Autorregresivo de Rezagos Distribuidos (ARDL), tres modelos de *machine learning* (Lasso, Ridge y Elastic Net) y dos modelos de selección de parámetros mediante algoritmos, el modelo General-to-specific (GETS) y el modelo Global Search Regression (GSR). De estos, el modelo Lasso fue el que menor error de pronóstico arrojó por 2 de las 3 métricas utilizadas, tanto para predecir el EMAE como el EMAE no Agropecuario. El modelo GETS también tuvo un desempeño destacado con ambas variables objetivo, mientras que el Ridge ajustó mejor para el EMAE no Agropecuario y el ARDL para el EMAE agregado.

Palabras clave: Nowcasting, EMAE, PBI, Machine Learning, Lasso, Ridge, GSR, ARDL, GETS

Índice

1) Introducción.....	3
2) Revisión de la literatura sobre <i>Nowcasting</i>	6
3) El EMAE como variable objetivo y sus diferentes predictores.....	14
a. Características, virtudes y dificultades de predecir al EMAE	14
b. El PBI Agropecuario como elemento exógeno a la hora de predecir: distinción entre EMAE sin sector Agropecuario vs EMAE Agropecuario.....	20
c. Variables predictoras del EMAE: criterio de selección y frecuencia temporal utilizada	23
4) Econometría: modelos para pronosticar el EMAE y el EMAE no agropecuario	26
a. Modelo ARDL	26
b. Modelos de aprendizaje automático: Lasso, Ridge y Elastic Net	27
c. Modelo GETS: General-to-Specific	30
d. Modelo Global Search Regression	31
5) Resultados encontrados	32
6) Conclusiones	40
7) Bibliografía	43

Modelos de *Nowcasting* para el pronóstico de la actividad económica mensual argentina

1) Introducción

La teoría económica se ha preguntado a lo largo de la historia qué hace rico a los países y cómo se mide esta riqueza. Pese a que aún hoy continúan dichos debates, existe un consenso importante: el Producto Bruto Interno (PBI) es la mejor medida para cuantificar la riqueza de una nación, lo que la convierte en la métrica más utilizada por los diferentes agentes económicos.

Este indicador contempla la parte de la riqueza que se caracteriza como “flujo”, es decir, los ingresos percibidos por una nación durante un período de tiempo particular. Esta consideración lo distingue de otros indicadores que captan el “stock” de riqueza de un país, midiendo bienes o recursos que posee una nación en un período específico, utilizado por ejemplo para medir el stock de recursos naturales de un país. Por el contrario, el PBI es una variable flujo que considera la cantidad de bienes y servicios finales producidos en un país durante un intervalo temporal determinado, por lo que su evolución es más fluctuante período a período y es una métrica más asociada al estado de la demanda interna, la actividad económica y los ingresos del país en cuestión.

Pero la complejidad del relevamiento de esta información hace que, en Argentina y otros países, la frecuencia con la que se publican estos datos sea de una vez por trimestre. Es más, el conocimiento de estas estadísticas relevantes se divulga con una demora de entre 70 y 80 días finalizado dicho cuarto del año. Esto hace que si se busca saber cómo evolucionó la actividad económica en el último trimestre de 2023 sea necesario esperar hasta finales de marzo de 2024 para saberlo mediante las estadísticas propias del PBI.

Por esta razón, el INDEC construyó el Estimador Mensual de Actividad Económica (EMAE), el cual es un indicador provisorio de la evolución del PBI real, con la particularidad de que tiene una frecuencia mensual y algunas otras diferencias menores. Esto permite conocer con mayor antelación la dinámica del PBI, a sabiendas de que ambos indicadores, en última instancia, terminan convergiendo entre sí prácticamente a los mismos resultados agregados.

Sin embargo, el EMAE presenta una serie de dificultades que impiden que logre cumplir su objetivo completamente: principalmente, la más importante es que su difusión tiene un retraso de entre 50 y 60 días concluido el mes de referencia. Este retraso puede ser normal en otros países de Latinoamérica, pero en la Argentina

actual, en dos meses pueden ocurrir una infinidad de acontecimientos que impiden que la discusión pública considere relevante al indicador que más rápido informa sobre la producción interna.

Por ejemplo, en los últimos dos meses al escribir este trabajo –entre el 30 de octubre y el 30 de diciembre de 2023- la dinámica macroeconómica sufrió de alta inestabilidad: el tipo de cambio oficial trepó casi 130% pero el tipo de cambio financiero CCL sólo 14%, el valor de los bonos argentinos creció más del 50% en dólares y el riesgo país disminuyó 26,2%, pero las reservas brutas y netas del Banco Central mermaron US\$ 3.000 millones. A la vez, las expectativas de inflación del mes siguiente subieron 13,5 p.p. pero las anuales sólo 17,8 p.p.; toda esta suba de nominalidad se dio con la tasa de interés efectiva mensual nominal cayendo 2,8 puntos porcentuales.

El acortamiento del horizonte temporal es un hecho relevante de los últimos años en Argentina: los agentes económicos no pueden ver más allá de las próximas semanas o el próximo mes, producto de la enorme volatilidad e incertidumbre macroeconómica. En otras palabras, cambios que en otros países llevan décadas en la Argentina de hoy pueden tardar semanas, haciendo que los pronósticos se focalicen en el cortísimo plazo. Al no tener información sobre la actividad económica por tanto tiempo, los agentes económicos no la consideran una información tan relevante para el día a día, asignándole mayor importancia a indicadores de alta frecuencia como la inflación, el tipo de cambio o indicadores de consumo masivo.

La importancia de este problema motivó a realizar este trabajo: el objetivo central del mismo es obtener una estimación, con 30 días de antelación de lo publicado por el INDEC, de la variación interanual del EMAE y del EMAE pero excluyendo el sector Agropecuario (distinción necesaria debido a la alta volatilidad de este sector, punto que se profundiza en la Sección 3). A modo de ejemplo, si dicho organismo publica el EMAE de diciembre de 2023 el 22 de febrero de 2024, ese mismo día nuestro trabajo permitirá tener una estimación aproximada de la dinámica de la actividad económica de enero de 2024.

Para este objetivo, esta investigación utiliza la teoría desarrollada en la literatura del *Nowcasting* de variables macroeconómicas. Esta explica que, a través de datos ya conocidos públicamente del período de referencia, es posible realizar estimaciones de cómo se movió la actividad económica mediante modelos econométricos y *machine learning*. Es más, la bibliografía refuerza la idea de que a medida que más información sale de dicho período, más preciso es el pronóstico realizado, por lo que existe un *trade-off* entre realizar el pronóstico con anticipación y su respectiva precisión.

En particular, como predictores se utilizaron variables de recaudación, comercio exterior, monetarias, financieras, cambiarias, de expectativas, de energía, demanda, producción sectorial y algunas variables dicotómicas construidas para captar algunos momentos temporales específicos (como por ejemplo, la pandemia). El criterio de elección se centró en contar con datos públicos mensuales de las variaciones interanuales de estas variables entre enero de 2012 y noviembre de 2023 (último dato). Pero más importante aún, el filtro fundamental para estas estadísticas fue que estas deben difundirse sólo 20 días después de finalizar su período de referencia, para poder ser el *input* del modelo predictivo del EMAE y conocer su variación interanual 30 días antes que lo publicado por el INDEC. Con esta metodología, se encontraron 44 variables predictoras.

Los modelos predictivos utilizados fueron seis y se basaron en modelos econométricos, técnicas algorítmicas y de aprendizaje automático. En particular, se usaron el Modelo Autorregresivo de Rezagos distribuidos (ARDL), tres modelos de *machine learning* (Lasso, Ridge y Elastic Net) y dos modelos de selección de parámetros mediante algoritmos, el modelo General-to-specific (GETS) y el modelo Global Search Regression (GSR). Estos fueron puestos a competir tanto para el EMAE como para el EMAE no Agropecuario.

Como el fin último de esta investigación es anticipar el EMAE y no explicar relaciones entre variables, el criterio de selección de modelos se basó en las medidas clásicas de bondad de pronóstico. Las utilizadas fueron tres, para contemplar diferentes ángulos: la Raíz del Error Cuadrático Medio (RMSE), el Error Absoluto Medio (MAE) y el Error Absoluto Porcentual Medio (MAPE).

En cuanto a los resultados, se encontró que el modelo que mejor pronosticó fue el Modelo Lasso, el cual lideró los mejores desempeños por 2 de las 3 métricas de bondad de pronóstico, tanto para predecir el EMAE como para predecir el EMAE no Agropecuario. Todos estos modelos son de gran utilidad para conocer con antelación qué performance mostró la actividad económica.

Para lo que viene, el trabajo se estructura de la siguiente manera. Luego de esta introducción, la Sección 2 recopila toda la literatura relevante sobre el tema, considerando la amplia bibliografía de *Nowcasting* (de PBI e inflación, principalmente), tanto para diferentes países del mundo y la región como para Argentina, incorporando aquí toda la literatura del EMAE también. Luego, en la Sección 3 se detallan todas las particularidades y las decisiones tomadas sobre las variables objetivo (el EMAE y el EMAE no Agropecuario) y las predictoras. En la Sección 4, se explican los modelos econométricos y de *machine learning* utilizados con sus respectivos fundamentos teóricos. Los resultados en términos de bondad

de pronóstico son presentados en la Sección 5. Por último, en la Sección 6 se desarrollan las conclusiones de este trabajo.

2) Revisión de la literatura sobre *Nowcasting*

La necesidad de contar con datos de alta frecuencia de variables relevantes de la economía llevó a que diferentes autores trabajen sobre la idea de *Nowcasting*. Esta noción, según la definición brindada por Bańbura et al. (2013), se focaliza en la predicción del presente, futuro muy cercano o pasado muy reciente. Por esta razón, el término *Nowcasting* surge de la interacción entre el presente (*now*) y el futuro (*forecasting*). Su utilidad reside en que la literatura muestra que, a medida que se conoce nueva información disponible, los pronósticos se hacen más certeros, ya que esta es adquirida y procesada por los nuevos modelos (Giannone et al., 2008; Knotek y Zaman, 2017; Bańbura et al., 2013).

En este sentido, la idea central del *Nowcasting* es realizar una estimación temprana de la variable de interés utilizando información conocida con mayor anticipación que la variable objetivo (Bańbura et al., 2013). El objetivo principal es predecir a partir de optimizar el uso de información disponible en cada momento, no siendo relevante establecer relaciones causales sino meramente correlaciones (Espinoza, 2022).

Generalmente, las aplicaciones de estas técnicas se realizan a través de modelos econométricos que buscan pronosticar las estadísticas de inflación o PBI a partir de variables conocidas con mayor anterioridad. Entre los trabajos que buscan pronosticar inflación a través de información conocida, se inscriben publicaciones como la de Modugno (2013). Este autor incluye datos de alta frecuencia de precios de energía, materias primas o variables financieras diarias y semanales para pronosticar la inflación de la zona euro y de Estados Unidos, utilizando modelos de componentes principales y Vectores Autorregresivos (VAR).

Alejándose de buena parte de la literatura de *Nowcasting*, otros autores eligen cuidadosamente una pequeña cantidad de series de datos con diferentes frecuencias para informar predicciones inmediatas, sin utilizar modelos de componentes principales (Knotek y Zaman, 2017). Estos autores proponen un modelo nuevo y parsimonioso para pronosticar la inflación general y el índice de precios del gasto de consumo personal (PCE) de Estados Unidos a partir de pocas variables de precios, utilizando modelos de mínimos cuadrados no lineales y modelos de factores dinámicos. Para comparar, utilizan modelos menos complejos para evaluar su performance, como un *Random Walk*.

Como se verá en otros trabajos, el pronóstico final de dichos autores se centra en la serie de tiempo de frecuencia trimestral a partir de datos mensuales. Esto implica que al pronosticar inflación con una frecuencia mensual, luego debe extrapolarse los resultados al trimestre de referencia. De esta forma, las estimaciones se realizan a partir del siguiente mes del trimestre finalizado y publicado, incorporando mes a mes la nueva información disponible de los indicadores macroeconómicos utilizados hasta el tercer mes del trimestre a pronosticar.

Al igual que Bańbura et al., (2013), Knotek y Zaman (2017) confirman que cuando llega nueva información disponible del período a pronosticar, la performance del modelo mejora. Así, logran aportar más información, perfeccionando el pronóstico. Lo mismo encuentran Aastveit et al (2011) para predecir el PBI de Estados Unidos, la capacidad predictiva de su modelo aumenta casi monótonamente a medida que llega nueva información durante el trimestre.

En este sentido, trabajos que tienen como objetivo pronosticar el PBI trimestral a través de información diaria o mensual, han utilizado una serie de soluciones para abordar el problema de diferentes frecuencias temporales. Por ejemplo, como señalan D'amato et al. (2015), estas técnicas pueden ser: modelos bivariados simples a partir de ecuaciones puente o *bridge equations* (Kitchen y Mónaco, 2003; Drechsel y Maurin, 2011), modelos de factores (Stock y Watson, 2002a, 2002b), representaciones en el espacio-estado (Barnett et al., 2014), modelos VARs (Giannone et al., 2008; Arouba et al., 2009; Álvarez et al., 2014) y Mixed Data Sampling (MIDAS) equations (Ghysels, 2007).

La utilización de ecuaciones puente fue durante varios años el método más utilizado por los Bancos Centrales del mundo para pronosticar PBI. Autores como Baffigi et al. (2004) encuentran que la capacidad predictiva de este método es mejor que un proceso Autorregresivo o VAR para el *nowcast* del PBI euro. Pero también existe dificultad al incorporar más variables, por lo que diferentes autores se volcaron al método de componentes principales que permite utilizar muchas más variables predictoras, las cuales son reducidas mediante esta técnica de regularización a un número menor de componentes o factores no correlacionados que contienen gran parte de la varianza del conjunto de variables utilizadas (Casares, 2017).

A su vez, la inclusión de más indicadores permite una mejor aproximación al PBI efectivo, aunque también supone un incremento de los parámetros del modelo a estimar lo que puede reducir los grados de libertad. Esto lo trabajan Álvarez et al (2014), que buscan predecir el PBI español mediante modelos VAR enfatizando la utilización de una gran cantidad de indicadores económicos (133) de naturaleza diversa. Estas variables incluyen estadísticas relacionadas con la actividad y demanda, con el sector público, variables de opinión, indicadores internacionales,

de precios y financieras vinculados con la economía española y a otras economías de interés.

Otra literatura aporta información para estudiar la predicción en tiempo real a través de datos de alta frecuencia. Por ejemplo, Choi y Varian (2012) utilizan datos de búsquedas en Google (mediante *Google Trends*) para predecir el comportamiento de la actividad económica. Otros autores encuentran una mejora en la precisión de los primeros pronósticos inmediatos, a través de la inclusión de pagos con tarjeta de débito en el modelo predictivo, estudiando los pagos electrónicos (Galbraith y Tkacz, 2015). A su vez, Higgins (2014) desarrolla un modelo con ecuaciones puente llamado “GDPNow”, que si bien puede tener mayor error de pronóstico que otros modelos citados, demuestra que su utilidad reside en que puede actualizarse después de prácticamente cada publicación importante de datos macroeconómicos.

Existe también otra serie de trabajos que se concentran en realizar pronósticos de la actividad económica para los diferentes países de América Latina. La gran mayoría de ellos utilizan modelos de factores dinámicos o componentes principales. Es decir, se busca reducir una gran cantidad de variables en ciertos componentes para explicar sólo un porcentaje de toda la variabilidad de las series en estudio. En otras palabras, se trata de una técnica de reducción de la información disponible aunque sin perder variabilidad.

Masoller (2002) construye un indicador sintético de la actividad económica de Uruguay utilizando el modelo de factores dinámicos de Stock y Watson (1991), destacándose que encuentra como variables coincidentes la recaudación real del IVA, el monto de las importaciones de bienes (excluido el petróleo y los destilados), el índice de volumen físico de la industria manufacturera y las ventas de cemento portland a obras privadas; mientras que descarta otra decenas de variables.

Perez y Brens (2018) también prueban diferentes modelos de factores dinámicos para pronosticar la actividad económica mensual de República Dominicana (IMAE). Estos autores encuentran que las variables con mayor ponderación corresponden a Ventas de Manufactura, Ventas de Comercio, Importaciones y Ventas de transporte; mientras que las que menos ponderación en el modelo son las vinculadas con los salarios.

Casares (2017) utiliza esta metodología (factores dinámicos) pero la vincula con ecuaciones puente, usando variables mensuales que se publican con alta frecuencia para alcanzar el PBI trimestral de Ecuador. Entre estas variables seleccionadas se encuentran: exportaciones, importaciones, consumo de energía

eléctrica, depósitos, cuasidinero, liquidez total y gasto público, entre otras. Para el criterio de selección, el autor utilizó un coeficiente correlación superior a 0,5.

Otra literatura se focaliza pronosticar el PBI mexicano: Klein y Coutiño (2004) utilizan modelos de componentes principales también; mientras que Azcona et al. (2021) usan un modelo VAR multinomial para la misma variable objetivo. Estos últimos encuentran que la incorporación de 2 rezagos mejora el ajuste del modelo en relación con un *lag* hacia atrás.

En cuanto al pronóstico del PBI argentino, existen diferentes trabajos de cabecera que nutren la discusión y la investigación presente. Entre ellos, el trabajo pionero de McCandless et al. (2001) es una referencia de la utilización de modelos econométricos para la predicción del PBI de Argentina, a la vez que tiene como variables objetivo a pronosticar también la inversión y las importaciones. Los autores realizan predicciones a uno y dos pasos través de procesos ARIMA y modelos VAR, y como resultado, la conclusión más relevante que obtienen es que los procesos ARIMA en general muestran una mejor performance que el modelo VAR tradicional. También encuentran que la inclusión del índice Merval en el sistema mejora en forma notable el funcionamiento del VAR.

Por otra parte, al igual que lo visto para otros países, diversos trabajos también utilizan los modelos de factores dinámicos basados en Stock y Watson (1991) para predecir el PBI argentino. Dal Bianco et al. (2013) utilizan esta clase de técnica econométrica para monitorear el PIB argentino en tiempo real utilizando datos económicos en frecuencias mixtas (mensual y trimestral), publicadas con diferentes desfases temporales, logrando anticipar a la publicación oficial con antelación y precisión mediante un índice coincidente. Como variables explicativas utilizan el Índice de Producción Industrial de la consultora FIEL, datos de empleo, ventas de supermercados y el ISAC (Indicador Sintético de la Actividad de la Construcción).

Además de utilizar factores dinámicos, D'amato et al. (2015) prueban también ecuaciones puente y un modelo AR (1) utilizando 37 variables y encuentran que el modelo de factores pronostica mejor el PBI trimestral que los otros dos métodos. Los predictores en estos casos son variables de producción de autos, cemento, recaudación, bursátiles, producción manufacturera, monetarias, producción agropecuaria y de expectativas.

Unos años más tarde, Blanco et. al (2017) tienen como variable objetivo también el PBI argentino trimestral entre 2006 y 2017. Los autores comparan la capacidad predictiva utilizando un modelo factorial, otro factorial dividido en indicadores de tipo *Soft*, *Hard* y de precios) y un VAR de factores aumentado (FAVAR). A la vez, prueban si existen diferencias significativas de utilizar 112 variables predictoras en

lugar de un grupo de 30 más reducido. Como resultado, proponen combinar modelos para realizar predicciones inmediatas, ya que encuentran que ninguno de los modelos prevalece sobre el otro: los modelos FAVAR superan al resto de modelos para la muestra predictiva completa, mientras que en el último periodo priman otros modelos, como el modelo factorial restringido y el libre.

Más recientemente, Llada (2022) propone un modelo factorial dinámico y lo compara con un modelo AR (1) y un modelo de crecimiento naive, con el objetivo de obtener una estimación temprana del PBI argentino trimestral entre 1998 y 2021. Además de encontrar que el modelo factorial es el que mejor predice, el autor utiliza como variables predictoras la demanda de energía, la producción de cemento, el EMAE, empleo, algunas variables de recaudación, producción manufacturera, construcción, cemento y ventas de supermercado; conocidas con anterioridad a la publicación del PBI. Variables similares utilizan Cohan y Zanini (2022) para incorporar el nuevo Índice Provincial de Actividad Industrial (IPAI) de la provincia de Santa Fe como componente del Índice Compuesto Coincidente de Actividad Económica (ICASFe).

Pero lo más relevante del trabajo de Llada (2022) resulta que incorpora tres indicadores que aportan información útil y mejoran la performance de los modelos a la hora de pronosticar: un indicador de tono sobre el ciclo económico argentino, un indicador que captura presión sobre el mercado cambiario y otro que aproxima niveles de incertidumbre económica.

Tanto el indicador de sentimiento económico como el de incertidumbre se basa en información no estructurada, explotando los artículos periodísticos de la sección de economía del diario Ámbito Financiero, La Nación y Página 12. En ellos se buscó encontrar palabras asociadas a ambos sentimientos económicos, para medir las expectativas de la población. Por su parte, el índice de presión sobre el mercado cambiario captura de forma conjunta los movimientos del tipo de cambio nominal, las reservas internacionales y el spread de la tasa de interés.

Otros autores se centran en utilizar índices bursátiles para anticipar los resultados de la actividad económica. Primero, Lanteri (2014) realiza un VEC (Vector de Corrección de Errores) para examinar las relaciones de largo plazo entre el Merval y el Burcap¹ con el EMAE. Encuentra que ambos indicadores bursátiles cointegran

¹ El Índice Merval es el índice más usado del mercado accionario argentino, mide el valor en moneda doméstica de una canasta con las principales acciones argentinas (empresas líderes), de acuerdo con su liquidez. En cambio, el índice Burcap es un índice basado en la capitalización bursátil de las empresas y no de la liquidez del mercado como el caso anterior.

con EMAE y lo causarían en sentido positivo (Granger), mientras que no se observa causalidad en sentido inverso (del EMAE hacia los índices accionarios).

Más recientemente, Cohan (2019) encuentra que el Índice Merval en términos reales se comporta de forma procíclica, que su correspondencia temporal con los giros de la actividad económica general es significativa (mayor al 70%), teniendo cualidades predictivas para anticipar las recesiones argentinas.

Por otro lado, Priarone (2019) también se pregunta si el Índice Merval es un buen indicador adelantado del ciclo económico argentino, tal como señala la anterior literatura. Pero en este caso la autora no descubre una relación con el EMAE ni que el Merval se comporte como un índice líder. Si bien sí encuentra que podría ser un índice coincidente (más que uno adelantado), argumenta que las razones que encuentra diferentes con respecto a otros países (donde sus mercados de valores anticipan cambios en el ciclo) corresponden al bajo grado de desarrollo del mercado financiero local, el cual a su vez es poco representativo de la actividad económica (petróleo y bancos se llevan el 60% del índice).

Centrándose en el objetivo central de este trabajo (predecir el EMAE), Frank (2021, a) utiliza una serie de variables conocidas con mayor anticipación: el Índice Merval deflactado por los precios mayoristas, la recaudación del IVA, Riesgo País, Índice de Confianza del Consumidor Nacional, Tipo de Cambio Real Multilateral del BCRA, producción de automóviles en unidades, producción de utilitarios, y despachos de cemento Portland. Para esto, el autor utilizó el modelo de componentes principales para reducir la dimensionalidad (busca explicar la serie desestacionalizada con tres componentes) y luego usó un modelo de Rezagos Distribuidos (ARDL) para el pronóstico, considerando hasta dos rezagos hacia atrás del EMAE.

En otro trabajo, Frank (2021, b) se focaliza en la desestacionalización del EMAE por las discrepancias que mostró la serie en el período de alta volatilidad que vivió en 2020 producto de la pandemia. Para esto, realiza el ejercicio de dividir el EMAE en los diferentes sectores productivos a nivel de letra de la clasificación CIIU-3. El trabajo se centra en desestacionalizar cada uno de los sectores productivos mediante un modelo ARIMA y su respectivo pronóstico del indicador agregado. Encuentra que las dificultades de anticipar la serie desestacionalizada del INDEC se deben a que la misma excluye la influencia de los feriados nacionales del procedimiento de ajuste del INDEC, más que por diferencias en las especificaciones de los modelos sectoriales.

A su vez, la serie desestacionalizada del INDEC se construye quitándole los componentes estacionales a cada uno de los sectores de actividad diferentes, para luego agregarlos en un indicador desestacionalizado del total de la actividad

económica. Esto requiere un pronóstico de cada uno de los componentes sectoriales de la producción para poder tener una estimación precisa de la actividad económica mensual desestacionalizada (INDEC, 2016a). Por esta razón, es habitual realizar el pronóstico de la serie original agregada (sin desestacionalizar) más que pronosticar cada uno de los 15 sectores productivos. En todo caso, luego es posible realizar la desestacionalización de la serie agregada de forma directa.

En síntesis, en los diferentes trabajos analizados primó la utilización de modelos autorregresivos, bivariados simples a partir de ecuaciones puente, modelos de factores, representaciones en el espacio-estado, modelos VARs y Mixed Data Sampling focalizándose en el pronóstico del Producto Bruto Interno, a través de diferentes variables explicativas conocidas con anterioridad.

Sin embargo, en los últimos años creció considerablemente el uso de técnicas de aprendizaje automático (*machine learning*) para fortalecer el uso de *Nowcasting*, como alternativa a los modelos mencionados. Entre ellos destacan los modelos de redes neuronales, Gradient Boosting, Ridge, Lasso, GETS o Global Search Regression, entre otros.

Ejemplo de ello es el de Espinosa (2022) que estima diferentes modelos de *Nowcasting* para predecir el PIB trimestral uruguayo mediante indicadores mensuales. El autor utiliza ecuaciones puente y factores dinámicos pero la selección de las variables explicativas es recursiva, mediante los métodos de aprendizaje automático General to Specific (GETS) y Least Absolute Shrinkage and Selection Operator (LASSO). Ambos resultados los compara con un AR (1) y con un modelo autoarima, encontrando que los de ecuaciones puente predicen mejor si las variables se seleccionan mediante GETS o LASSO, en lugar que las realizadas mediante AR (1).

Otro aporte relevante en esta clave es el trabajo de Richardson et al. (2021) que tiene como objetivo pronosticar el PBI de Nueva Zelanda en tiempo real con 600 variables predictoras mediante el uso de *machine learning*. Los autores utilizan modelos Gradient Boosting, Ridge, Lasso, Elastic Net y Redes neuronales; contrastándolos con modelos AR y factores dinámicos. Como resultado, encuentra que todos los modelos de aprendizaje automático pronostican mejor que estos últimos dos más tradicionales.

Por esta razón, es posible aprender de la literatura relevante analizada diferentes lecciones. En primer lugar, las técnicas de *Nowcasting* están muy difundidas en la actualidad en la economía aplicada y son cada vez más relevantes para obtener información con más anticipación, lo que es de gran utilidad para la política

económica, pero también para cualquier agente económico a la hora de tomar decisiones.

Segundo, las variables predictoras deben ser conocidas con anterioridad a la publicación del indicador de actividad económica, pero el tiempo acorde previo lo define el investigador de forma arbitraria. Aquí el investigador se topa con un *trade-off*: mientras mayor sea la distancia entre la publicación oficial y la posibilidad de realizar el pronóstico, mayor error tendrá esta predicción. A cambio, obtendrá más temprano información relevante que de otra forma no existiría. Qué tanto se priorice la anticipación o la precisión del pronóstico depende de cada investigador.

Además, las variables predictoras utilizadas por la literatura deben ser lo más diversas posibles y no parecen mostrar necesariamente un vínculo específico con la producción a analizar, ya que su único fin es que muestren una alta correlación con la variable objetivo. A su vez, mientras más variables se prueben, mejor será la performance del modelo utilizado.

En lo que hace a la variable objetivo de este trabajo, los autores que realizaron modelos para pronosticar el EMAE enfatizaron sobre la inestabilidad de la serie desestacionalizada y cierta dificultad para su anticipo. Por esta razón, la literatura se focalizó generalmente en trabajar con las variables en su estado original (series con estacionalidad).

Por último, un buen modelo de *Nowcasting* debe surgir de contrastar modelos más avanzados en la literatura (como por ejemplo los más recientes avances en aprendizaje automático), con otras técnicas econométricas más probadas que ya han mostrado buenos resultados. La complejidad matemática no garantiza que los modelos más básicos no sean mejores para pronosticar (Makridakis et al., 2018).

El desafío de este trabajo es aprender de esta y las otras lecciones mencionadas para realizar un modelo robusto econométricamente, útil para los profesionales de la economía y de uso difundido por los diferentes agentes económicos para que, a la hora de tomar decisiones en Argentina se cuente con mayor cantidad de información sobre el estado de la economía.

3) El EMAE como variable objetivo y sus diferentes predictores

a) Características, virtudes y dificultades de predecir al EMAE

Una de las grandes preguntas de la teoría económica a lo largo de la historia es qué hace rico a los países y cómo se mide esta riqueza. Pese a que aún hoy algunas discusiones siguen presentes, la ciencia económica parece mostrar un consenso: la mejor medida de riqueza de cada nación es el Producto Bruto Interno (PBI). Este indicador mide la cantidad de bienes y servicios finales producidos por un país durante un período de tiempo específico (generalmente un año).

Ahora bien, la complejidad del relevamiento de la información necesaria para construir este indicador en cada país hace que, tanto en Argentina como en otros países, la frecuencia con la que se publican estos datos sea de una única vez por trimestre. De esta forma, el PBI refiere a una medida que brinda información sobre la producción (variable flujo) promedio trimestral a partir de una gran recolección de datos productivos, que se dan a conocer públicamente por el Instituto Nacional Estadística y Censos (INDEC) entre 70 y 80 días finalizado el trimestre (INDEC, 2016b). A modo de ejemplo, los datos del PBI del tercer trimestre de 2023 se publicaron el 15 de diciembre, dos meses y medio después del cierre de dicho trimestre.


Por esta razón, el INDEC construyó el Estimador Mensual de Actividad Económica (EMAE), el cual es un indicador provisorio de la evolución del PBI real (a precios constantes de 2004, año base), con la particularidad de que tiene una frecuencia mensual lo que permite conocer con mayor antelación cómo se está desempeñando la producción de un país.

También existen algunas diferencias entre el EMAE y el PBI a precios constantes, más allá de ser el primero una primera versión del segundo. El EMAE se presenta como un índice con base 100 en el promedio anual de 2004 que computa la evolución de las cantidades producidas (sin considerar el efecto precio), mientras que el PBI tiene como unidad de medida los millones de pesos de 2004, así que también se ocupa del volumen de actividad. Otro detalle que se encuentra al analizar la producción sectorial es que el primero no incluye información sobre la producción sectorial del sector P “Servicios de hogares privados que contratan servicio doméstico”, el cual sí se encuentra desagregado en el segundo.

Además, la estimación del PBI trimestral contempla una mayor cantidad de datos y fuentes que el EMAE. Fundamentalmente porque el indicador mensual se realiza con información parcial, de carácter provisorio, por lo que en las diferentes publicaciones del EMAE se garantiza la revisión hacia atrás de la serie para que converja con el PBI, con la mayor información que contempla este indicador.

Pese a estas pequeñas diferencias en cómo es la presentación del EMAE y del PBI, conocer previamente cómo evolucionó el primero (como se propone este trabajo), es saber con anterioridad la evolución del segundo, el principal indicador sobre la evolución de la riqueza nacional. El EMAE es un anticipo del PBI y este trabajo se propone anticipar el EMAE.

Una forma de ver esta convergencia entre los indicadores es observando la serie de datos para atrás, luego de sus respectivas revisiones. Por ejemplo, es posible observar las variaciones interanuales de sus series originales, tal como muestra el Gráfico 1.




Algo similar ocurre con las series sin estacionalidad del EMAE y del PBI. Primero, vale aclarar que contar con información de las series desestacionalizadas también es relevante debido a que estas permiten realizar contrastes de los datos de la variable con independencia del punto de comparación en el uno se encuentre, sin necesidad de estimar variaciones contra los mismos meses de otros años, como ocurre con la serie original. Por ejemplo, una serie sin estacionalidad es de utilidad

para ver cómo evolucionó la producción de un trimestre hacia el otro o, como es el caso del EMAE, de un mes al otro. Es más, también pueden realizarse comparaciones entre puntos muy diferentes del tiempo: contrastar cómo se encuentra la producción en algún mes de 2023 vs el máximo o mínimo histórico de la serie o cualquier otro dato que presente la variable a lo largo de su historia.

Pero la comparación entre el PBI y el EMAE en este punto no es exacto como en la serie original, ya que los métodos de desestacionalización muestran cierta inestabilidad a lo largo del tiempo. Como el INDEC desestacionaliza nuevamente toda la serie original hacia atrás a medida que sale un nuevo dato, aún tras pasar los años y realizarse las revisiones, permanecen algunas pequeñas diferencias entre el EMAE y el PBI en sus variaciones trimestre a trimestre sin estacionalidad. No obstante, estas divergencias son muy pequeñas y no parecen modificar el panorama general de que el EMAE converge al PBI, ya que las mismas no superan más de una décima de puntos porcentuales (ver Gráfico 2).

Gráfico 2. EMAE y PBI desestacionalizados casi sin diferencias

En variación % intertrimestral desestacionalizada



Fuente: Elaboración propia en base a INDEC

Sin embargo, pese a sus ventajas como anticipador del PBI, el EMAE también tiene sus peculiaridades. Primero, se publica con un rezago de entre 50 y 60 días concluido el mes de referencia, de acuerdo con el calendario de difusión del INDEC. Esto hace que, por ejemplo, se conozca el desempeño de la actividad económica de diciembre recién a finales de febrero o comienzos de marzo.

Tanto tiempo de demora genera dos problemas interrelacionados: primero, en una coyuntura tan dinámica como la argentina, el indicador pasa desapercibido para la opinión pública por su lejanía con el período a analizar y no se utiliza como insumo a la hora de tomar decisiones. Esto quedó muy claro para el pasado diciembre de 2023: en el marco de la suba del tipo de cambio y la liberación de precios realizadas por la nueva administración de la política económica de Argentina, la fuerte retracción de la actividad evidenciada en dicho mes quedó en un segundo plano en la discusión nacional, ya que sus estadísticas tardaron casi dos meses en difundirse. Caso contrario, los efectos de estas políticas en inflación, tipo de cambio, agregados monetarios o balance del Banco Central fueron de público conocimiento y estuvieron en la agenda de la opinión pública desde el primer día del nuevo gobierno.

Es más, no es descabellado pensar que la falta de conocimiento de esta información se traduce también en una falta de jerarquización de la actividad económica por parte de los *policy makers*. Si bien la última década marcó una alta inestabilidad económica, el contexto económico argentino se volvió muy volátil durante el último año (2023), fundamentalmente por el ingreso a un Régimen de Alta Inflación. Esto hizo que el horizonte temporal para las decisiones sea mucho más corto: 1 mes o algunas semanas. Por esto, los agentes económicos revisan sus pronósticos semana tras semana, ya que la dinámica de alta inflación nubla las perspectivas a futuro y el panorama muestra mucha incertidumbre.

Ejemplo de esto es la dinámica de las principales variables económicas entre el 30 de octubre del 2023 y el 30 de diciembre de 2023. Como se mencionó, dos meses es el tiempo de rezago de difusión del EMAE, mientras que al mismo tiempo, las principales variables económicas fundamentales mostraron una alta volatilidad, como puede verse en la **Tabla 1)**

Tabla 1. En dos meses, la Argentina actual puede sufrir un gran cambio

Principales variables macroeconómicas	30-oct-23	30-dic-23	Variación
Tipo de cambio oficial (AR\$)	350	804,5	129,9%
Tipo de cambio CCL (AR\$)	853,1	973,9	14,2%
AL30 D	25	37,85	51,4%
Riesgo País (En pbs)	2.583	1.906	-26,2%
Reservas brutas (En millones de US\$)	24.614	23.073	-1.541
Reservas netas a precios corrientes (En millones de US\$)	-7.575	-10.116	-2.541
Expectativa de inflación t+1 (REM)	11,5%	25,0%	13,5
Expectativa de inflación t+12 (REM)	195,2%	213,0%	17,8
Tasa de interés (TEM)	11,1%	8,4%	-2,8

Fuente: Elaboración propia en base a BCRA y diversas fuentes

En un intervalo temporal tan corto como son dos meses, en Argentina pueden observarse cambios muy fuertes: el tipo de cambio de oficial puede trepar casi 130% pero el CCL sólo 14%, el valor de los bonos argentinos (AL30) puede crecer más del 50% en dólares y el Riesgo País bajar 26,2%, las reservas brutas y netas caer menos de US\$ 3.000 millones, las expectativas de inflación del mes siguiente subir 13,5 p.p. pero las anuales sólo 17,8 p.p., a la vez que la tasa de interés efectiva nominal cae 2,8 p.p., pese al shock nominal que se verificó en las otras variables. En otras palabras, cambios que pueden darse en décadas en otros países vecinos, en Argentina pueden darse en meses o semanas.

La segunda particularidad del EMAE es que este se conoce con tanto tiempo de demora que no logra cumplir el rol que busca: ser un anticipador del PBI. En la práctica, este último termina siendo el único indicador que se tiene en cuenta a la hora de seguir la dinámica de la actividad, ya que si bien tiene rezagos, el EMAE también los tiene y sólo capta un mes de referencia, mientras que el otro un trimestre.

Por estas razones, resulta de enorme utilidad contar con un anticipo del EMAE 30 días antes de lo publicado por el INDEC. Pero dicha estimación no va a estar exenta de trabas: a la hora de buscar herramientas para pronosticar esta variable objetivo surgen dos nuevos problemas, los cuáles provienen de la revisión de la serie hacia atrás (sus estimaciones son provisorias) y de la serie desestacionalizada.

El primero es que, en cada una de las publicaciones oficiales, dado que las últimas estadísticas eran estimadas, se corrige la serie del EMAE hacia atrás. Esto lleva a que el modelo utilizado para pronosticar contemple información como *input* que luego cambia, llevando a un mínimo error ya desde el momento previo a realizar el pronóstico. El tamaño de este error es difícil de cuantificar previamente, ya que depende de cuánto modifique el INDEC las estimaciones de los meses previos, lo cual es volátil y depende de factores exógenos a este trabajo. Pero se podría estimar que es un error bajo, que no supera el medio punto porcentual.

Por otra parte, como se anticipó en la sección anterior, el segundo problema proviene de la serie desestacionalizada, la cual también se modifica permanentemente. Es más, los coeficientes estacionales sufren de alta inestabilidad, más aún tras la volatilidad que sufrió la serie sin estacionalidad en los años de pandemia (Frank, 2021, b). Esto hace que, a modo de ejemplo, si el INDEC publica que el EMAE desestacionalizado creció 1,2% en agosto; dos meses después es habitual que el EMAE desestacionalizado de agosto puede hasta haber sufrido una contracción mensual. Semejante varianza se traduce también en una falta de relevancia del indicador en cuestión, por lo que la atención se suele centrar sobre la serie original.


Por estas razones, este trabajo se propone seguir el siguiente camino: anticipar la serie original del EMAE -su variación interanual- para luego construir, de requerirlo, las series desestacionalizadas del EMAE y también la del PBI trimestral (serie original y desestacionalizada). Es decir, buscar pronosticar lo que se conoce más rápido en el tiempo y desde ahí lograr obtener información más precisa en el tiempo, para conocer qué resultados se vienen observando de la variable más relevante para medir el flujo de riqueza interna en Argentina. Como se verá en la siguiente subsección, esta misma dinámica se realizará para el EMAE no Agropecuario.

b) El PBI Agropecuario como elemento exógeno a la hora de predecir: distinción entre EMAE sin sector Agropecuario vs EMAE Agropecuario

Otro factor que fue considerado a la hora analizar la variable objetivo y de realizar el modelo de estimación fue el de distinguir en dos grupos la variable objetivo del EMAE: EMAE sin sector Agropecuario y EMAE Agropecuario. Al seguir ambos segmentos dinámicas muy disímiles, en el presente trabajo se consideró como variable objetivo a la actividad económica excluyendo la parte agropecuaria, además del EMAE agregado.

En detalle, vale la pena aclarar que tanto el PBI como el EMAE pueden desagregarse en diferentes sectores, entre los que se destacan el Agro, la Industria Manufacturera, el Comercio, diferentes Servicios no transables, entre otros. Pero por su dinámica, uno puede distinguir fundamentalmente en dos grandes grupos: sectores que se mueven en línea con el ciclo económico y la demanda interna, mientras que el Agro depende de factores exógenos (clima, conocimientos tecnológicos, demanda externa, etc).

Si se observa la dinámica de estos dos grupos, uno puede observar que la producción agropecuaria sigue otros factores (por ejemplo, con alta volatilidad los años de sequía y su recuperación posterior, por ejemplo), mientras que el EMAE no Agropecuario se mueve más en línea con el ciclo y las variables vinculadas a la demanda interna (ver **Gráfico 3**). Entre 2005 y 2023 no coincidieron en el signo de su variación anual en 8 de los 19 años.



Analizando las estadísticas descriptivas de las tres variables relevantes (EMA, EMA sin Agro y EMA Agropecuario), esta vez en función de la serie de tiempo interanual con frecuencia mensual (métrica utilizada para predecir), puede verse que no existen tantas diferencias en términos de las medidas de tendencia central de cada variable (ver **Tabla 2**). Es decir, tanto el promedio como la mediana de las tres variables orbitan en torno a 0,0%.

Tabla 2. Estadística descriptiva para el EMAE y sus componentes

Variaciones interanuales entre Ene-12 y Nov-23	EMAE*	EMAE sin Agro*	EMAE Agropecuario*
Media	0,3%	0,5%	-0,3%
Mediana	0,1%	0,2%	0,3%
Mínimo	-24,4%	-28,4%	-45,2%
Máximo	30,0%	37,0%	52,8%
Rango	54,5%	65,4%	98,0%
Coefficiente de Variación	22,3	15,0	45,9

Fuente: Elaboración propia en base a INDEC


Sin embargo, en términos de volatilidad se nota una diferencia importante: el EMAE sin Agro es la serie con menor variabilidad, con un coeficiente de variación de 15 p.p., mientras que el del EMAE Agropecuario es 45,9 puntos porcentuales. Inclusive los máximos y mínimos superan crecimientos de más de 50% y caídas superiores al 40%, debido a la alta volatilidad mencionada de la producción del campo argentino debido a la cuestión climatológica. Para sumar, en términos de correlación, el vínculo lineal entre el EMAE no Agropecuario y el Agropecuario es muy bajo: el coeficiente de correlación es de 22% en el período mencionado, por lo que parecen seguir dinámicas diferentes entre sí.

Pese a estas divergencias, en el presente trabajo se probó primero por intentar predecir el EMAE agregado en su conjunto. Es decir, utilizar las diferentes variables explicativas que se desarrollarán en la siguiente sección y, a través de diferentes modelos econométricos y de *machine learning*, tener la variación interanual del EMAE (variable objetivo) con mayor anticipación.

Sin embargo, ninguno de los 6 modelos utilizados -los cuales se profundizarán en la **Sección 4 y 5**- captó bien el impacto de la sequía en el EMAE durante el segundo trimestre de 2023, perdiendo gran poder predictivo y no logrando el objetivo de este trabajo con precisión (ver **Gráfico 4**). Si bien son modelos que ajustan bien a la muestra en momentos donde el campo no sufre variaciones en su producción de fuerte magnitud, para adelante los modelos también mostrarán problemas en su performance predictiva: en especial, en 2024 se espera que el sector Agropecuario crezca con gran fuerza por la mejoría climatológica y la baja base de comparación de 2023 tras la sequía.

Gráfico 4. Los pronósticos del EMAE no captaron bien la sequía

En variación % interanual



Fuente: Elaboración propia en base a INDEC

Estos motivos son los que llevaron a que también se incorpore como variable objetivo de este trabajo al EMAE excluyendo el sector Agropecuario, lo que permite predecir con mayor precisión el ciclo real de la economía argentina, a la vez que no resulta difícil incorporarle la variación del agro al modelo, determinada de forma exógena por otros factores, tal como se mencionó.

Para esta construcción, se utilizaron los ponderadores sectoriales del Valor Agregado Bruto de 2004 (año base del EMAE) y se construyó el EMAE no Agropecuario de la siguiente forma, tomando al $EMA E_{Agro_t}$ y el $EMA E_t$ en números índice:

$$EMA E_t = \alpha EMA E_{Agro_t} + (1 - \alpha) EMA E_{sin Agro_t}$$

Despejando el $EMA E_{sin Agro_t}$, se obtiene que:

$$EMA E_{sin Agro_t} = \frac{EMA E_t - \alpha EMA E_{Agro_t}}{(1 - \alpha)}$$

Donde $\alpha=9,56$ y es la ponderación del $EMA E_{Agro_t}$ en el $EMA E_t$, a la vez que $1 - \alpha$ es el peso de los sectores no Agropecuarios en el EMAE y equivale a 90,4. Estos ponderadores surgen de estimar el peso del Sector “Agricultura, ganadería, caza y silvicultura” en el PBI de 2004, descontando el peso del sector “Servicios de hogares privados que contratan servicio doméstico”, el cual se contabiliza en el PBI pero no en el EMAE, tal como se mencionó.

c) Variables predictoras del EMAE: criterio de selección y frecuencia temporal utilizada

Otra cuestión relevante para la elección del modelo predictivo es el intervalo temporal utilizado y los criterios usados para elegir los diferentes predictores del EMAE. Sobre lo primero, si bien el INDEC brinda información sobre las variaciones interanuales del EMAE, primero desde 1993 y luego desde 2004, el presente trabajo utilizó todos los datos de variaciones interanuales desde enero 2012. Es decir, se requirieron observaciones desde enero 2011 para todas las variables, ya que se trabajó con variaciones de las variables 12 meses hacia atrás.

Esta decisión se fundamentó en la presencia de muchos cambios estructurales en las últimas décadas, los cuales podían añadir más distorsiones a los modelos predictivos, a la vez que complejizaban la disponibilidad de información estadística para todas las variables independientes. Por esta razón, a comienzos de 2012 la economía argentina ya tenía una serie de características similares a la actual: fundamentalmente, estancamiento económico de largo plazo (el PBI per cápita cerraría 2023 en torno a 12% por debajo de 2011), inflación anual superior al 20% interanual y controles al acceso a las divisas, los cuales derivaron en brecha cambiaria.

Si bien entre 2012 y 2023 existieron cambios estructurales también, se buscó aislar estos efectos mediante variables dummy, como fue el caso de la pandemia y sus consecuentes efectos en la caída y posterior recuperación de la actividad entre 2020 y 2021; o también, el intervalo temporal entre 2016 y 2019 en el cual no existieron controles cambiarios.

Además, el otro criterio relevante para la elección del intervalo temporal fue la posibilidad de disponer de datos para las variables explicativas de los modelos. Construir un modelo predictivo del EMAE con variables explicativas desde 2004 implicaba reducir el tamaño de los predictores significativamente, lo cual perdía precisión al pronóstico. Tomando datos entre enero 2012 y noviembre de 2023, el modelo se entrenó con un tamaño muestral suficientemente grande: 143 observaciones.

Por último, la otra consideración para elegir los predictores fue el momento de difusión de sus estadísticas. Recapitulando, el objetivo de este trabajo es que, a través de los modelos de *Nowcasting* utilizados, se logre anticipar la variación interanual del EMAE. En particular, se buscará predecir el EMAE del período de

referencia entre 20 y 30 días después de la finalización de dicho período, es decir, exactamente un mes antes que lo difundido por el INDEC.

Por estas razones, los modelos de *Nowcasting* contruidos tienen que poder tener disponibles todas las variables independientes el día de difusión del EMAE, pero con el objetivo de pronosticar el período posterior: a modo de ejemplo, cuando el INDEC publicó el EMAE de noviembre el día 23 de enero de 2024, este modelo ya permitió conocer un proxy del EMAE de diciembre de 2023. Así, la utilidad de este trabajo radica en tener información certera de qué dinámica tomará la actividad económica sólo tres semanas después de finalizar el periodo, en lugar de ser 50 días más tarde.

Esto hizo que variables muy relevantes para anticipar el EMAE no queden incluidas, como el Índice de Producción Industrial manufacturero (IPI – INDEC) o el Indicador Sintético de la Actividad de la Construcción (ISAC – INDEC), los cuales brindan información precisa sobre dos sectores grandes del EMAE pero se difunden alrededor de 15 días después del EMAE. De todas formas, se logró encontrar 44 predictores de alta frecuencia.

En cuanto a las características de los predictores, para el presente trabajo se buscaron todas las variables económicas de alta frecuencia, que pueden observarse en la **Tabla 3** en detalle asociadas con su respectiva clasificación:

Tabla 3. Variables predictoras usadas para el pronóstico del EMAE

Clasificación	Variables a modelizar
<i>Recaudación</i>	Recaudación General, IVA, IVA DGI, Créditos y débitos, Seguridad Social
<i>Importaciones</i>	Cantidades importadas: Bienes, Bienes sin energía, Bienes de capital, Bienes intermedios, Piezas, Bienes de Consumo, Vehículos
<i>Producción sectorial</i>	Autos, Utilitarios, Vacas, Cemento, Acero
<i>Energía</i>	Demanda de energía eléctrica no residencial, ventas de gasoil, ventas de nafta super
<i>Cambiarias</i>	TCN Oficial, Tipo de Cambio Real Multilateral, Brecha cambiaria CCL, Tipo de cambio Exportador Efectivo, Tipo de cambio Importador Efectivo
<i>Monetarias y nominales</i>	Inflación mensual, Base monetaria real, Agregados monetarios reales: total M1, total M2, total M3, M1 privado, M2 privado, M3 privado.
<i>Financieras</i>	Riesgo País, Merval real, Merval en US\$
<i>Expectativas</i>	ICC UTDT general, Situación Personal, Perspectivas macro, Bienes Durables, Índice Líder
<i>Dummys</i>	Pandemia, Cuarentena, Descuarentena.

Fuente: Elaboración propia en base a diversas fuentes

La elección de estas se centró en disponer de datos públicos mensuales difundidos sólo 20 días después de finalizar su período de referencia, para poder ser el input del modelo predictivo del EMAE, tal como se anticipó. Entre los predictores, se encuentran todas las variables vinculadas con actividad de recaudación, de comercio exterior, monetarias, financieras y cambiarias, tomando como referencia la literatura de *Nowcasting* analizada. A la vez, también se incluyeron los indicadores de producción y demanda conocidos en el mes, como autos, acero o también la venta de nafta super.

Muchas de ellas también fueron construidas para el presente trabajo, tomando como hipótesis que su impacto en actividad era más relevante de otra manera que lo conocido por el organismo de difusión de dicha información. En otras palabras, por ejemplo, se construyeron diferentes variantes de las cantidades importadas, ya que se hipotetizó que el impacto en actividad era más fuerte si se descontaban las cantidades importadas de energía.

De la misma forma, se pensó que la demanda de energía más vinculada con la producción es la comercial e industrial, por lo que se descontó a la demanda de

energía eléctrica total su componente residencial. Asimismo, el tipo de cambio oficial nominal perdió importancia en el último tramo de 2023 ya que los exportadores e importadores accedían a tipos de cambio implícitos más complejos, los cuales tenían cupos, impuestos o resultaban de combinaciones con el tipo de cambio financiero CCL. Por esto, se construyeron tipos de cambio exportadores e importadores, para medir mejor el impacto de los saltos cambiarios de finales de 2023.

En la próxima sección se desarrolla en detalle los modelos predictivos que se utilizaron para combinar estas variables explicativas con el EMAE no Agropecuario y el EMAE, así poder tener una variable proxy mensual del PBI tras 20 días de finalizar el período de referencia.

4) Econometría: modelos para pronosticar el EMAE y el EMAE no Agropecuario

a) Modelo ARDL

El primero de los modelos estimados es el modelo Autorregresivo de Rezagos Distribuidos (por sus siglas en inglés, de ahora en más será ARDL). Este se enmarca en la familia de modelos dinámicos que cuentan con rezagos de las variables dependientes y las variables explicativas. El caso más simple de los modelos autorregresivos es el AR (1) el cual vincula a una variable y_t con ella misma en el pasado más cercano (y_{t-1}).

Como se señaló en la revisión bibliográfica, diferentes autores utilizaron el modelo AR (1) como punto de referencia para la comparación con sus modelos de pronósticos más complejos, considerándolo como la serie de tiempo más simple. Pero este trabajo intentó ir más allá y tomar como modelo de comparación el modelo ARDL, considerando no sólo el efecto de la variable y_{t-1} en la y_t , sino también el vínculo entre esta última y otras variables explicativas en el presente y en el pasado cercano. Estas pueden englobarse dentro de un vector más amplio X_t . De esta forma, puede ganarse poder explicativo y predictivo, conociendo más información del período actual y pasado para el pronóstico del PBI.

En detalle, el modelo ARDL permite estimar el cambio marginal de muchas variables explicativas (y sus rezagos) pero también de la misma variable dependiente en el pasado cercano. Dichas modificaciones impactarán sobre la variable dependiente en el período actual (y_t) y pueden ser estimadas mediante el método de Mínimos Cuadrados Ordinarios (Nkoro & Uko, 2008; Rosales et al., 2012).

De esta forma, el modelo a estimar puede escribirse como:

$$y_t = \alpha + \sum_{i=0}^r \beta_i x_{t-i} + \sum_{g=1}^p \gamma_i y_{t-g} + u_t$$

En nuestro caso, y_t representa el EMAE (descontando el sector agropecuario), x_{t-i} es el vector de variables explicativas con sus respectivos rezagos relevantes y, por último, y_{t-g} representan los retardos del EMAE. Para no tener problemas de estimación, se verificó que u_t no presente problemas de autocorrelación ni heterocedasticidad.

b) Modelos de aprendizaje automático: Lasso, Ridge y Elastic Net

Friedman et al. (2008) resumen tres métodos de aprendizaje automático (*machine learning*), que son útiles para la tarea de predecir variables: Lasso, Ridge y Elastic Net. En el presente trabajo, se utilizarán estos tres modelos, ya que la virtud de incorporar esta clase de modelos de aprendizaje automático radica en que generalmente superan a los enfoques de modelado tradicionales (como Mínimos Cuadrados Ordinarios) en el desempeño predictivo. Si bien no es una tarea que se lleve a cabo en este trabajo, esta ganancia para el *Nowcasting* se da a costa de perder propiedades relevantes para la inferencia causal, lo cual no es problemático para predecir el EMAE (Chakraborty y Joseph, 2017).

Esto es así porque la idea central de Lasso, Ridge y Elastic Net es la de regularización. La noción radica en reducir y controlar la complejidad del modelo a estimar (es decir, la cantidad de parámetros) sin tener que probar todas las combinaciones posibles, a través de un parámetro por fuera del modelo. Debido a que las estimaciones con muchas variables explicativas tienden producir sobreajustes (*overfitting*), eliminando sesgos pero teniendo una alta varianza, es habitual toparse con modelos insesgados que no son los que menor error cuadrático medio tienen necesariamente.

Por eso, estos modelos de regularización buscan evitar el sobreajuste de los modelos lineales buscando una performance predictiva óptima. Así, el modelo computa todos los modelos posibles para un determinado conjunto de datos y se queda con el que menor error de predicción tenga.

Con estos procedimientos, los modelos mencionados realizan la tarea de “reducción de dimensionalidad”, que implica acortar la cantidad de variables

relevantes en un modelo, buscando el mejor posible predictivamente pero más pequeño en términos de complejidad, lo que eficientiza el trabajo de los investigadores *ex post*.

Este objetivo se logra a través de las tres técnicas (Lasso, Ridge y Elastic Net) que son métodos de suavizados que introducen un término de penalización a la función de error que busca poner un límite a la complejidad del modelo a estimar (cantidad de variables explicativas), actuando sobre valores de parámetros que sean diferentes de cero, especialmente grandes.

I) Modelo Lasso (Least Absolute Shrinkage and Selection Operator)

La idea general de estas técnicas es penalizar el valor de los coeficientes en la función de pérdida cuadrática de MCO. Comenzando por el modelo Lasso, este tiene la siguiente forma:

$$R_{Lasso}(\beta) = \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p |\beta_j|$$

El término de penalización a la función objetivo se llama término de regularización. λ representa el peso asignado a la regularización: si vale cero significa que se retorna al caso sin regularización (Mínimos Cuadrados Ordinarios), pero $\lambda \rightarrow \infty$ (a medida que crece) hace que más coeficientes se vuelvan cero.

Con esta penalización, Lasso pone variables en el modelo sólo si son suficientemente relevantes y las que no lo son, las sesga hacia valer cero. Este proceso que realiza Lasso se lo que se conoce como *Shrinkage*, que es la estimación sesgada por la regularización. Así, elimina variables (sesgo por variables omitidas) pero baja la varianza mejorando el error cuadrático medio. Por esta razón, Lasso suele usarse para elegir variables explicativas relevantes o lo que se conoce en la literatura como selección de características o *features* (Chakraborty y Joseph, 2017).

Sobre la elección del λ óptimo, existen diferentes metodologías. En este trabajo en particular, tanto para Lasso como para Ridge y Elastic Net se modelizó mediante el λ encontrado con el método de *cross-validation*. Este consiste en probar computacionalmente todos los λ posibles y quedarse con el que minimice el error cuadrático medio (medida de bondad de pronóstico).

II) Modelo Ridge

La regresión Ridge es similar a Lasso pero se diferencia en que no reduce a cero los coeficiente del modelo que reflejen variables no tan relevantes. Así, todas las variables explicativas se mantienen en el modelo pero reducen su importancia significativamente, haciéndolo menos complejo y más flexible en términos de sobreajuste.

Una ventaja de Ridge sobre Lasso es que es más estable, fundamentalmente cuando existe una correlación entre las variables explicativas. Al sensibilizar los datos de entrenamiento del modelo, por ejemplo añadiendo más observaciones a la muestra, los coeficientes de Ridge se modifican menos que los de Lasso, el cual tiende a elegir variables explicativas y reducir a cero los coeficientes de las restantes correlacionadas (Friedman et al., 2008).

Nuevamente, el coeficiente λ es el hiperparámetro que se define por fuera del método de estimación de los coeficientes Ridge y busca hacer el proceso de regularización. Pero en este caso, para no eliminar los coeficientes menos relevantes, Ridge incorpora los β_j multiplicados por λ elevados al cuadrado. En términos de ecuación, este método tiene la próxima estructura:

$$R_{Ridge}(\beta) = \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p \beta_j^2$$

III) Modelo Elastic Net

Por último, el modelo Elastic Net es una combinación de Lasso y Ridge. Esta estrategia de regularización incorpora ambos términos de penalización, tanto el término de Lasso como el de Ridge. Así, Elastic Net proporciona las ventajas de ambas técnicas, ya que permite seleccionar *features* eliminando las variables no tan relevantes como Lasso, pero también reduciendo los valores de los coeficientes como Ridge. Además, este modelo brinda mayor estabilidad que Lasso también en los coeficientes estimados.

Sin embargo, la complejidad computacional de Elastic Net es mayor ya que debe combinar ambas penalizaciones, a la vez que a menudo dificulta su interpretación directa porque algunos coeficientes se vuelven muy pequeños aunque no nulos.

Elastic Net también adiciona un hiperparámetro α que controla la proporción relativa de las penalizaciones Ridge y LASSO, el cual también fue elegido por el

método de *cross-validation*. En síntesis, la modelización de Elastic Net puede ser resumida así:

$$R_{Elastic\ Net}(\beta) = \sum_{i=1}^n \left(y_t - \beta_0 - \sum_{j=1}^p \beta_j x_p \right)^2 + \alpha \left[\lambda \sum_{j=1}^p \beta_j + (1 - \lambda) \sum_{j=1}^p \beta_j^2 \right]$$

c) Modelo GETS: General-to-specific

El modelo GETS es una técnica algorítmica para la selección de variables independientes en un modelo de regresión, el cual se basa en la idea de partir de un modelo general con la totalidad de las variables a estimar para luego ir hacia un modelo de menor complejidad (Clarke, 2014). En el presente trabajo, para ejemplificar, se partió de un modelo que incluía la totalidad de los indicadores de alta frecuencia mencionados en la Sección 3 para terminar utilizando un modelo con mejor ajuste y simplicidad.

En primer lugar, se realiza el proceso de modelización general donde se incluyen todas las variables explicativas que el investigador intuye como relevantes, lo que se conoce como llama Modelo General Sin Restricciones (GUM, por sus siglas en inglés). A continuación, el algoritmo realiza pruebas de restricciones para testear la significancia de cada variable, utilizando test de hipótesis y criterios de información. Luego, también prueba si se cumple con los supuestos de normalidad y no autocorrelación de los errores (Espinosa, 2022).

Por último, el modelo GETS arma el modelo final seleccionando las variables más relevantes y eliminando las que, en cambio, tienen menor importancia. Este proceso de selección se hace mediante pruebas que permiten observar si la inclusión de una variable adicional mejora significativamente la bondad de ajuste del modelo o no.

Para este último objetivo se toma como métrica el R-cuadrado y los criterios de información. Vale destacar que, a diferencia de los modelos previamente desarrollados, el fin central del GETS entonces no es el de predecir, sino el de encontrar el mejor ajuste al interior de la muestra. Esto implica no centrarse en buscar la flexibilidad por fuera del modelo (incluso a costa de sesgar el modelo como Lasso, Ridge o Elastic Net), sino en lograr que las variables explicativas cubran una buena proporción de la variabilidad de la variable objetivo.

d) Modelo Global Search Regression

El último modelo utilizado es el surgido del algoritmo Global Search Regression (GSR), elaborado por Gluzmann & Panigo (2015), el cual también puede ser utilizado para regresiones de corte transversal, series de tiempo o datos de panel. En este trabajo se aplicó en series de tiempo, ya que se utilizaron operadores de rezagos para agregar información relevante para el pronóstico del EMAE (por ejemplo, qué registró el INDEC para el EMAE en el período inmediatamente anterior).

La técnica de selección de parámetros es una metodología *data-based* (en contraposición a las técnicas *theory-based*). Es decir, este esquema utiliza un enfoque de explorar las diferentes variables y estructuras del modelo con el objetivo de encontrar la mejor combinación posible de ajuste a los datos efectivos, sin considerar relevante las interpretaciones entre las posibles relaciones entre variables, lo cual se vuelve auspicioso para un modelo predictivo.

Pero en lugar de seguir un enfoque secuencial paso a paso, este algoritmo evalúa múltiples modelos de forma simultánea. La diferencia central con el modelo GETS es que este último parte de un modelo general y de a poco va pasando a combinaciones menos extensas probando de a un modelo a la vez, cuando el enfoque de GSR es una búsqueda global simultánea.

Los criterios utilizados por Global Search Regression para seleccionar el modelo tienen en cuenta el ajuste del modelo a los datos, pero también penalizan su complejidad de información (Akaike o Bayesiano). A la vez, GSR garantiza la optimización con criterios de selección fuera de la muestra, lo que es una dificultad para modelos como GETS, como se anticipó (Gluzmann & Panigo, 2015).

El algoritmo de GSR presenta dos etapas. En la primera, el investigador selecciona las variables relevantes, teniendo en cuenta que se sugiere menos de 30 parámetros por la dificultad computacional, lo que implicó restringir la selección a las variables más importantes. Con estas variables candidatas GSR realiza todas las combinaciones posibles de esas variables explicativas, incluyendo interacciones, las variables al cuadrado o sus respectivos lags. Luego, en una segunda etapa realiza cada regresión posible guardando los resultados de cada modelo y su bondad de ajuste, eligiendo finalmente el óptimo.

En este trabajo, la aplicación de GSR y el alcance computacional disponible permitió utilizar 15 variables independientes (con dos rezagos cada una), lo que implicó combinar más de 130 mil modelos. De todos estos, el algoritmo eligió un “ganador”, del cual se profundizará en su performance en la siguiente sección.

5) Resultados encontrados

Dado que el objetivo central de este trabajo es encontrar un modelo que permita anticipar la trayectoria interanual del EMAE, el criterio final de selección del modelo econométrico debe estar vinculado a la performance de cada modelo en términos de *Nowcasting*. Vale aclarar que también, en la medida en que los modelos lo permitieron, se contrastó que los residuos sean ruido blanco, se distribuyan normalmente y cumplan los criterios de homocedasticidad, previo a la selección de los métodos.

En este sentido, las métricas estadísticas utilizadas para medir qué modelo tuvo un mejor desempeño son las clásicas estadísticas de bondad de pronóstico. Las elegidas en este trabajo son: la Raíz del Error Cuadrático Medio (*RMSE*, por sus siglas en inglés), el Error Absoluto Medio (*MAE*) y el Error Absoluto Porcentual Medio (*MAPE*). Antes de mostrar los resultados encontrados, vale la pena detallar qué dice cada una de ellas, ya que la elección de tres criterios diferentes es necesario para cubrir las diferentes ventajas y desventajas de cada métrica.

El RMSE estima la raíz cuadrada del promedio de los errores al cuadrado, entendidos a los errores como la diferencia entre los valores pronosticados por cada modelo y los valores reales efectivos del EMAE. La idea es que cuanto menor sea el RMSE, menor será el error del modelo; a la vez que la raíz cuadrada permite analizar el error del modelo en la misma unidad de medida que se encuentra la variable dependiente (en este caso, variaciones interanuales). Además, al incorporar el cuadrado de los errores, el RSME les asigna mayor penalidad a los errores más grandes, lo que puede impactarle negativamente en valores atípicos.

Por otra parte, el Error Absoluto Medio (MAE) calcula el promedio de los errores absolutos entre los valores esperados por el modelo y los valores efectivos. Al igual que el estadístico RMSE, la unidad de medida es la misma que la de la variable dependiente, aunque como no eleva al cuadrado los errores, no penaliza los errores más grandes ni es sensible a valores *outliers*. También, un valor más bajo representa un pronóstico más preciso.

Por último, el Error Absoluto Porcentual Medio (MAPE) está expresado en porcentaje y sirve como métrica relativa, la cual refiere al promedio de los errores absolutos entre los valores estimados y los efectivos. Al no estar expresado en la unidad de medida de la variable dependiente, puede ser útil para comparar modelos que pronostiquen variables diferentes, aunque no es el caso que compete a esta

investigación. Además, al igual que los anteriores, mientras más chico sea este valor, mejor será el pronóstico.

En síntesis, los diferentes estadísticos pueden desarrollarse de la siguiente forma:

$$\text{Raíz del Error Cuadrático Medio: } \mathbf{RMSE} = \sqrt{\frac{\sum_{t=T+1}^{T+N} (Y_t^f - Y_t)^2}{N}}$$

$$\text{Error Absoluto Medio: } \mathbf{MAE} = \frac{\sum_{t=T+1}^{T+N} |Y_t^f - Y_t|}{N}$$

$$\text{Error Absoluto Porcentual Medio: } \mathbf{MAPE} = \frac{\sum_{t=T+1}^{T+N} \left| \frac{Y_t^f - Y_t}{Y_t} \right|}{N}$$

Donde: Y_t^f el valor del EMAE pronosticado por el modelo, Y_t es el EMAE efectivo y N es la cantidad de observaciones.

Hechas estas aclaraciones, se realizaron estas estimaciones utilizando como variables dependientes el EMAE y el EMAE sin Agro. Para ambos casos, los parámetros del modelo en general fueron elegidos por los algoritmos seleccionados, considerando la totalidad de las 44 variables elegidas, en función de los criterios ya detallados en la **Sección 4**. Eso ocurrió tanto con los modelos Lasso, Ridge, Elastic Net y GETS.

Distinto fue el caso del modelo más simple (ARDL) y del algoritmo GSR. Para el primero, se partió de las 44 predictores y sus primeros 2 rezagos. Luego, se buscó la combinación de variables que mejor bondad de ajuste muestren dentro de la muestra (tomando el R-cuadrado ajustado como métrica), considerando también la significatividad de cada variable en particular y que sus errores sigan ruido blanco. Esto determinó 14 parámetros óptimos.

Para el caso del algoritmo GSR, tal como se detalló en la **Sección 4**, la complejidad computacional de probar todas las combinaciones posibles de parámetros implicó restringir la selección a 15 variables explicativas. Estas 15 fueron elegidas considerando su grado de correlación con las variables dependientes (EMAE y EMAE sin agro); aunque también se optó por la amplitud de características y rubros a considerar por el modelo. Es decir, se buscó que el algoritmo contemple al menos

una variable por clasificación (la que mejor correlación muestre), dentro de la selección realizada. Así, el modelo GSR consideró a los 15 parámetros que mejor correlación mostraron pero también cumplió con tener una variable de todas las clasificaciones seleccionadas en la **Tabla 3** (recaudación, comercio exterior, monetarias, financieras, cambiarias, de expectativas, de energía, demanda, producción sectorial y variables dicotómicas para captar la pandemia).

Los primeros resultados pueden verse en la **Tabla 4**, tomando como variable dependiente el EMAE no Agropecuario. En este caso, el modelo que mejor performance obtuvo fue el modelo Lasso según el estadístico de la Raíz del Error Cuadrático Medio (RMSE) y el MAE (Error Absoluto Medio), mientras que Ridge por el lado del Error Absoluto Porcentual Medio (MAPE). Ambos modelos de *machine learning* fueron los que mejor acierto tuvieron, lo que muestra la relevancia de estos algoritmos que jerarquizan el pronóstico en lugar de la inferencia, tal como se detalló en la **Sección 4**.

En términos de magnitud del error, todos los modelos mostraron una diferencia de menos de 1,5 p.p. (tomando RMSE y MAE que se expresan en variaciones interanuales). Es decir, considerando las variaciones interanuales del EMAE una diferencia muy pequeña, lo cual refuerza la importancia de todos modelos para conocer cómo se desarrolló la actividad económica 30 días antes.

Tabla 4.EMA no Agropecuario: bondad del pronóstico para cada modelo

Estadístico de bondad del pronóstico	ARDL	Lasso	RIDGE	Elastic Net	GETS	GSR
RMSE (Raíz del Error cuadrático Medio)	1,33%	1,08%	1,18%	1,53%	1,11%	1,28%
MAE (Error Absoluto Medio)	1,05%	0,87%	0,91%	1,19%	0,89%	1,02%
MAPE (Error absoluto porcentual medio)	2,94%	1,63%	1,10%	3,15%	2,05%	1,17%

Fuente: Elaboración propia en base a diversas fuentes

En cuanto a los modelos restantes, la **Tabla 5** establece un orden de jerarquía más nítido en cuanto a la posición que le tocó a cada modelo en la carrera por pronosticar con mayor acierto. Para las primeras dos métricas el segundo lugar se lo quedó la selección de parámetros vía GETS, mientras que para MAPE fue el de Global Search Regression. Los modelos que peor performance obtuvieron fueron el de *Elastic Net* y el ARDL.

Tabla 5. Proyección del EMAE no Agropecuario: de mejor a peor performance

Posición según acierto	RMSE	MAE	MAPE
1er lugar	Lasso	Lasso	RIDGE
2do lugar	GETS	GETS	GSR
3er lugar	RIDGE	RIDGE	Lasso
4to lugar	GSR	GSR	GETS
5to lugar	ARDL	ARDL	ARDL
6to lugar	Elastic Net	Elastic Net	Elastic Net

Fuente: Elaboración propia en base a diversas fuentes

Este mismo ejercicio fue hecho con la variable dependiente del EMAE agregado total. Si bien, como se aclaró en la **Sección 3**, el pronóstico para el EMAE no Agropecuario tiene diferentes ventajas -más aún en años donde el agro muestra alta variabilidad como 2023 y 2024-, resultó útil para los propósitos de este trabajo realizar los mismos tipos de modelos considerando como variables dependientes al EMAE. Por supuesto, los valores, cantidades y variables que hacen a los parámetros óptimos encontrados para cada modelo no son los mismos que tomando al EMAE no Agropecuario como variable dependiente, por lo que las estadísticas de bondad de pronóstico diferirán.

En este caso, la **Tabla 6** muestra los estadísticos de bondad de pronóstico de los seis modelos para el EMAE. Nuevamente, Lasso lidera tanto el caso de RMSE como el de MAE, mientras que el modelo ARDL marca la sorpresa para el caso de MAPE. También, puede verse que a diferencia de lo observado en la **Tabla 4**, la magnitud del error es mayor en este caso, lo que responde a la alta variabilidad del sector Agropecuario. Mientras que para el caso de RMSE Lasso tenía un error de 1,08 p.p. para el EMAE sin Agro, para el EMAE esta cifra asciende a 1,48 puntos porcentuales. De todas maneras, siguen siendo modelos muy útiles para el fin de este trabajo.

Tabla 6. EMAE agregado total: bondad del pronóstico para cada modelo

Estadístico de bondad del pronóstico	ARDL	Lasso	RIDGE	Elastic Net	GETS	GSR
<i>RMSE (Raíz del Error cuadrático Medio)</i>	1,52%	1,48%	1,78%	1,76%	1,53%	2,07%
<i>MAE (Error Absoluto Medio)</i>	1,19%	1,15%	1,34%	1,32%	1,19%	1,50%
<i>MAPE (Error absoluto porcentual medio)</i>	0,38%	0,49%	0,70%	0,69%	0,52%	0,61%

Fuente: Elaboración propia en base a diversas fuentes

La **Tabla 7** puede dar un panorama mejor de los modelos restantes. Para el pronóstico del EMAE, el modelo Ridge no tuvo una buena performance (quedó quinto para RMSE y MAE, mientras que sexto para MAPE). La performance de Global Search Regression tampoco fue la esperada si se compara con los resultados que obtuvo para el EMAE no agropecuario: en este caso quedó último para RMSE y MAE, aunque cuarto para MAPE. Elastic Net mostró mejores estadísticos que lo que se había visto para la producción no agropecuaria.

Tabla 7. Proyección del EMAE total: de mejor a peor performance


Posición según acierto	RMSE	MAE	MAPE
<i>1er lugar</i>	Lasso	Lasso	ARDL
<i>2do lugar</i>	ARDL	GETS	Lasso
<i>3er lugar</i>	GETS	ARDL	GETS
<i>4to lugar</i>	Elastic Net	Elastic Net	GSR
<i>5to lugar</i>	RIDGE	RIDGE	Elastic Net
<i>6to lugar</i>	GSR	GSR	RIDGE

Fuente: Elaboración propia en base a diversas fuentes

Luego de comparar los diferentes estadísticos de bondad de pronóstico para los seis modelos utilizados, resulta interesante contrastar lo pronosticado por el modelo más preciso con lo realmente efectivo lanzado por el INDEC. Una aclaración relevante, en este caso es que podemos hablar solamente de contrastes al interior de la muestra y los datos de entrenamiento del modelo, ya que aún no tuvo muchas pruebas en la práctica cotidiana para predecir datos fuera de la muestra. De todas

formas, es un ejercicio recurrente en la literatura comparar los resultados del modelo de *Nowcasting* con los datos efectivos publicados por el INDEC.


En primer lugar, el **Gráfico 5** da una mirada de largo plazo del modelo Lasso aplicado para el predecir el EMAE excluyendo el sector Agropecuario. A rápida vista muestra un gran ajuste del modelo en línea con el ciclo de la producción no Agropecuaria, tal como arrojaban las estadísticas de bondad de pronóstico.



Sin embargo, para distinguir en detalle la dinámica de los últimos meses parece necesario hacer foco en un intervalo temporal más corto. En ese sentido, el **Gráfico 6** muestra las mismas dos variables pero considerando el intervalo de tiempo entre enero 2022 y noviembre 2023. Aquí se permite ver en detalle la buena performance del modelo también para captar cambios de dirección en la variación interanual de la variable dependiente (aceleración del crecimiento o desaceleración, por ejemplo), lo cual añade utilidad también a la investigación, con independencia de la cifra exacta de la variación de la producción. Además, a simple vista el modelo también muestra no tener una tendencia a subestimar ni sobreestimar en los últimos meses, lo cual es relevante, ya que de ocurrir esto es posible estar frente a la presencia de una variable omitida relevante que haya cobrado importancia en los últimos meses y sesgue demasiado la estimación.

Gráfico 6. Serie corta: Modelo Lasso para el EMAE sin Agro

En variación % interanual



Fuente: Elaboración propia en base a INDEC

Este mismo ejercicio realizado para el EMAE sin Agro puede realizarse para el EMAE agregado, con las limitaciones ya señaladas previamente sobre la cuestión Agropecuaria. El **Gráfico 7** muestra la misma mirada de largo plazo pero para el EMAE y el modelo Lasso. A simple vista se verifica lo observado en la **Tabla 6** previamente: el error de pronóstico aquí es mayor en comparación con el *Nowcasting* del EMAE no Agropecuario.


El **Gráfico 8** hace foco en una serie más de corto plazo para buscar observar estas diferencias de pronóstico. Tomando la serie desde enero 2018 a noviembre 2023, puede verse más en detalle estas divergencias. La elección del intervalo temporal no es inocente: en 2018 ocurrió una divergencia importante entre la dinámica del EMAE excluyendo el sector Agropecuario y la producción de este último sector, producto de la sequía que sufrió el campo argentino en aquel año. Por esta razón, este mismo gráfico remarca esos momentos donde el pronóstico divergió considerablemente del dato efectivo, nuevamente, producto del impacto de los fenómenos climáticos en el EMAE agregado.

En síntesis, los resultados encontrados permiten mostrar las ventajas y limitaciones de los modelos encontrados. En términos generales, es posible decir que el modelo Lasso fue el que mejor pronóstico tuvo por 2 de las 3 métricas de bondad de pronóstico, tanto para predecir el EMAE como para predecir el EMAE no Agropecuario.

Pronosticar las dos variables objetivos permite tener un panorama más amplio, aunque en tiempos de alta volatilidad del sector Agropecuario (como la que se vive en sequía o recuperación de ella) parece mejor considerar el EMAE sin Agro como variable objetivo por su mejor precisión y luego sumarle la variación estimada del Agro.

Gráfico 7. Serie larga: Modelo Lasso para el EMAE


En variación % interanual



Fuente: Elaboración propia en base a INDEC

Gráfico 8. Serie corta: Modelo Lasso para el EMAE

En variación % interanual



Fuente: Elaboración propia en base a INDEC

6) Conclusiones

El presente trabajo se enmarca en la literatura del *Nowcasting* de variables macroeconómicas, término que surge de la interacción entre el presente (*now*) y el futuro (*forecasting*). Su utilidad reside en la incorporación de datos de alta frecuencia temporal para predecir el presente, futuro muy cercano o pasado muy reciente. La idea central es utilizar nueva información disponible para anticipar el desenvolvimiento de variables de interés. Si el período de referencia a pronosticar ya ocurrió y se conocen otros datos de ese momento del tiempo, la utilización del *Nowcasting* le agrega mayor certeza a la estimación, en contraste con un pronóstico hacia adelante del futuro que cuenta con menor información (*forecast*).

En este caso, esta investigación es un aporte para conocer con mayor anticipación la performance de la actividad económica argentina, con el fin de brindar a los diferentes agentes económicos información que resulta necesaria para la toma de decisiones en una economía tan volátil como la de Argentina. La razón fundamental de este trabajo reside en que en las estadísticas del PBI en Argentina (medida principal de la evolución de la producción interna y la riqueza de los países en la actualidad) se conocen con casi tres meses de rezago al finalizar el período de referencia. El INDEC reconoce esta dificultad y por eso publica el Estimador Mensual de Actividad Económica, el cual es un indicador provisorio anticipado de

la evolución del PBI real (a precios constantes de 2004, año base), con la particularidad de que tiene una frecuencia mensual.

Sin embargo, este indicador no logra cumplir con creces su objetivo: se publica con un rezago de entre 50 y 60 días concluido el mes de referencia. Esto hace que en una economía tan dinámica, donde el horizonte temporal para las decisiones se acortó a semanas o meses, el indicador pase desapercibido para la opinión pública por su lejanía con el período a analizar. Además, tanto tiempo de demora hace que no logre cumplir el rol de anticipador del PBI: los agentes económicos terminan considerando más relevante este último indicador para la discusión económica, pese a que el EMAE se conozca antes y converja en última instancia con el PBI, como hemos demostrado.

Por esta razón, en este trabajo se construyeron modelos econométricos y de *machine learning* para anticipar la variación interanual del EMAE y del EMAE no Agropecuario. La decisión de utilizar estas métricas se fundamenta en varias conclusiones extraídas de la investigación. Primero, tomar la variación interanual de la serie original se explica porque la serie desestacionalizada del EMAE sufre reiteradas modificaciones y revisiones para atrás, lo que dificulta su pronóstico ya que se corrigen los datos de entrenamiento de los modelos en alta magnitud. Segundo, la mayor volatilidad de la producción Agropecuaria (por su dependencia a factores climáticos) dificulta el anticipo del EMAE y produce un sesgo significativo en años de sequía o de recuperación de ella, como fue 2023 o se avizora que será 2024. Por esta razón, se modelizó como variable objetivo también el EMAE excluyendo el sector Agropecuario, lo que permite conocer con mayor detalle la dinámica del ciclo real de la actividad económica. Luego, con facilidad, puede añadirse la variación interanual de dicho sector explicado por factores exógenos a los modelos utilizados en este trabajo.

Como predictores se utilizaron variables de recaudación, comercio exterior, monetarias, financieras, cambiarias, de expectativas, de energía, demanda, producción sectorial y algunas variables dummies construidas para captar algunos momentos temporales específicos (como por ejemplo, la pandemia). El criterio de elección se centró en disponer de datos públicos mensuales entre enero 2011 y noviembre de 2023, difundidos solo 20 días después de finalizar su período de referencia, para poder ser el input del modelo predictivo del EMAE y conocer dicha variación interanual 30 días antes que lo publicado por el INDEC. Esto permite que cuando, por ejemplo, el INDEC publica el EMAE de marzo, el modelo ya pueda pronosticar el de abril ese mismo día. Con esta metodología y estas restricciones, se encontraron 44 variables predictoras.

Los modelos predictivos utilizados fueron seis y se basaron en modelos econométricos, técnicas algorítmicas y de aprendizaje automático. En detalle, se usaron el Modelo Autorregresivo de Rezagos Distribuidos (ARDL), tres modelos de *machine learning* (Lasso, Ridge y Elastic Net) y dos modelos de selección de parámetros mediante algoritmos, el modelo General-to-specific (GETS) y el modelo Global Search Regression (GSR). Estos seis modelos fueron puestos a competir utilizando datos de las variaciones interanuales de las 44 variables predictoras, del EMAE y del EMAE no Agropecuario entre enero 2012 y noviembre de 2023 (última información disponible al momento de escribir este trabajo).

Dado que el objetivo de esta investigación fue pronosticar y no hacer inferencia, el criterio de selección de modelos se basó en las estadísticas convencionales de bondad de pronóstico. Las utilizadas fueron tres, ya que cada una contempla un aspecto diferente: la Raíz del Error Cuadrático Medio (RMSE), el Error Absoluto Medio (MAE) y el Error Absoluto Porcentual Medio (MAPE). En términos generales, es posible decir que el modelo Lasso fue el que mejor pronóstico arrojó por 2 de las 3 métricas de bondad de pronóstico, tanto para predecir el EMAE como para predecir el EMAE no Agropecuario. El modelo GETS también tuvo un desempeño destacado con ambas variables objetivo, mientras que el Ridge ajustó mejor para el EMAE no Agropecuario y el ARDL para el EMAE agregado.

Los resultados de estos modelos permiten conocer 30 días antes de lo publicado por el INDEC un buen proxy de la evolución de la actividad económica interanual. Esto permitiría poner nuevamente en la agenda cotidiana la dinámica de la producción, la cual por su lejanía parece haber pasado a un segundo plano frente a otras variables que su disponibilidad de datos es más frecuente (como la inflación, el tipo de cambio, la producción manufacturera, entre otras).

A futuro, podría ser de interés replicar dichos modelos con otras variables económicas para el pronóstico del EMAE Agropecuario y también para otros indicadores relevantes que se conocen con alto retardo en Argentina, tal como las estadísticas de empleo o la pobreza, los cuáles tampoco aparecen en la agenda económica cotidiana salvo al momento de su publicación meses después.

7) Bibliografía

Aastveit, K. A., Gerdrup, K. R., Jore, A. S., & Thorsrud, L. A. (2014). Nowcasting GDP in real time: A density combination approach. *Journal of Business & Economic Statistics*, 32(1), 48-68.

Álvarez, L. J., Cabrero, A., & Urtasun, A. (2014). Un procedimiento para la predicción a corto plazo del PIB. *Boletín Económico*, (OCT), 1-8.

Aruoba, S. B., Diebold, F. X., & Scotti, C. (2009). Real-time measurement of business conditions. *Journal of Business & Economic Statistics*, 27(4), 417-427.

Azcona, A. M., Guevara, V. H. V., & Sanabria, F. (2021). Modelado y predicción del PIB trimestral mediante modelos VAR multinomiales. XIII Semana Internacional de la Estadística y la Probabilidad, FCFM-BUAP, 2020.

Baffigi, A., Golinelli, R., & Parigi, G. (2004). Bridge models to forecast the euro area GDP. *International Journal of forecasting*, 20(3), 447-460.

Bañbura, M., Giannone, D., Modugno, M., & Reichlin, L. (2013). Now-casting and the real-time data flow. In *Handbook of economic forecasting* (Vol. 2, pp. 195-237). Elsevier.

Barnett, W. A., Chauvet, M., & Leiva-Leon, D. (2014). Real-Time Nowcasting of Nominal GDP Under Structural Breaks. Available at SSRN 2691693.

Blanco, E., D'Amato, L., Dogliolo, F., & Garegnani, M. L. (2017). Nowcasting GDP in Argentina: Comparing the predictive ability of different models (No. 74). *Economic Research Working Papers*.

Casares, F. (2017). Nowcasting: modelos de factores dinámicos y ecuaciones puente para la proyección del PIB del Ecuador. *COMPENDIUM: Cuadernos de Economía y Administración*, 4(8), 25-46.

Chakraborty, C., & Joseph, A. (2017). Machine learning at central banks. *Bank of England working papers* 674. Bank of England.

Choi, H., & Varian, H. (2012). Predicting the present with Google Trends. *Economic record*, 88, 2-9.

Clarke, D. (2014). General-to-specific modeling in Stata. *The Stata Journal*, 14(4), 895-908.

Cohan, P. P. (2019). El índice Merval como indicador líder de la actividad económica en Argentina. Período 1994-2018. Master's thesis, Facultad de Ciencias Económicas y Estadística, Universidad Nacional de Rosario.

Cohan, P. P., & Zanini, L. El sector manufacturero en el estudio de los ciclos económicos subnacionales. Evaluación de mejoras para al índice de actividad económica coincidente de la provincia de Santa Fe.

Dal Bianco, M., Martinez-Martín, J., & Camacho, M. (2013). Short-Run Forecasting of Argentine GDP Growth (No. 1314).

D'Amato, L., Garegnani, L., & Blanco, E. (2015). Nowcasting de PIB: evaluando las condiciones cíclicas de la economía argentina (No. 2015/69). Working Paper.

Drechsel, K., & Maurin, L. (2011). Flow of conjunctural information and forecast of euro area economic activity. *Journal of Forecasting*, 30(3), 336-354.

Espinosa, M. (2022). Nowcasting del PIB de Uruguay: evaluación del desempeño de los modelos en las crisis de 2002 y 2020. Tesis de maestría, FCEA, Udelar.

Frank, L. (2021). Revisión de modelos para ajuste estacional y proyección de sectores de actividad del EMAE. Año 2021. MPRA Paper No. 112285

Frank, L. (2022). Predicción anticipada de agregados macroeconómicos con indicadores no contemporáneos: el caso de EMAE. MPRA Paper No. 114324

Friedman, J., Hastie, T., & Tibshirani, R. (2010). Regularization paths for generalized linear models via coordinate descent. *Journal of statistical software*, 33(1), 1.

Galbraith, J. W., & Tkacz, G. (2015). Nowcasting GDP with electronic payments data (No. 10). ECB Statistics Paper.

Ghysels, E., Sinko, A., & Valkanov, R. (2007). MIDAS regressions: Further results and new directions. *Econometric reviews*, 26(1), 53-90.

Giannone, D., Reichlin, L., & Small, D. (2008). Nowcasting: The real-time informational content of macroeconomic data. *Journal of monetary economics*, 55(4), 665-676.

Gluzmann, P., & Panigo, D. (2015). Global search regression: A new automatic model-selection technique for cross-section, time-series, and panel-data regressions. *The Stata Journal*, 15(2), 325-349.

Higgins, P. C. (2014). GDPNow: A model for GDP 'nowcasting'. Federal Reserve Bank of Atlanta, working paper, No. 2014-7, July.

INDEC (2016, a). Metodología del Estimador Mensual de Actividad Económica (EMAE).

INDEC (2016, b). Cuentas Nacionales: Metodología y estimación.

Kitchen, J., & Monaco, R. (2003). Real-time forecasting in practice: The US Treasury staff's real-time GDP forecast system. *Business Economics*, pp. 10–19.

Klein, L. R., & Coutiño, A. (2004). Enfoque metodológico para un modelo de pronósticos de alta frecuencia para la economía mexicana. *Investigación económica*, 63(250), 47-58.

Knotek, E. S., & Zaman, S. (2017). Nowcasting US headline and core inflation. *Journal of Money, Credit and Banking*, 49(5), 931-968.

Lanteri, L. N. (2014). Indicadores del mercado accionario y actividad económica. *Alguna evidencia para la Argentina. Ensayos Económicos*, (70).

Llada, M. (2022). Forecasting del PIB argentino. *Revista de Economía Política de Buenos Aires*, (25), 35-72.

Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PloS one*, 13(3), e0194889.

Masoller, A. (2002). Un indicador sintético de actividad económica. *Revista de Economía*, 9(2), 49-84.

McCandless, G., Gabrielli, M. F. & Murphy, T. (2001). Modelos econométricos de predicción macroeconómica en la Argentina. Banco Central de la República Argentina, Documento de Trabajo N° 19.

Modugno, M. (2013). Now-casting inflation using high frequency data. *International Journal of Forecasting*, 29(4), 664-675.

Nkoro, E., & Uko, A. K. (2016). Autoregressive Distributed Lag (ARDL) cointegration technique: application and interpretation. *Journal of Statistical and Econometric methods*, 5(4), 63-91.

Perez, J., & Brens, P. (2018). Modelo de Factores Dinámicos para Pronósticos de la Actividad Económica en Tiempo Real. Santo Domingo, República Dominicana. Ministerio de Hacienda. Serie de documentos de investigación.

Priarone, R. (2019). ¿Es el índice Merval un buen indicador adelantado del ciclo económico argentino?

Richardson, A., van Florenstein Mulder, T., & Vehbi, T. (2021). Nowcasting GDP using machine-learning algorithms: A real-time assessment. *International Journal of Forecasting*, 37(2), 941-948.

Rosales, R., Perdomo, J., Morales, C., & Urrego, J. (2012). *Intermediate economics: Theory and applications*. Universidad de los Andes.

Stock, J. H., & Watson, M. W. (1991). A probability model of the coincident economic indicators. In: G. Moore and K. Lahiri, eds., *The Leading Economic Indicators: New Approaches and Forecasting Records* (Cambridge University Press, Cambridge) 63-90.

Stock, J. H., & Watson, M. W. (2002, a). Macroeconomic forecasting using diffusion indexes. *Journal of Business & Economic Statistics*, 20(2), 147-162.

Stock, J. H., & Watson, M. W. (2002, b). Forecasting using principal components from a large number of predictors. *Journal of the American statistical association*, 97(460), 1167-1179.



equilibra

CENTRO DE ANÁLISIS ECONÓMICO