

PulsoPBA

El termómetro de actividad de la
Provincia de Buenos Aires



Nueva Metodología PulsoPBA

Introducción

PulsoPBA es una herramienta creada para mostrar la evolución de la actividad económica de la Provincia de Buenos Aires (PBA), desarrollada por la Gerencia de Estudios Económicos del Banco Provincia en colaboración con el Instituto de Ciencias de la Computación de la Universidad de Buenos Aires (ICC-UBA).

El Banco posee bases de datos de alta frecuencia provenientes de sus operaciones bancarias. Estas incluyen información detallada sobre transacciones, préstamos, operaciones de comercio exterior y consumos a través de diferentes medios de pago. Los datos están desagregados por fecha, centro zonal, actor institucional, actividad económica (CLANAE a dos dígitos), tipo de moneda y tipo de movimiento. A partir de esta información, se construyó un conjunto de aproximadamente 1.200 variables agregadas con frecuencia diaria, que luego a su vez se agregan en bloques semanales por cada mes.

Utilizando estas bases y el Estimador Mensual de Actividad de la Provincia de Buenos Aires (EMA-PBA), elaborado por el Ministerio de Economía de la Provincia de Buenos Aires, se entrenan algoritmos de Inteligencia Artificial (IA) diseñados para modelar series de tiempo. Una vez entrenados, los modelos permiten estimar el nivel actual de actividad económica (nowcasting), proyectar su evolución en las semanas siguientes (forecasting) y realizar un reentrenamiento mensual. Tanto las estimaciones como el reentrenamiento se generan de forma automatizada en un servidor de la Gerencia de Estudios Económicos.

Hasta el mes de enero de 2026, los datos que fueron publicados corresponden a una versión anterior. A partir de febrero de 2026, la serie informada surge de una evolución metodológica que será expuesta en el presente documento.

Si bien este marco metodológico fue objeto de una evolución técnica significativa, no se alteraron sus fundamentos conceptuales, siendo los principales cambios el mayor nivel de desagregación, una ampliación del conjunto de modelos evaluados y mejoras en la validación empírica del pipeline de predicción.

Una de las principales diferencias metodológicas introducidas en esta nueva versión es el pasaje desde predicciones del agregado de la actividad económica provincial hacia un enfoque sectorial, en el cual, además de la actividad económica del conjunto, se estima la actividad económica por ramas de actividad. Luego se asegura la consistencia entre los resultados sectoriales y el agregado total. Este cambio implicó el desarrollo y la evaluación de estrategias

específicas de reconciliación jerárquica, orientadas a garantizar la coherencia interna del sistema de predicción, aspecto que no formaba parte del diseño metodológico original.

Asimismo, la evolución técnica del proyecto hizo más exhaustivo el proceso de competencia y selección de modelos, centrándose en arquitecturas de deep learning especialmente diseñadas para contextos de alta dimensionalidad, como TiDE y TSMixer. La nueva versión introduce un esquema operativo en el que múltiples arquitecturas compiten entre sí bajo distintos conjuntos de datos y parámetros de entrenamiento, con el objetivo de seleccionar aquellas que alcanzan un mejor desempeño en la predicción.

En relación con la evaluación de resultados, si bien se mantienen métricas estándar de error como MAPE, MAE y RMSE, a la métrica Weighted Interval Score (WIS) se le incorporó la evaluación multiobjetivo en una frontera de Pareto. Finalmente, los mejores modelos seleccionados son ensamblados y ponderados por el WIS. Este enfoque permite ponderar simultáneamente la precisión puntual y la calidad de los intervalos de predicción, incorporando además criterios complementarios vinculados a la capacidad de anticipar correctamente la dirección de los cambios en la actividad económica y a la cobertura efectiva de los intervalos.

Finalmente, la nueva versión es fruto de un proceso iterativo de ajuste técnico-metodológico, basado en la evidencia empírica obtenida mes a mes desde marzo de 2025. Este proceso permitió identificar configuraciones más robustas frente a la presencia de valores atípicos, reducir la propagación de errores entre niveles de agregación y definir una versión consolidada del pipeline de predicción, que sienta las bases para la operación futura del sistema.

Definiciones y conceptos básicos para comprender la metodología

1. EMA-PBA: Estimador mensual de actividad económica de la Provincia de Buenos Aires, serie sin estacionalidad. Indicador oficial mensual que adelanta el PIB trimestral. Se publica periódicamente luego de la publicación del Estimador Mensual de Actividad Económica (EMAE) confeccionado por el INDEC.
2. Bloque/semana: período o unidad de observación de siete u ocho días, definida según la duración del mes y que lo segmenta en cuatro bloques. De este modo se garantiza la consistencia en las comparaciones.
3. Centro Zonal: distribución geográfica interna del Banco.
4. ESA-PulsoPBA: nuevo indicador sintético que mide la evolución semanal de la actividad económica en la Provincia de Buenos Aires. La suma de las variaciones semanales de un mes es igual a la variación mensual de la serie sin estacionalidad del EMA-PBA.
5. Entrenar un modelo: en este caso, el objetivo del modelo será estimar cómo evoluciona la economía semana a semana. En el contexto de PulsoPBA, este entrenamiento algorítmico implica “mostrarle” al modelo ejemplos del pasado (los datos históricos) para que “aprenda” las relaciones entre variables bancarias y la actividad económica de la Provincia (medida con el EMA-PBA sin estacionalidad).
6. Generalización: es la capacidad que muestra un modelo de aplicar lo aprendido (en base al pasado) a estimar situaciones nuevas. Un modelo útil no se limita a repetir lo conocido, sino que puede reconocer patrones y proyectarlos en datos distintos a los utilizados para su entrenamiento. Una baja capacidad de generalización se puede deber a un sobreajuste (overfitting) o la falta de un ajuste adecuado (underfitting).
7. Predicción: una vez entrenado, un modelo puede recibir datos nuevos (por ejemplo, las transacciones de la última semana) y a partir de lo aprendido en el pasado, dar una

PulsoPBA

El termómetro de actividad de la
Provincia de Buenos Aires



estimación de lo que ocurre hoy o de lo que probablemente ocurrirá mañana. En el contexto de PulsoPBA:

- a. Nowcasting: estimación en tiempo real de la actividad semanal del pasado reciente, basada en los datos bancarios más recientes.
 - b. Forecasting: proyección del futuro inmediato de la actividad económica para el bloque-semana siguiente.
8. Covariables: variables dependientes.
9. Evaluación del modelo: para asegurarse de que el algoritmo funcione bien, se compara lo que ofrece como predicción contra los valores reales observados. Si el error es bajo, el modelo se considera confiable. Las métricas de error seleccionadas para evaluar la precisión de los modelos son:
- MAPE (mide el error porcentual promedio).
 - MAE (mide la diferencia absoluta promedio entre lo estimado y lo real).
 - RMSE (mide el error cuadrático promedio, dando más peso a errores grandes).
 - WIS (es una métrica integral que permite evaluar simultáneamente la precisión puntual y la calidad de los intervalos de predicción)

Fuentes de información

Se trabaja con cuatro grandes bases de datos: Movimientos, Préstamos, Comex y Consumo, cada una con características propias (resumidas en la Tabla 1):

1. Movimientos: disponible desde 2013, con frecuencia diaria y clasificación por actividad económica a dos dígitos del CLANAE, centro zonal, sector institucional. Aporta un total de 772 variables.
2. Préstamos: también disponible desde 2013, con frecuencia diaria y clasificación por actividad económica a dos dígitos del CLANAE, centro zonal, sector institucional. Aporta 94 variables.
3. Comex: disponible desde 2019, con frecuencia diaria y clasificación por actividad económica a dos dígitos del CLANAE, centro zonal, sector institucional y aporta 327 variables.

- Consumo: disponible desde 2015, con frecuencia diaria y 21 rubros específicos (indumentaria, alimentos, etc.). No registra centro zonal, pero sí incluye variables relacionadas con clientes y compras. Tiene 57 variables y solo admite valores positivos (no negativos).

Tabla 1: características de las bases de datos insumo del algoritmo

Característica	Movimientos	Préstamos	Comex	Consumo
Registra actividad fines de semana/feriados	✘	✘	✘	✓
Fecha imputada al primer día hábil	✓	✓	✓	✘
Rubros clasificados	Actividad a 2 dígitos	Actividad a 2 dígitos	Actividad a 2 dígitos	21 rubros (indumentaria, alimentos, etc.)
Registra centro zonal	✓	✓	✓	✘
Fecha de inicio de datos	2013	2013	2019	2015
Nivel de desagregación temporal	Diario	Diario	Diario	Diario
Variables relacionadas a clientes y compras (Q_CUENTES, Q_TRX)	✘	✘	✘	✓
Cantidad de variables	772	94	327	57
Valores nominales	✓	✓	✓	✓
Valores negativos (débitos)	✓	✓	✓	✘
Fuente de datos	Control de Gestión	Control de Gestión	Control de Gestión	Inteligencia Comercial

Fuente: elaboración propia

Todas la variables están expresadas en valores nominales. Los valores positivos son créditos y los negativos débitos. Las operaciones realizadas en monedas diferentes al Peso argentino son convertidas al tipo de cambio oficial del día de la transacción.

Semanalización de la información bancaria y del EMA-PBA

Dado que PulsoPBA se propone informar una dinámica semanal de la actividad económica, es necesario que tanto las variables bancarias (variables explicativas) como la actividad económica (variable explicada) estén expresados en la misma frecuencia semanal.

La agregación de las variables diarias en semanas presenta un desafío: los meses no empiezan el mismo día de la semana ni tienen la misma cantidad de días. Para solventar este problema metodológico, se conforma una semanalización de los meses que consiste en 4 unidades “semana-bloque” por mes, de duración variable según la cantidad de días del mes. Cada variable bancaria diaria es agregada en un bloque semanal según el esquema descrito en la Tabla 2.

Por otra parte, debe aumentarse la granularidad del dato de actividad económica, desde una granularidad mensual (EMA-PBA) hacia una granularidad semanal (ESA-PBA). Para ello, se adoptó un enfoque supervisado que aprovecha la riqueza de los datos bancarios. La metodología implementa el método de desagregación de Chow-Lin (1971), que garantiza que la suma de las estimaciones semanales coincida con el dato mensual publicado.

PulsoPBA

El termómetro de actividad de la
Provincia de Buenos Aires



Tabla 2: Método de semanalización dependiendo del mes

Días de un mes	Bloque 1	Bloque 2	Bloque 3	Bloque 4
28	7	7	7	7
29	8	7	7	7
30	8	8	7	7
31	8	8	8	7

Fuente: elaboración propia

Modelos utilizados

Sobre la base de los datos semanalizados se entrenan 17 modelos de series de tiempo -uno para cada sector y uno para el total de la economía-, orientados a la estimación y predicción de la actividad económica. El enfoque adoptado combina distintos tipos de arquitecturas, priorizando aquellos que demostraron mejor desempeño empírico en contextos de alta dimensionalidad.

Concretamente, en esta nueva versión, se definió un esquema en el que, en cada sector, compiten arquitecturas de deep learning, principalmente TiDE y TSMixer, descartándose otros enfoques que no alcanzaron niveles adecuados de desempeño y estabilidad. Los modelos se entrenan utilizando tanto un dataset completo (Full), que incluye la totalidad de las variables disponibles (~1200), como también un dataset reducido (Reduced), obtenido mediante criterios estadísticos y supervisados de filtrado (~500 variables).

Etapas del entrenamiento

El entrenamiento de PulsoPBA es un ciclo que se repite todos los meses y cuenta de las siguientes etapas:

1. Partición de los datos

Se realiza la partición de los datos en tres subconjuntos: entrenamiento, validación y testeo. Esta división garantiza que la evaluación del modelo se realice sobre datos no utilizados previamente durante el entrenamiento, evitando sesgos. En particular, el conjunto de validación proporciona una evaluación intermedia del modelo mientras se refinan los hiperparámetros durante la validación cruzada. Por su parte, el conjunto de testeo permanece completamente aislado hasta el final, para obtener una medida objetiva del rendimiento del modelo ya ajustado.

2. Optimización de hiper-parámetros de los modelos

Los hiper-parámetros son variables de configuración que definen la estructura y el proceso de aprendizaje de un modelo. Ejemplos habituales son la tasa de aprendizaje, el número de neuronas en una red o la profundidad de los árboles en un XGBoost. A diferencia de los parámetros internos, que se ajustan automáticamente a partir de los datos, los hiper-parámetros se fijan de antemano y determinan cómo aprende el modelo entre un conjunto de opciones posibles. Una selección adecuada de hiper-parámetros puede mejorar la precisión y generalización; mientras que valores inadecuados pueden provocar subajuste (underfitting) o sobreajuste (overfitting).

La validación cruzada es un procedimiento para estimar el rendimiento real de un modelo. Consiste en entrenar y evaluar repetidamente el algoritmo sobre distintos subconjuntos de los datos, garantizando un uso eficiente y robusto de la información disponible. A partir de la evidencia empírica acumulada durante la elaboración de la nueva versión, se estableció una configuración estándar de 100 trials para la búsqueda de hiperparámetros, por ofrecer un balance adecuado entre desempeño y estabilidad.

En problemas de series temporales, como PulsoPBA, se emplea la modalidad de ventana móvil (rolling window). En cada iteración, el modelo se entrena con un bloque de datos históricos consecutivos y se valida en el período inmediatamente posterior. Luego la ventana de entrenamiento se desplaza hacia adelante y el proceso se repite. Este esquema preserva la secuencia temporal y permite evaluar la capacidad predictiva del modelo en contextos cambiantes, simulando el escenario de actualización continua.

El criterio principal para seleccionar los mejores hiper-parámetros fue minimizar el MAPE (Mean Absolute Percentage Error), una métrica expresada en porcentaje que mide el error relativo y evita sesgos de escala (ecuación 1), algo especialmente importante cuando se comparan períodos con distinta magnitud en la actividad económica semanal.

$$MAPE_{median} = median \left\{ \frac{1}{S} \sum_{s=1}^S \left| \frac{PulsoPBA_{w,s} - ESA_{w,s}}{ESA_{w,s}} \right|, w = 1, \dots, W \right\} (1)$$

Siendo,

S: el número de semanas de la predicción

W: el número de ventanas móviles

3. Los mejores K modelos de CV evaluados en test

Tras el entrenamiento y la validación cruzada se generan múltiples modelos candidatos que demuestran ofrecer una buena calidad. En PulsoPBA, se seleccionan los K=10 modelos con menor MAPE mediano, lo que permite comparar varios candidatos sólidos y reducir riesgos de

PulsoPBA

El termómetro de actividad de la
Provincia de Buenos Aires



azar. Cada modelo elegido se reentrena con todo el conjunto de entrenamiento y validación, aprovechando la máxima información disponible.

Finalmente, los modelos se evalúan en el conjunto de prueba, nunca usado en etapas previas. Allí se calculan las métricas de error, obteniendo una estimación imparcial de la capacidad predictiva real. Al igual que en la fase anterior, el error se calcula comparando las estimaciones semanales generadas por el modelo con la serie del ESA-PBA (ecuación 2).

$$MAPE_{test} = \frac{1}{S} \sum_{s=1}^S \left| \frac{\widehat{PulsoPBA}_s - ESA_s}{ESA_s} \right| \quad (2)$$

4. Competencia entre modelos y selección de los modelos para la predicción

La elección del mejor modelo se realiza mediante un proceso de filtros sucesivos que aseguran predicciones confiables y útiles. Esto son:

- Capacidad de generalización: se descartan los modelos que muestran sobreajuste, es decir, aquellos que funcionan bien en entrenamiento, pero no así en datos nuevos (conjunto de prueba).
- Cobertura: se eliminan los modelos cuyos intervalos de confianza de predicción no logran abarcar suficientemente los datos reales.
- Dirección de los cambios: se priorizan los modelos que aciertan en predecir si la economía crecerá o caerá semana a semana.

Finalmente, los modelos que superan estos filtros se ordenan según una métrica que pondera precisión, calibración y cobertura (WIS, Weighted Interval Score, ecuación 3). El mejor modelo es el que se selecciona para ser entrenado y utilizado como producto final, es decir, el que se utiliza para las predicciones de PulsoPBA.

$$WIS = \frac{1}{K+1} \left(|y - \hat{y}| + \sum_{k=1}^K \left[\alpha_k (u_k - l_k) + \frac{2}{\alpha_k} (l_k - y) I_{inf} + \frac{2}{\alpha_k} (u_k - y) I_{sup} \right] \right) \quad (3)$$

Siendo,

- y : el valor observado,
- \hat{y} : la mediana de los valores (muestras) predichos.
- K : Intervalos de confianza a ponderar,
- α_k : k-ésimo intervalo de confianza,
- l_k y u_k : los límites inferior y superior de α_k ,
- I_{inf} : $I(y < l_k)$ es la función indicador sobre el cuantil inferior
- I_{sup} : $I(y > u_k)$ es la función indicador sobre el cuantil superior

Al dividir por $K+1$, la métrica queda promediada sobre distintos intervalos y es comparable entre modelos que reporten distinto número de intervalos.

5. Reentrenamiento mensual

Cada mes, cuando se publica un nuevo dato del EMA-PBA, el modelo se actualiza con esa nueva información. Así, el sistema incorpora de manera continua las observaciones más recientes y actualiza su capacidad de predicción ajustada a la coyuntura económica.

Predicciones sectoriales y reconciliación con el agregado

Una ampliación metodológica central de la nueva versión es la estimación de la actividad económica por ramas de actividad. Este enfoque sectorial requiere garantizar la coherencia entre las predicciones sectoriales y el agregado total.

Para ello se desarrolló y evaluó un conjunto de estrategias de reconciliación jerárquica, incluyendo enfoques top-down y bottom-up, así como variantes basadas en métricas de error (MinT-like y MeanT-like). El análisis empírico mostró que, si bien distintas variantes presentan desempeños similares en promedio, la reconciliación meanT basada en WIS ofrece un balance superior entre precisión, estabilidad y consistencia económica. Como resultado de este proceso, la configuración definitiva del pipeline adoptada en la nueva versión establece la reconciliación top-down guiada por la calidad de los modelos como criterio operativo principal.

Las predicciones

Los modelos entrenados de cada sector se ejecutan semanalmente para realizar predicciones correspondientes. El modelo de nowcasting pronostica la evolución de la actividad libre de los efectos estacionales durante la cantidad de semanas que distan entre el ESA-PulsoPBA y los datos bancarios. El modelo de forecasting pronostica la actividad económica sin estacionalidad de la semana siguiente a la última pronosticada por el nowcasting.

El reentrenamiento de los modelos se realiza con frecuencia mensual, incorporando cada nuevo dato publicado del EMA-PBA. Este esquema garantiza la actualización continua del sistema y su adaptación a los cambios en la coyuntura económica.

PulsoPBA

El termómetro de actividad de la
Provincia de Buenos Aires



Para más información: InvestigacionesEconomicas@bpba.com.ar

Referencias bibliográficas

Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. arXiv preprint arXiv:1907.10902. <https://arxiv.org/abs/1907.10902>

Chen, Tianqi, and Carlos Guestrin. "XGBoost: A Scalable Tree Boosting System." In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785–94. New York: ACM, 2016. <https://doi.org/10.1145/2939672.2939785>.

Chen, S.-A., Li, C.-L., Yoder, N., Arik, S. O., & Pfister, T. (2023). TSMixer: An all-MLP architecture for time series forecasting. arXiv preprint arXiv:2303.06053. <https://arxiv.org/abs/2303.06053>

Chow & Lin (1971) "Best Linear Unbiased Estimation of Missing Observations", Journal of the American Statistical Association, Vol. 71, No. 355.

Das, A., Kong, W., Leach, A., Mathur, S., Sen, R., & Yu, R. (2023). TiDE: Time-series Dense Encoder. arXiv preprint arXiv:2304.08424. <https://arxiv.org/abs/2304.08424>

Gal, Y., & Ghahramani, Z. (2015). Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning (Version 6). arXiv. <https://doi.org/10.48550/ARXIV.1506.02142>