



Contenido

1. *Nearshoring*: características, el caso de México y las oportunidades para Latinoamérica..... p. 1

2. Machine Learning y banca central ... p.5

Nearshoring: características, el caso de México y las oportunidades para Latinoamérica

Edwin Felipe Morales Cal¹

1. Introducción

Algunos años antes de que China surgiera económicamente como un actor importante del comercio internacional, este estaba dominado por los Estados Unidos de América, algunos países europeos y Japón. Cuando el *offshoring*² empezó a tener auge en el comercio internacional, China fue uno de los países más beneficiados, debido a su gran población, mano de obra relativamente barata y un entorno regulatorio favorable para la inversión extranjera directa (IED). Un evento importante en la dinámica del comercio internacional fue el ingreso de la República Popular China a la Organización Mundial del Comercio (WTO, por sus siglas en inglés) en 2001.

En casi 40 años, China pasó de aportar un 3% al PIB mundial en 1980 a un 18% en 2022. Eso fue logrado, en parte, por las acciones del exlíder chino Deng Xiaoping, quien adoptó una política comercial estratégica similar a la que décadas atrás había adoptado Japón. Con estas acciones industrializó a China y la convirtió en el mayor exportador mundial.

Sin embargo, el incremento de las tensiones geopolíticas entre EE. UU. y China en los últimos años, que tuvieron un aumento significativo durante el período de mandato del expresidente Donald Trump, y las disrupciones de las cadenas de suministro entre otras causas, tuvieron un impacto negativo sobre el *offshoring*. Para evitar estas vulnerabilidades y también reducir costos de transporte, las empresas han seguido estrategias en las que trasladan toda o parte de sus operaciones a lugares más cercanos al país de consumo. A esto se le conoce como *nearshoring*.

En la década de los 90, las empresas empezaron a experimentar con el *nearshoring* trasladando parte de sus operaciones a Europa del Este, luego a Asia y ahora a

México. En este contexto cabe preguntarse: ¿Qué países se beneficiarán más del *nearshoring*? ¿Cuáles son sus principales determinantes? ¿Qué aspectos han acelerado el *nearshoring*? A continuación se abordan estos temas, así como una breve reseña histórica.

2. Reseña histórica

Nearshoring es el fenómeno de trasladar procesos de producción, investigación y negocios a países que son baratos y cercanos, en vez de los muy baratos y lejanos (*The Economist*, 2005). Los primeros en recibir inversión vía *nearshoring* fueron países de Europa Oriental en la década de los 90, como República Checa, Polonia, Hungría, Ucrania, entre otros, cuando estos empezaron a parecer atractivos a inversionistas occidentales, que vieron el beneficio de externalizar parte de sus operaciones gracias a: i) una mano de obra más barata; ii) una proximidad geográfica a dichos mercados occidentales. En ese contexto, la importación de servicios de Tecnologías de Información hacia el EU-15,³ provenientes de la región Central y del Este de Europa, había crecido 13% por año en el período entre 1992 y 2004. Los lazos cercanos de cultura, geografía e idioma hicieron atractivas a estas regiones. (Meyer, 2006)

Algunos ejemplos de empresas pioneras en el *nearshoring* en Europa son los siguientes: Skype,⁴ fundada por un danés y un sueco. En sus inicios, antes de pertenecer a Microsoft, se instalaron en Tallin, capital de Estonia, por su cercanía geográfica y menores costos laborales. De acuerdo con *The Economist*, empresas como DHL, Siemens y Lufthansa trasladaron sus operaciones de procesamiento de datos masivos a República Checa, donde características como la calidad del trabajo, una zona horaria similar, un entorno político y regulatorio estable y la afinidad cultural, la hicieron atractiva en aquellos años.

¹ Analista de la Sección de Investigación Económica Aplicada del Departamento de Investigaciones Económicas del Banco de Guatemala.
² El traslado de procesos y servicios de fabricación al extranjero, para aprovechar los costos más bajos.

³ EU-15 se refiere a los antiguos miembros de la Unión Europea. Ésta comprende: Bélgica, Dinamarca, Alemania, Grecia, España, Francia, Irlanda, Italia, Luxemburgo, Países Bajos, Austria, Portugal, Finlandia, Suecia, Reino Unido.
⁴ Lanzada en 2003 con nombre inicial "Sky Peer-to-Peer".

El Banco Suizo UBS externalizó muchas de sus actividades comerciales y administrativas a países de Europa del Este como Polonia y Serbia, con el objetivo de mejorar su estrategia operativa, reducir costos y acceder a talento calificado. Por su parte, en América, la reconfiguración del comercio internacional ha tenido hasta ahora ciertas interacciones que se han ido acentuando y que tienen un factor común: México. Entre las compañías estadounidenses que se han establecido en este último, como parte de su estrategia de *nearshoring*, encontramos a Ford Motors, General Motors, Intel, Honeywell International, P&G (Procter & Gamble) y Tesla.

China es otro jugador más que ha tomado la estrategia de moverse cerca de su mercado objetivo. Empresas chinas han empezado a migrar sus operaciones de manufactura de ese país asiático hacia México, entre las que se encuentran: Lizhong Group, Citic Dicastal, Alibaba, CF Moto, BOE Technology Group (FTI Consulting, 2024). Otras empresas que se suman a esta estrategia son Lingong Machinery Group, Trina Solar y Solarever Group.

Por su parte, Canadá pareciera estar rezagada en la relocalización de operaciones (Tetawaki, 2024). Esto se explica porque, entre 2000 y 2012, el costo laboral promedio por unidad de producción en Canadá aumentó un 75% en comparación con EE. UU., lo cual puede estar impidiendo la reubicación en ese país. Esto ha ocasionado que, de acuerdo con *The Globe and Mail*, la base manufacturera en Canadá podría empezar a reducirse. Sin embargo, esta nación sigue muy de cerca los pasos de EE. UU. y empieza a trasladar operaciones de algunas de sus empresas a México, tal el caso de Bombardier Aerospace.

3. Aspectos que han acelerado el *nearshoring*

El fenómeno del *nearshoring* ha evolucionado recientemente y en los últimos años las crisis geopolíticas han inducido a las empresas a acercar sus operaciones a sus clientes (*Financial Times*, 2023). Adicionalmente, el temor de los gobiernos y empresas por lo ocurrido en los mercados internacionales, por las guerras (como la ruso-ucraniana), los conflictos de Occidente con China, han resultado en otros factores importantes que han acelerado el traslado de fábricas y procesos productivos (*The Economist*, 2023). Un ejemplo de esto es Europa, donde actualmente las empresas más grandes de todo el mundo están adquiriendo fábricas en 9 países de esta región, entre los cuales se incluyen el Reino Unido, Francia y Alemania, con el objetivo de producir lo que antes solían comprar a China (dicha adquisición representó un aumento del 29% en 2022 respecto al año anterior, según Cushman y Wakefield). Otro ejemplo de esto es el aumento del interés en México por parte de las empresas chinas, el cual se acentuó desde 2018. Esto fue ocasionado por la guerra comercial entre EE.UU. y China, en la que se aumentaron los aranceles a las importaciones del gigante asiático, medida tomada por el entonces presidente Donald Trump y mantenidas por el actual presidente, Joe Biden.

Respecto a las disrupciones de las cadenas de suministro se destaca que durante la pandemia del COVID-19, estas se vieron acentuadas cuando, debido al cierre de las

ciudades y los puertos, el flujo de bienes se detuvo por varios meses. De acuerdo con una encuesta realizada por Ernst & Young (2023), la pandemia no creó nuevos desafíos para las cadenas de suministro, pero sacó a la luz importantes vulnerabilidades. Por ejemplo, en China, que fue el epicentro de la pandemia, se experimentaron graves interrupciones en sus cadenas de suministro debido a los confinamientos. En los Estados Unidos de América también hubo importantes disrupciones en sus cadenas de suministro, donde estados como California, Texas, Nueva York y Florida fueron afectados significativamente. En adición, también deben mencionarse las disrupciones provocadas por la guerra entre Israel y Palestina. En ésta, los huties (grupo de Yemen respaldado por Irán) dificultan el paso de barcos por el Canal de Suez en el Mar Rojo. Según *The Economist* (2023), el 10% del comercio marítimo mundial en 2023 transitó por este canal, lo que conllevó a que EE.UU. liderara la creación de una Coalición Naval, con el fin de defender el transporte marítimo en la zona.

Otro factor acelerador del *nearshoring* es el tratado de libre comercio, que existe entre los países de Norteamérica,⁵ el cual establece una plataforma para el libre y más fácil intercambio transfronterizo de bienes y servicios. Este tratado fue actualizado con el USMCA⁶ en 2020, con el objetivo de crear un comercio recíproco, más equilibrado, que respaldara empleos bien remunerados e hiciera crecer la economía de América del Norte (*Office of the United States Trade Representative*, 2024).

4. Principales determinantes y efectos del *nearshoring*

En función de las experiencias de los diferentes países que han recibido inversiones extranjeras como resultado del *nearshoring*, se listan a continuación algunas características comunes en ellos:

- Cercanía a uno de sus mercados objetivo
- Costos reducidos
- Mano de obra calificada
- Lazos económicos fuertes
- Entorno legal y regulatorio favorable
- Afinidad cultural
- Infraestructura
- Estabilidad macroeconómica y política

En el caso particular de México se destaca que tiene como ventaja la calidad de vida que ofrece a extranjeros y sus familias y la zona horaria, alineada con los horarios de EE.UU. (Ernst & Young, 2023). Sin embargo, este país muestra debilidades en su entorno legal y el Estado de Derecho que actualmente no representan un incentivo (Deloitte, 2023).

En este sentido, se ha observado que el porcentaje de nuevas inversiones del total de la IED se ubica en sus niveles más altos desde 2013 (48% de la IED total en 2022). Adicionalmente, en el primer semestre de 2023, México recibió alrededor de USD29,000 millones en inversiones, lo cual representa un 5.6% más comparado con el mismo período para 2022 (Reuters, 2024). Las importaciones de EE.UU. desde México subieron aproximadamente 19% en 2022, respecto al año anterior. Por su parte, las importaciones de China desde México pasaron de un 1% en 1994 al 20% en 2022.

5 North American Free Trade Agreement (NAFTA) o Tratado de Libre Comercio de América del Norte, promulgado en 1994 entre EE.UU., Canadá y México.


6 También conocido en Canadá como el acuerdo CUSMA o en México como T-MEC, pero los tres acrónimos se refieren al mismo acuerdo comercial.

Si esa dinámica continúa, la creación de nuevas plantas de fabricación podría añadir un 3% adicional al PIB de ese país durante los siguientes 5 años, según Deloitte. Estos resultados han hecho que México sea de los países que más se han beneficiado del *nearshoring* (Deloitte, 2023).

Es importante mencionar el auge manufacturero que México ha tenido en los últimos años debido a la mayor demanda global. Para 2022, la producción manufacturera mexicana creció 5.2% anual, lo cual es significativamente mayor que el promedio de 2.3% de los 10 años anteriores (ver figura 1). En este contexto, se deben señalar algunos de los efectos positivos que puede traer el *nearshoring* en el país receptor:

- Crecimiento económico mediante la atracción de IED, del incremento de la productividad y de la generación de más ingresos.
- Creación de trabajo en el país receptor.
- Desarrollo de habilidades con el establecimiento de las nuevas empresas que ofrecen programas de capacitación y desarrollo para los empleados locales, lo que beneficiaría la fuerza laboral del país receptor.
- Desarrollo de infraestructura debido a que las inversiones tipo *nearshoring* requieren mejoras en infraestructura, como transporte, redes de comunicación y servicios públicos.
- Transferencia de tecnología de las empresas multinacionales hacia las empresas locales, lo cual genera innovación y competitividad para el país que recibe las inversiones.
- Diversificación de la economía para el país receptor al expandirse hacia nuevas industrias y sectores.

Figura 1: Producción manufacturera de México como porcentaje del PIB



Fuente: (Deloitte, 2023)

A pesar de estos efectos beneficiosos, el *nearshoring* podría traer algunos efectos negativos, tales como: a) dependencia de inversiones de empresas extranjeras; b) presiones salariales y de precios; c) agotamiento de recursos, específicamente para los casos donde las empresas consumen altos recursos locales o producen mucha contaminación; y d) desequilibrios comerciales, específicamente si la mayoría de productos se exportasen a mercados extranjeros, entre otros.

5. ¿Qué países de Latinoamérica se beneficiarán?

Los flujos de inversión extranjera directa sugieren que los países cercanos a EE.UU. serían los más beneficiados, donde destaca México, y los de la región centroamericana, como

Guatemala y El Salvador, que tienen potencial en el marco del *nearshoring* debido a su privilegiada ubicación geográfica, su previa experiencia en inversiones internacionales y sus tratados de libre comercio (Banco de Desarrollo de América Latina y el Caribe, 2022).

De acuerdo con el Banco Interamericano de Desarrollo (BID), la ganancia potencial para América Latina y el Caribe, derivado del *nearshoring*, en el corto y mediano plazo podría representar un aumento de hasta USD78,000 millones, de los cuales serían USD64,000 millones en comercio de bienes y USD14,000 millones en comercio de servicios (Banco Interamericano de Desarrollo, 2022). Al respecto, es importante señalar que en 2022, Brasil (41% del total) y México (17%) destacaron como los países que recibieron la mayor proporción de la IED; por su parte, Chile (9.3%), Colombia (7.5%), Argentina (6.8%), Perú (4.8%) y algunos países de Centroamérica y El Caribe (ver tabla 1) recibieron flujos de Inversión Extranjera Directa en menor proporción.

De acuerdo con la clasificación elaborada por la consultora inglesa Savills⁷ en su "Índice de Nearshoring", de una muestra de 40 países, México ocupa la posición más alta de la región latinoamericana (posición 15), seguido por Brasil (posición 25), siendo estos dos los únicos de la región en aparecer en dicho listado. En esta clasificación se toma en cuenta que para los fabricantes, la mano de obra no es el único costo crítico, sino también los costos de energía, infraestructura de calidad, un entorno comercial y regulatorio favorable y una base existente de exportación manufacturera (ver figura 2).


Tabla 1: Participación del flujo de entrada de IED en América Latina y el Caribe (año 2022)

País	Proporción en 2022 (%)
América del Sur	74.0
Argentina	6.8
Brasil	40.7
Chile	9.3
Colombia	7.5
Ecuador	0.4
Perú	4.8
Uruguay	4.2
Resto de países	0.3
México	17.3
América Central	4.4
Costa Rica	1.6
Guatemala	0.6
Honduras	0.5
Nicaragua	0.6
Panamá	1.1
Resto de países	0.0
El Caribe	4.3
Bahamas	0.5
República Dominicana	1.8
Guyana	2.0
Resto de países	0.0

Fuente: (Naciones Unidas, 2023)

⁷ Vietnam, Ucrania e Indonesia ocupan las primeras tres posiciones, respectivamente.

Figura 2: Índice de Nearshoring



Fuente: (Savills, 2020)

6. Conclusiones

El *nearshoring* está cobrando relevancia en el continente americano debido a aceleradores como la crisis geopolítica entre EE.UU y China, la pandemia del COVID-19 y las disrupciones en las cadenas de suministro. Esto ha provocado una reconfiguración del comercio mundial, que ha llevado a varias empresas a ubicarse cerca de sus mercados objetivos por razones logísticas y mano de obra calificada, entre otras.

México y Brasil han sido identificados como los países latinoamericanos con las mejores oportunidades para aprovechar el *nearshoring*. Sin embargo, Centroamérica y otras repúblicas de América del Sur también tienen características potenciales que podrían ser explotadas para la atracción del *nearshoring*.

Es importante resaltar que los optantes a país receptor, deben poseer características como: cercanía, costos relativamente menores, mano de obra calificada, un entorno legal y político favorable, infraestructura y estabilidad macroeconómica, entre otros. En este sentido, las políticas macroeconómicas debieran enfocarse en lograr que las economías con estas características se vuelvan atractivas para las empresas en busca de esta opción.

7. Referencias

Banco de Desarrollo de América Latina y el Caribe (11 de marzo de 2022). Obtenido de <https://www.caf.com/es/conocimiento/visiones/2022/03/nearshoring-y-las-oportunidades-para-la-industria/>

Banco Interamericano de Desarrollo (07 de junio de 2022). Obtenido de <https://www.iadb.org/es/noticias/nearshoring-agregaria-us78000-millones-en-exportaciones-de-america-latina-y-caribe>

Bloomberg Línea (28 de agosto de 2023). Obtenido de Bloomberglinea: <https://www.bloomberglinea.com/2023/08/28/que-sectores-lideran-la-inversion-en-nearshoring-en-latinoamerica/#:~:text=El%20nearshoring%2C%20la%20estrategia%20industrial,consolida%20como%20el%20principal%20destino.>

Deloitte (13 de julio de 2023). Obtenido de Deloitte Insights: <https://www2.deloitte.com/us/en/insights/economy/issues-by-the-numbers/advantages-of-nearshoring-mexico.html>

Ernst & Young (2023). Obtenido de https://www.ey.com/es_mx/foreign-investment-nearshoring-in-mexico

Ernst & Young (06 de enero de 2023). Obtenido de https://www.ey.com/en_gl/insights/supply-chain/how-covid-19-impacted-supply-chains-and-what-comes-next#:~:text=The%20pandemic%20continues%20to,new%20challenges%20for%20supply%20chains.

Financial Times (12 de junio de 2023). Obtenido de <https://www.ft.com/content/802bd45c-d420-418a-8ba4-dble3f643d31>

FTI Consulting (14 de marzo de 2024). Obtenido de FTI Consulting: <https://www.fticonsulting.com/insights/articles/nearshoring-mexico-where-opportunities>

Garrido, C. (2022). México en la fábrica de América del Norte y el *nearshoring*. Naciones Unidas (CEPAL), 1-95.

Meyer, T. (2006). Offshoring to new shores: Nearshoring to Central and Eastern Europe. Deutsche Bank Research, 1-12.

Naciones Unidas (2023). Foreign Direct Investment in Latin America and the Caribbean. CEPAL.

Office of the United States Trade Representative (2024). Obtenido de Office of the United States Trade Representative: <https://ustr.gov/trade-agreements/free-trade-agreements/united-states-mexico-canada-agreement>

Reuters (20 de marzo de 2024). Obtenido de <https://www.reuters.com/breakingviews/mexican-wave-nearshoring-firms-is-all-sea-2024-03-19/>

Savills (02 de julio de 2020). Spotlight: Covid-19 and Global Manufacturing Supply Chains. Obtenido de https://www.savills.com/research_articles/255800/301674-0

Tetawaki (14 de marzo de 2024). Obtenido de Tetawaki: <https://insights.tetakawi.com/canada-nearshores-brings-assembly-back-to-north-america>

The Economist (01 de diciembre de 2005). The rise of nearshoring. The Economist - Outsourcing in eastern Europe. Obtenido de <https://www.economist.com/special-report/2005/12/01/the-rise-of-nearshoring>

The Economist (19 de diciembre de 2023). Attacks on shipping in the Red Sea are a blow to global trade.

The Economist (2023). Attempts to make supply chains "resilient" are likely to fail. The Economist - Homeland Economics.

Machine Learning y banca central

Mariano José Gutiérrez Morales¹

I. Introducción

En la actualidad nos encontramos en la convergencia de dos tendencias muy importantes en la ciencia de datos. Por un lado, se han dado grandes avances en las técnicas de modelaje guiadas por los datos, que combinan conceptos de estadística computacional, optimización matemática, reconocimiento de patrones, análisis predictivo e inteligencia artificial. Usualmente englobamos todo esto en el término *Machine Learning*. Por otro lado, podemos observar un incremento exponencial en la cantidad de datos granulares en diferentes campos, usualmente conocido como *Big Data*.

A pesar de que la mayor parte de estos desarrollos se han producido en el sector privado, no existe una razón por la cual el sector público, y en especial los hacedores de política económica, no puedan beneficiarse de ellos, dado que tienen un gran potencial para ayudar a instituciones como los bancos centrales en el manejo y análisis de los ambientes cada vez más complejos en los que operan.

Estas nuevas técnicas pueden ser de apoyo para recolectar más y mejor información, la cual es clave para instituciones como los bancos centrales, que dependen en gran medida de datos. Algoritmos de *Machine Learning* pueden responder a esta demanda mejorando la calidad de los datos, lidiando con *outliers*, datos faltantes o datos con frecuencia distinta. Una dimensión adicional en la que los algoritmos de *Machine Learning* y el *Big Data* pueden ser de gran utilidad es en la supervisión financiera, ya que pueden ser herramientas para que los supervisores puedan identificar fragilidades financieras u otro tipo de amenazas emergentes a un nivel microeconómico. Desde un punto de vista macroprudencial, los bancos centrales pueden beneficiarse del uso de *Machine Learning* para reunir e interpretar información de varias fuentes de datos no relacionadas para evaluar vulnerabilidades sistémicas y su evolución en el tiempo. Además, estas técnicas pueden apoyar otras tareas relevantes desde el punto de vista de la estabilidad financiera, incluyendo el funcionamiento del sistema de pagos, la inclusión financiera, protección al consumidor y actividades contra el lavado de dinero.

El fin primordial es que los formuladores de política tengan a su disposición información de mejor calidad, más oportuna e interpretable para la toma de decisiones. En este sentido, la complementariedad es esencial: los algoritmos de *Machine Learning* deben ser entendidos como herramientas de soporte, que proveen información adicional a los enfoques tradicionales y se suman a la experiencia del *staff*, ya que estas técnicas tienen también limitaciones que deben ser entendidas.

La mayor parte de las aplicaciones de *Machine Learning* han sido tradicionalmente construidas alrededor de problemas de predicción. Por otro lado, las herramientas econométricas, especialmente las utilizadas en análisis de política económica, han sido hechas para la inferencia causal. En este sentido, la econometría y los algoritmos de *Machine Learning* debieran entenderse como extensiones mutuas.

Podemos entender los problemas de política económica como una combinación de dos partes: una predictiva y una de inferencia causal. Es evidente que necesitamos pronosticar de la mejor manera las variables que son relevantes para la política, pero asimismo, es de suma importancia conocer la fuerza y dirección de las relaciones entre estas variables, con el fin de poder dar recomendaciones de política adecuadas.

II. Conceptos básicos

Cada sistema de aprendizaje consiste de un conjunto de componentes: un problema, una fuente de datos, un modelo, un algoritmo de optimización y una rutina de validación y prueba. Las técnicas de *Machine Learning* están relacionadas con el reconocimiento de patrones o en la construcción de aproximaciones generales de las relaciones existentes en los datos, en situaciones en las que no existe una solución analítica evidente.

Podemos hablar de dos tipos generales de algoritmos de *Machine Learning*: 1) de aprendizaje supervisado y 2) de aprendizaje no supervisado, y el tipo de algoritmo dependerá de la naturaleza del problema.

El aprendizaje supervisado es el caso clásico de modelar Y utilizando X . Existe un modelo que trata de ajustar la variable Y , dado un conjunto X de datos de entrada. Se dice que en este caso, los datos están etiquetados dado que cada dato observado X_i , está relacionado a un resultado Y_i observado. Por otro lado, en el caso del aprendizaje no supervisado, no existe una variable objetivo Y . En este caso, los algoritmos están enfocados en encontrar una estructura en los datos, por ejemplo, agruparlos de algún modo. Estos métodos se conocen como modelo solo de variable latente, ya que no se especifica ninguna relación previamente.

El aprendizaje supervisado se divide en dos clases principales de problema: clasificación y regresión. En los problemas de clasificación, el resultado consiste de un set discreto de “salidas”, las cuales podrían no estar ordenadas. Por ejemplo, podríamos querer inferir Y : empleado o desempleado, a partir de un conjunto de hábitos de consumo (X). Un método de aprendizaje nos devolvería uno de los dos posibles resultados para cada conjunto de hábitos X_i .

Por el contrario, los problemas de regresión tratan de ajustar un resultado para una variable continua. Un ejemplo

¹ Especialista III, Departamento de Investigaciones Económicas, Banco de Guatemala.

podría ser un modelo que trate de modelar la inflación o el crecimiento económico. En este sentido, el término regresión en *Machine Learning* difiere al típicamente utilizado en econometría. Regresión en *Machine Learning* se refiere al tipo de problema y no al tipo de modelo estadístico (lineal o logístico, por ejemplo).

Dentro de los modelos de aprendizaje supervisado y no supervisado podemos nombrar los siguientes:

Aprendizaje supervisado

- Clasificador *Naïve Bayes*
- *K-Nearest neighbours*
- *Tree models* y *Random Forests*
- Redes neuronales artificiales
- *Support vector machines*

Aprendizaje no supervisado

- *K-Means clustering*
- *Clustering* jerárquico
- Sistemas de recomendación

III. Usos y aplicaciones en banca central

Recolección de más y mejor información

Además de ser pilares en los sistemas de estadísticas nacionales, los bancos centrales también son usuarios intensivos de información. Esta es utilizada como soporte para la toma de decisiones de política económica, la cual está basada en buena medida en evidencia cuantitativa. La creciente disponibilidad de bases de datos granulares complejas, de alta frecuencia, han puesto de manifiesto la necesidad de crear mejores y más eficientes sistemas de administración de datos para garantizar su calidad y su confiabilidad al momento de su utilización.

Un ejemplo de esto es el desarrollo de herramientas para detección de valores atípicos en estas bases de datos. Usualmente, para bases de datos pequeñas, las herramientas tradicionales manuales pueden ser utilizadas por un analista de datos, pero al incrementar el tamaño de las mismas, esto se vuelve imposible. El Bundesbank o banco central de Alemania ha adoptado un sistema para detectar *outliers* en una base de datos financiera de gran volumen. El enfoque se basa en varios algoritmos para agrupar la información en *clusters*, evaluar sus diferencias, comprimir la información a analizar y generar explicaciones para el uso en sistemas de predicción o modelaje.

Por otro lado, es importante para un banco central contar con suficiente información en el momento preciso, lo cual en ocasiones puede ser complicado derivado de los rezagos en la publicación de cierta información relevante. En este sentido, las técnicas de *Machine Learning* pueden ser de ayuda para extrapolar información de alta frecuencia (diaria por ejemplo) hacia variables de menor frecuencia (trimestral) con el objetivo de crear “predicciones inmediatas” (*nowcasts*) o proveer información en tiempo real del comportamiento de algunas variables como el crecimiento económico. El Banco de Rusia, por ejemplo, ha desarrollado herramientas que facilitan la compilación

de las cuentas financieras y las balanzas del sistema de cuentas nacionales.

Adicionalmente, estas técnicas pueden proveer información contextual adicional para las tareas de un banco central. En este sentido, el Banco Central Europeo ha desarrollado una herramienta basada en *Machine Learning* para ampliar su base de datos de Identificación Legal de Entidades (LEI, por sus siglas en inglés), para clasificar entre instituciones financieras y no financieras, y dentro de las que se identifican como no financieras, las cuales podrían ser supervisadas por su relación con entidades financieras y que podrían representar riesgos al sistema financiero, a partir de los nombres de dichas entidades.

En la práctica, estos enfoques no pueden depender únicamente de ejecutar algoritmos en una computadora, requieren un grado significativo de experiencia y conocimiento, no solo en aspectos computacionales, sino en los problemas específicos bajo análisis. En nuestro último ejemplo, es necesaria la experiencia en supervisión para saber el listado de palabras en los nombres de las entidades analizadas, para poder obtener un resultado relevante.

Tareas de análisis macroeconómico y financiero

Dado que las decisiones de los bancos centrales se basan cada vez más en evidencia empírica, un factor clave para ellos es organizar y analizar la gran variedad de datos existentes para derivar perspectivas útiles sobre la situación económica y de este modo, poder tomar decisiones de política mejor informadas. Las técnicas de *Machine Learning* pueden ser de gran utilidad, ayudando a darle sentido a los datos económicos y financieros, y facilitando el proceso de modelaje de la economía.

Dar sentido a la información disponible

Un ejemplo de esto es un proyecto del Banco Central Europeo para explorar fuentes alternativas de datos para extraer, en tiempo real, información que podría ser útil. Estas fuentes podrían derivarse de la creciente digitalización de la actividad económica, información extraída de aplicaciones de compra de bienes, de acciones, de entretenimiento o del uso de tarjetas de crédito, generando indicadores suplementarios de información. El objetivo es maximizar el uso de la información disponible, explorar fuentes de datos alternativas no explotadas y mejorar la cooperación con las nuevas entidades privadas que generan estos datos. El Banco de Francia, por ejemplo, ha construido indicadores no tradicionales, utilizando redes como *Twitter* para estimar la percepción inflacionaria.

Modelación macroeconómica

Más allá de la creación y utilización de fuentes alternativas de información para la toma de decisiones, esta también puede ser usada para mejorar la especificación de los modelos utilizados en el proceso. Otro aporte importante de las técnicas de *Machine Learning* es el caso de comprender de forma agnóstica cuáles son las variables

relevantes para la macroeconomía de un país, esto por medio de aproximaciones estrictamente basadas en los datos, en vez de utilizar supuestos previos.

Por ejemplo, Kohlscheen (2021) aplica algoritmos de *random forest* para analizar las causas subyacentes de la inflación, y en particular, el papel de los factores financieros que usualmente no se toman en cuenta en los modelos macroeconómicos. Otro ejemplo en este campo es el uso de *Machine Learning*, en el Banco de Francia, para seleccionar un set reducido de variables a partir de una base de datos inicial de mayor tamaño, para estimar las exportaciones y la inversión extranjera directa. Estos son solamente algunos ejemplos de cómo estas técnicas están siendo cada vez más utilizadas como soporte en ejercicios de modelaje macroeconómico.

Pronósticos

Es este el campo en el que las técnicas discutidas tienen un mayor terreno. Los modelos de *Machine Learning* son cada vez más usados para la generación de pronósticos de corto plazo y *nowcast*, con el objetivo de mejorar los ejercicios usuales de pronóstico realizados en los bancos centrales. Un ejemplo de esto ocurre en el Banco Central de Malasia, en donde se han utilizado algoritmos de *Machine Learning* para realizar un análisis de sentimiento a partir del texto de noticias, redes sociales y otras fuentes escritas de información y, posteriormente, emplear un indicador basado en dicha información para generar pronósticos de actividad económica o inflación más precisos. Sin embargo, es importante analizar y comparar los resultados a la luz de modelos más sencillos, como los modelos usuales de series de tiempo. Otro ejemplo es el uso de artículos de periódico, columnas y otras fuentes de texto para generar pronósticos de desempleo y condiciones del mercado laboral, realizado por el Banco de Indonesia.

Política monetaria

Como se menciona en los párrafos anteriores, las técnicas de *Machine Learning* pueden ser utilizadas para complementar el análisis y los pronósticos del crecimiento económico y la inflación, dos de las variables más importantes dentro de la función de reacción de un banco central. Además, permiten integrar un set mucho más amplio de variables que pueden contribuir a un mejor entendimiento del proceso económico.

En este sentido, el Banco de Indonesia ha desarrollado una herramienta basada en *Machine Learning* para integrar el impacto del comportamiento de los inversionistas extranjeros en la evolución del tipo de cambio y, por consiguiente, en las decisiones de política monetaria. Este ejercicio involucró el análisis de aproximadamente 2,000 variables, derivadas de datos de proveedores privados y de una base de datos de supervisión.

Además de lo mencionado, se han utilizado estas técnicas para el análisis y mejor entendimiento del proceso de toma de decisión de política monetaria a lo largo de la historia. Un estudio del Fondo Monetario Internacional se enfocó en el análisis de las transcripciones de las reuniones del

Comité Federal de Mercado Abierto (FOMC por sus siglas en inglés), entre 2003 y 2012, utilizando un modelo de Procesamiento de Lenguaje Natural (NLP por sus siglas en inglés). Estas transcripciones fueron divididas en aproximadamente 45,000 entradas de texto. El algoritmo clasificó estos datos en ocho temas principales: pronóstico, modelación económica, lenguaje de declaraciones, riesgo, banca, decisiones de votación, actividad económica y comunicación. Esto permitió identificar aquellos que fueron más discutidos por el FOMC al tomar decisiones de política monetaria. Por ejemplo, se mostró que la modelación económica fue el tema predominante durante la gran crisis financiera, y el bancario fue el tema principal en los períodos siguientes, seguido por la comunicación. Existe extensa literatura relacionada con modelos de lenguaje y política monetaria, por ejemplo Lucca y Trebbi (2009) analizan los comunicados del FOMC con el objetivo de identificar choques de política monetaria y analizarlos en un esquema de modelos de vectores autorregresivos (VAR).

Supervisión financiera

El campo de la supervisión financiera ha observado uno de los incrementos más marcados en el uso de *Machine Learning*. Estas técnicas pueden mejorar la eficiencia en la supervisión al complementar las tareas de supervisión tradicionales, facilitar el análisis de fragilidades a un nivel micro y al identificar nuevos temas emergentes, como los riesgos financieros relacionados con el clima, las vulnerabilidades al inicio de la pandemia o la creciente digitalización en las finanzas.

El Banco de Canadá, por ejemplo, ha desarrollado una herramienta basada en *Machine Learning*, para detectar anomalías en los datos reportados por instituciones financieras. El objetivo es mejorar la eficiencia y la calidad del proceso existente. Esto ha permitido detectar anomalías que previamente no eran detectadas, ahorrando tiempo en la ejecución del proceso. Además, este proceso fue creado para ser escalable, fácil de entender y de ejecutar localmente o desde un servidor. Por otro lado, estas técnicas también pueden ayudar a identificar fragilidades en instituciones financieras específicas, identificando prematuramente riesgos que podrían tener efectos sistémicos, mejorando la calidad de la supervisión a nivel de firmas.

Adicionalmente, al igual que en el ámbito macroeconómico, los algoritmos de *Machine Learning* pueden ser útiles en los ejercicios de análisis macroprudencial, mejorando los indicadores recolectados y ayudando a afinar el análisis de las relaciones entre variables de interés y las interconexiones observadas por medio de diferentes segmentos del sistema financiero. En este punto, el Banco Central Europeo, Deloitte y Google han desarrollado conjuntamente una solución a través de redes neuronales, que ayuda a los supervisores a manejar los indicadores disponibles de una forma integral y analizarlos por medio de herramientas y operaciones usualmente empleadas en la ciencia de datos. Esto ha ayudado a facilitar el monitoreo de la estabilidad financiera a la luz de eventos de riesgo sistémico.

Otras áreas que se han beneficiado de estas técnicas son las de inclusión financiera, protección al consumidor y el sistema de pagos. Este último se encuentra en el centro de las operaciones de un banco central y es esencial su buen funcionamiento para una economía. Los algoritmos de *Machine Learning* pueden ser de gran ayuda en el manejo de grandes cantidades de transacciones individuales, como se muestra en la experiencia del Banco Central del Ecuador, en el desarrollo de redes neuronales para la detección de transacciones anómalas, que podrían requerir el escrutinio detallado del equipo de vigilancia del sistema de pagos. Según Rubio et al. (2020), esta aplicación ha permitido identificar una amplia gama de transacciones anómalas.

IV. Conclusiones

Las técnicas de *Machine Learning* han estado en el ambiente desde hace varios años; sin embargo, recientemente el incremento de la capacidad computacional, a disposición de cualquier usuario, ha potenciado su utilización en diversos campos, entre ellos la economía.


Para un banco central, estos algoritmos pueden ser un gran complemento para las herramientas tradicionales usadas. Esto no solo está limitado a la generación de pronósticos o al modelaje macroeconómico, estas técnicas pueden ser instrumentales en la supervisión financiera, en la vigilancia del sistema de pagos, en el análisis macroprudencial, en la generación de indicadores y estadísticas, y su potencial es mayor aún. Sin embargo, es importante mencionar que ningún modelo o herramienta sustituye la experiencia y el conocimiento experto del *staff* de un banco central.

V. Referencias

Araujo, D., Bruno, G., Marcucci, J., Schmidt, R., & Tissot, B. (2023). Machine learning applications in central banking. *Journal of AI, Robotics & Workplace Automation*, 2(3), 271–293.

Chakraborty, C., & Joseph, A. (2017). Machine learning at central banks.

Kleinberg, J., Ludwig, J., Mullainathan, S., & Obermeyer, Z. (2015). Prediction policy problems. *American Economic Review*, 105(5), 491–495.



Directorio

Director

Johny Rubelcy Gramajo Marroquín

Consejeros

Herberth Solórzano Somoza
William Ariel Cano Hernández

Coordinador

Guillermo Aníbal Carranza

Producción

Alejandra María Segura García

Edición de textos

Juan Francisco Sagüí Argueta
Olga María Gallegos Rodríguez

Arte y Diagramación

Juan Carlos Calderón Lam

Impresión

Taller Nacional de Grabados en Acero

Notas Monetarias es un órgano divulgativo de información económica-financiera actualizada, de periodicidad bimestral y distribución gratuita. De aparecer colaboraciones especiales, sus autores serán entera y exclusivamente responsables por sus opiniones y, por consiguiente, estas no reflejarían la posición oficial del Banco de Guatemala, a menos que ello se haga constar de modo expreso. Es libre la reproducción de los artículos, gráficas y cifras que figuren en esta publicación, siempre y cuando se mencione la fuente. Toda correspondencia deberá dirigirse a: Notas Monetarias del Banco de Guatemala, 7a. Avenida 22–01, Zona 1, Ciudad de Guatemala, Código Postal No. 01001.