


**UNIVERSIDAD TÉCNICA
FEDERICO SANTA MARÍA**
DEPARTAMENTO DE INDUSTRIAS



ESTIMACIÓN DE CAUSALIDAD EN EL CRECIMIENTO
ECONÓMICO Y EN POLÍTICAS ECONÓMICAS EXPANSIVAS
MEDIANTE UPLIFT MODELING

CRISTHIAN MAURICIO BERMEO MUÑOZ

TESIS DE GRADO PARA OPTAR AL TÍTULO DE MAGÍSTER
EN CIENCIAS DE LA INGENIERÍA INDUSTRIAL

PROFESOR GUÍA: DR. WERNER KRISTJANPOLLER

PROFESORES CORREFERENTES: DR. JAVIER SCAVIA Y DR. WERNER CREIXELL

NOVIEMBRE, 2022

Resumen

En línea con el proyecto FONDECYT N° 1200555 denominado “*Estimation of causality in economic growth and expansionary policies using uplift modeling*”, el presente trabajo de tesis tiene como principal objetivo aterrizar diversos algoritmos causales de machine learning al área económica, presentando un marco de referencia con múltiples tratamientos y potenciales variables de respuesta para entender la causalidad existente entre el crecimiento de la producción real de bienes y servicios y la aplicación de políticas económicas expansivas en datos de panel.

Para esta investigación se utiliza un conjunto de series de tiempo de países pertenecientes a la Organización para la Cooperación y el Desarrollo Económico (OCDE, de aquí en adelante) para caracterizar el efecto causal que generan las políticas económicas expansivas (obtenidas a través de cambios porcentuales en el Gasto Final de Consumo de los gobiernos y en la Tasa de Interés de Largo Plazo de los países) sobre el crecimiento económico (obtenido a través de PIB Real de las economías). Adicionalmente, se modela una respuesta causal de las políticas expansivas a través de un nuevo conjunto de covariables macroeconómicas rezagadas en el tiempo.

La estimación de los efectos causales se realiza mediante la aplicación de métodos propios del *uplift modeling* enfocados en el estudio de la inferencia causal sobre datos experimentales y observacionales. Los modelos utilizados corresponden a algoritmos causales de ramificación que permiten asignar un tratamiento óptimo de acuerdo al efecto que se tenga sobre el resultado potencial.

Los principales resultados del estudio son los siguientes:

1. Se capturan efectos causales sobre el crecimiento económico dada la aplicación de políticas expansivas en el mismo período, mediante la mayoría de algoritmos utilizados. Este comportamiento se visualiza en todas las economías estudiadas, y logra coincidir con el comportamiento observado durante los últimos años del horizonte temporal.
2. Se modela y caracteriza la aplicación de políticas económicas expansivas de acuerdo al comportamiento rezagado del Índice General de Precios (IPC) y del PIB. Se definen

tratamientos potenciales que caracterizan a estas variables para explicar, a través de modelos de uplift modeling con respuesta binaria, el impacto que generan sobre la aplicación de las políticas previamente mencionadas.

Mediante el marco de referencia de doble causalidad intertemporal propuesto, se espera incentivar el uso de inteligencia artificial, y en particular la aplicación de métodos de uplift modeling para estudiar distintos fenómenos de índole económico (que actualmente se analizan mediante modelos econométricos tradicionales, con poca capacidad de generalización).

Agradecimientos

Quiero partir agradeciendo a los profesores Werner Kristjanpoller y Kevin Michell por haber confiado este tema de investigación en mí, apoyándome y aconsejándome de manera constante durante todo el proceso. Desde el momento en que me incorporé como alumno tesista hasta el momento en que nuestro paper quedó en revisión, rescato cada una de las reuniones que tuvimos y toda la información que fuimos descubriendo en conjunto. Agradezco igualmente que se interesaran en las propuestas y comentarios que realizaba, y sobre todo la flexibilidad con la que me permitieron trabajar en este trabajo cúlmine de mi etapa universitaria. Sin duda alguna fue una experiencia muy bien aprovechada, la cual me permitió crecer tanto a nivel profesional como personal.

Agradezco al profesor Rodolfo Salazar por haberme aconsejado desde el primer año de Universidad, entregándome herramientas y oportunidades que al día de hoy son muy valiosas. Por la confianza que depositó en mí para llevar la ayudantía de Microeconomía durante varios años y el apoyo que me dio de cara al Magíster y el posterior desarrollo como profesional.

Les agradezco a mis compañeros de magíster Mijail Littin, Vicente Castro, Felipe Alarcón, Mathias Reveco, Nicolás Irribarra, Fernando Ebensperger, Amanda García y Paulina Tapia por la ayuda que me otorgaron durante los ramos que rendimos juntos, y por la valiosa información que me dieron para abordar cada hito dentro del posgrado. A mis compañeros y amigos de generación, Nicolás Valenzuela, Jorge Valenzuela, Francisco Catalán e Ignacio Cabezas por entregarme miles de experiencias y oportunidades que me han hecho surgir. A día de hoy aún recuerdo todos esos momentos que estuvimos compartiendo ya sea dentro o fuera de la Universidad, los cuales valoro inmensamente.

A mi gran amigo Alexis Aravena, con el cual hemos mantenido contacto desde el colegio. Por todos esos días en que nos juntábamos a compartir historias y el total apoyo que recibí por su parte en múltiples situaciones que tuve que afrontar por mi cuenta.

Finalmente, agradecer a quienes considero a día de hoy como mi familia. A mi mamá Jenny por apoyarme incondicionalmente en todas las decisiones que he ido tomando, que aunque a veces le costaba aceptarlas de todas maneras confiaba en mí y en mis habilidades para alcanzar mis objetivos. A mi hermano Andrés, que ha seguido mi historia muy de cerca,

y al cual espero haberle transmitido lo mejor de mí tanto en experiencia como en metas y aspiraciones. A nuestro gato Yeezus que se convirtió en un pilar emocional muy fuerte desde que llegó a nosotros. A Valentina Milla, por acompañarme en este trayecto de mi vida, alentarme a vivir nuevas y maravillosas experiencias, por aconsejarme y estar ahí cuando la he necesitado.

Tabla de Contenidos

1	Introducción	1
2	Objetivos	4
2.1	Objetivo Principal	4
2.2	Objetivos Específicos	4
3	Marco Teórico	5
4	Metodología	8
4.1	Datos observacionales	8
4.2	Procesamiento de datos y propuesta metodológica	9
4.3	Algoritmos de Uplift Modeling	13
4.4	Métodos de evaluación para uplift modeling	14
4.4.1	Qini Curve y Revenue Qini Curve	14
4.4.2	Expected Outcome y Modified Uplift Curve	15
5	Resultados	17
5.1	Análisis estadístico	17
5.2	Importancia de las variables en la predicción del crecimiento económico . . .	22
5.3	Predicciones de efectos causales para el crecimiento económico	23
5.4	Importancia de las variables en la predicción de políticas económicas expansivas	27
5.5	Predicciones de efectos causales para las políticas económicas expansivas . .	28
6	Conclusiones y Recomendaciones	33

Lista de Tablas

5.1	Estadísticas del crecimiento del PIB real trimestral en los 34 países analizados entre 1979 y 2021. n : número de observaciones, x_{min} : valor mínimo, μ : media, x_{max} : valor máximo, σ : desviación estándar, CV : coeficiente de variación, γ : coeficiente de asimetría, k : coeficiente de curtosis.	18
5.2	Estadísticas del crecimiento del PIB real, el gasto general del gobierno y de las tasas de interés de largo plazo entre 1979 y 2021. n : número de observaciones, x_{min} : valor mínimo, μ : media, x_{max} : valor máximo, σ : desviación estándar, CV : coeficiente de variación, γ : coeficiente de asimetría, k : coeficiente de curtosis.	19
5.3	Número de observaciones para cada política económica entre 1979 y 2021. $\Delta\%G_t$ corresponde al cambio porcentual en el gasto general del gobierno en el período t , $\Delta\%INT_t$ a la variación porcentual en las tasas de interés de largo plazo del trimestre t	20
5.4	Estadísticas del crecimiento trimestral del PIB real, del gasto general del gobierno y de las tasas de interés de largo plazo por política económica entre 1979 y 2021. x_{min} : valor mínimo, μ : media, x_{max} : valor máximo, σ : desviación estándar, CV : coeficiente de variación, γ : coeficiente de asimetría, k : coeficiente de curtosis.	21
5.5	Estadísticas del crecimiento del PIB real, el gasto general del gobierno y de las tasas de interés entre el conjunto de datos de entrenamiento y el de evaluación. x_{min} : valor mínimo, μ : media, x_{max} : valor máximo, σ : desviación estándar, CV : coeficiente de variación, γ : coeficiente de asimetría, k : coeficiente de curtosis.	21
5.6	Porcentaje de aciertos entre predicciones de algoritmos de Revenue Uplift Modeling y asignaciones reales sobre el conjunto de datos de evaluación.	27

Lista de Figuras

4.1	Marco de referencia de doble causalidad propuesto. Se considera las matrices de covariables X_p y X_g (la diferencia es que esta última posee la variable correspondiente al IPC), además de los tratamientos de las políticas expansivas y el cambio porcentual del PIB real. Las variables <i>Country</i> y <i>t</i> representan el nombre del país y el período analizado, respectivamente.	12
5.1	Importancia de las variables sobre el PIB real de acuerdo al modelo de Bosque Aleatorio con 100 árboles.	22
5.2	Curvas de Qini y de Resultado Esperado sobre las variaciones porcentuales del PIB mediante Revenue Uplift Modeling.	24
5.3	Porcentaje promedio acumulado de los tratamientos óptimos basados en políticas expansivas por decil	26
5.4	Importancia de las variables rezagadas sobre las políticas expansivas de acuerdo al modelo de Bosque Aleatorio con 100 árboles.	28
5.5	Curvas de Qini y de Resultado Esperado sobre variaciones porcentuales de las políticas expansivas mediante Conversion Uplift Modeling. (a) Curva de Qini para política fiscal expansiva pura. (b) Curva de Qini para política expansiva mixta. (c) Curva de Qini para política monetaria expansiva pura. (d) Curva de <i>Expected Outcome</i> para política fiscal expansiva pura. (e) Curva de <i>Expected Outcome</i> para política expansiva mixta. (f) Curva de <i>Expected Outcome</i> para política monetaria expansiva pura.	29
5.6	Porcentaje promedio acumulado de los tratamientos óptimos basados en el PIB y en el IPC por decil. (a) Porcentaje promedio acumulado para política fiscal expansiva pura. (a) Porcentaje promedio acumulado para política expansiva mixta. (a) Porcentaje promedio acumulado para política monetaria expansiva pura.	32

Capítulo 1

Introducción

El crecimiento económico es un objetivo fundamental para los gobiernos, las empresas y los hogares que componen la economía de un país. Este fenómeno es estudiado a través de Producto Interno Bruto (PIB), el cual mide la producción de bienes y servicios de una economía en un tiempo determinado y permite el análisis de las fluctuaciones económicas sin considerar el efecto de la inflación. Se han generado múltiples métodos para predecir el PIB, utilizando diferentes modelos econométricos de series de tiempo para caracterizar el crecimiento económico. Mitchell et al. (2005) sugiere un enfoque formal para estimar el PIB mensual real del Reino Unido utilizando técnicas de predicción de corto plazo y diferentes análisis por sector económico. Por otro lado, Roush et al. (2017) usaron un vector autorregresivo para la predicción del crecimiento económico trimestral a través del gasto real de consumo de los hogares y del gobierno, en conjunto con la inversión doméstica. Kalaitzidakis et al. (2001) investigaron el crecimiento económico en un conjunto de datos de panel basándose en el capital humano, logrando percibir un comportamiento no lineal y cambios de acuerdo al desarrollo económico de los países bajo estudio.

La investigación econométrica ha identificado patrones entre covariables macroeconómicas y la producción de bienes y servicios al aplicar varias pruebas estadísticas cuyo objetivo era determinar la significancia de estas relaciones. Sin embargo, la correlación entre variables no debe ser confundida con la causación entre ellas, considerando que la correlación no asegura la repetibilidad de comportamientos observados y por lo tanto no se puede afirmar que futuras intervenciones serán efectivas (Dempster, 1990). La literatura estadística ha propuesto métodos como el Test de causalidad de Granger (1988) para estimar la direccionalidad causa-efecto en series de tiempo estacionarias, teniendo diversas aplicaciones como por ejemplo en la relación entre el crecimiento económico y el consumo de energía de un país (Beaudreau, 2010), o entre las exportaciones, importaciones y el PIB (Amiri y Gerdtham, 2012). No obstante, este indicador muestra algunas limitaciones ya que el marco de referencia basado

en un vector autorregresivo analiza si una serie de tiempo es predictiva de otra, que en sí mismo no corresponde a una real causalidad per se, además de considerar configuraciones de a pares que no necesariamente reflejan todas las relaciones existentes en los datos (Shojaie y Fox, 2022).

Utilizando como marco de referencia al análisis causal de resultados potenciales de Rubin (1972) y aprovechando el actual desarrollo computacional, ha surgido recientemente un área de investigación conocida como *uplift modeling*, la cual corresponde a una herramienta de machine learning (aprendizaje automático) que permite tratar efectos causales a un nivel individual. Una de sus ventajas corresponde a la generalización de patrones causales en múltiples conjuntos de datos de evaluación por sobre las inferencias que pueden ser obtenidas mediante modelos estadísticos convencionales (Athey e Imbens, 2019). Entre los modelos utilizados bajo el enfoque de uplift modeling se encuentran el Árbol Causal (CT, por sus siglas en inglés) de Athey y Wager (2018), el cual permite estimar efectos causales mediante un método de *nearest neighbor* con métrica adaptativa. El Bosque Causal (CF, por sus siglas en inglés) es una extensión de este modelo, el cual estima el efecto causal a través del promedio de inferencias obtenidas a través de múltiples árboles causales para mejorar el desempeño de la predicción, algo característico de los métodos de aprendizaje en conjunto (Dietterich, 2000). Otra rama de investigación dentro del uplift modeling corresponde al uso de *learners* o algoritmos de aprendizaje base con un Enfoque de Modelos Separados (SMA, por sus siglas en inglés), que estima respuestas incrementales de manera indirecta al entrenar un modelo para cada grupo de análisis (también conocidos como grupos de tratamiento), y escogiendo aquel que presente una mayor diferencia con respecto a un grupo de control determinado. Lo y Pachamanova (2015) extendieron este enfoque al caso de múltiples tratamientos usando un problema de optimización con regresión logística como modelo base. Zhao et al. (2017) propusieron un algoritmo basado en árboles con un criterio de partición particular para optimizar el rendimiento de los *uplifts* o respuestas incrementales; este método se conoce como Bosque de Selección Contextual de Tratamiento (conocido en la literatura de habla inglesa como CTS Forest), y se basa en un método de estimación insesgada de la esperanza de una respuesta condicionada al tratamiento aplicado (en esta área de estudio se conoce como Resultado Esperado o *Expected Outcome*). Se han implementado otros algoritmos al análisis multi-tratamiento, tales como el Enfoque de Respuesta Modificada al Multitratamiento (MMOA por sus siglas en inglés) que genera nuevas variables de respuesta a través de la segmentación de individuos y el Enfoque Incremental *Naive* (NUA, por sus siglas en inglés) que calcula el uplift de manera separada para cada tratamiento contra el caso de control (Olaya et al., 2020a). Otro modelo basado en procedimientos de ramificación o *branching* corresponde al Bosque de Ingresos Incrementales Multitratamiento (MTRUF, por sus siglas en inglés), el

cual particiona los datos favoreciendo al tratamiento con el mayor Resultado Esperado en cada nodo resultante (Gubela y Lessmann, 2020).

El área de uplift modeling ha tenido un alcance importante no solo entre investigadores para el desarrollo de nuevos métodos de estimación causal sino también en la industria, enfocando esfuerzos en áreas afines al marketing para la optimización de campañas publicitarias o de incentivos en términos de sus diseños y de la segmentación de los consumidores (Devriendt et al., 2018). Si bien existen otras aplicaciones, como por ejemplo el análisis de la tasas de deserción en la educación superior (Olaya et al., 2020b) y la retención de personal en compañías (Rombaut and Guerry, 2019), no existe en la literatura actual aplicaciones de esta área sobre efectos causales macroeconómicos producidos sobre el crecimiento económico. Es así como la principal contribución de esta investigación corresponde a la propuesta de un modelo de causalidad dual entre el PIB y un conjunto de políticas económicas, utilizando como método de estimación modelos propios de uplift modeling para analizar el impacto de estas relaciones en el crecimiento económico de diversos países alrededor del mundo.

Capítulo 2

Objetivos

2.1 Objetivo Principal

El objetivo principal de esta investigación corresponde a la aplicación de métodos de uplift modeling para la estimación de efectos causales bidireccionales entre el crecimiento económico de los países y sus correspondientes comportamientos macroeconómicos, utilizando para ello información trimestral de un conjunto determinado de países miembros de la OCDE entre los años 1979 y 2021.

2.2 Objetivos Específicos

1. Determinar qué políticas económicas (y bajo qué umbrales) pueden llegar a impactar en el crecimiento económico de un país, en busca de caracterizarlas como tratamientos.
2. Aplicar métodos de uplift modeling con respuesta continua para la estimación de efectos causales sobre el PIB Real, utilizando los tratamientos establecidos previamente.
3. Identificar posibles causas de los ajustes en las políticas económicas a través del comportamiento macroeconómico de los países para el establecimiento de nuevos tratamientos rezagados en el tiempo.
4. Modelar, mediante métodos de uplift modeling con respuesta binaria, los efectos causales que producen los tratamientos rezagados sobre las políticas económicas de los países.
5. Evaluar el desempeño de las estimaciones mediante métricas propias de uplift modeling, en busca de determinar la validez e interpretabilidad de los resultados.

Capítulo 3

Marco Teórico

Utilizando como base el marco de referencia de Rubin (1972), se define el Efecto Individual de un Tratamiento (ITE, por sus siglas en inglés) como la diferencia entre dos resultados potenciales. En primera instancia se debe considerar la aplicación o no de una variable causal, caracterizada por el indicador binario $T \in \{0, 1\}$. Si $T = 1$ entonces se ejerce dicha variable, y si $T = 0$ no se ejerce. Sea un conjunto de datos con N individuos o unidades. Sea $Y_i(T = 1)$ la variable de respuesta del individuo $i \in [1, N]$ bajo la aplicación de la acción más favorable (de aquí en adelante referida como tratamiento), y $Y_i(T = 0)$ la variable de respuesta potencial del mismo cuando el tratamiento no es aplicado, es decir, cuando dicha observación pertenece al grupo de control. Cada individuo puede llegar a tener o no un determinado tratamiento. El efecto causal, también conocido como el efecto de un tratamiento τ_i sobre la unidad i corresponde a:

$$\tau_i = Y_i(T = 1) - Y_i(T = 0) \quad (3.1)$$

Se espera que este efecto sea positivo, de manera que se puede justificar que el tratamiento ejercido tiene un impacto sobre la variable de respuesta a nivel individual. Ahora bien, en la realidad sólo un resultado puede ser observado, lo cual complica la estimación de esta variable. La existencia de un *contrafactual* (respuesta que no ocurrió) impone lo que se conoce como el problema fundamental de la inferencia causal (Holland, 1986).

La literatura sobre inferencia causal muestra un particular interés sobre la función $\tau(x)$ del Efecto Medio Condicional de un Tratamiento (CATE de aquí en adelante, por sus siglas en inglés), la cual corresponde al efecto esperado del tratamiento cuando las características del individuo (representada por el vector de covariables $X_i \in [0, 1]^d$) corresponden a x :

$$\tau(x) = \mathbb{E}[Y_i(T = 1) - Y_i(T = 0)|X_i = x] \quad (3.2)$$

La estimación de esta función en estudios observacionales (a diferencia de los estudios experimentales, sus grupos de tratamientos y control no pueden ser determinados previamente) requiere de tres supuestos. El primero de ellos corresponde al de ignorabilidad o de *unconfoundedness* bajo el cual la asignación de los tratamientos en los datos es cercana a la aleatoriedad, condicionada a las covariables del estudio (Rosenbaum y Rubin, 1983):

$$\{Y_i(T = 0), Y_i(T = 1)\} \perp T_i \mid X_i \quad (3.3)$$

El segundo supuesto corresponde a la Hipótesis de Valor Individual Estable del Tratamiento (SUTVA, por sus siglas en inglés) que implica que los resultados potenciales de un individuo deben ser independientes de la asignación del tratamiento a otro individuo o unidad. El último de estos supuestos corresponde al de Superposición, bajo el cual la puntuación de propensión (conocida como *propensity score* $e(X_i) = \mathbb{P}[T_i = 1|X_i]$) debe estar acotada entre el valor nulo y de la unidad ($e(X_i) \in (0, 1)$) (Gubela y Lessmann, 2020). El *propensity score* corresponde a la probabilidad de obtener un tratamiento condicionada a las características del individuo.

En línea con la investigación relacionada a los efectos causales, el *uplift modeling* corresponde a un enfoque propio del área de machine learning que permite estimar el Efecto Individual de un Tratamiento (ITE) en una variable de respuesta de interés. Este conjunto de métodos o algoritmos se utiliza porque el verdadero efecto de los tratamientos no puede ser observado (debido a la presencia de contrafactuales), y por lo tanto no puede ser estimado mediante modelos econométricos tradicionales, ni siquiera bajo configuraciones experimentales basadas en ensayos de control aleatorio (Gutiérrez y Gérardy, 2016). La estimación del ITE en configuraciones binarias ($T_i \in \{0, 1\}, \forall i$) se basa en probabilidades condicionales, cuya diferencia es utilizada para determinar el efecto del tratamiento en un conjunto de datos:

$$\hat{\tau}_i(X_i) = \hat{\mathbb{P}}[Y_i(T = 1) = 1|X_i] - \hat{\mathbb{P}}[Y_i(T = 0) = 1|X_i] \quad (3.4)$$

Este modelo puede ser extendido al caso de multitratamiento, donde se analiza la aplicación de K tratamientos, con o sin grupo de control. Esta investigación se enfoca en el modelamiento de efectos causales con un grupo de control, es decir, comparando cada alternativa $t \in [1, K]$ de tratamiento con un grupo sin tratamiento ($T = 0$), para posteriormente determinar la acción óptima para cada individuo:

$$\hat{\tau}_{i,t}(X_i) = \hat{\mathbb{P}}[Y_i(T = t) = 1|X_i] - \hat{\mathbb{P}}[Y_i(T = 0) = 1|X_i] \quad ; \forall i, t \quad (3.5)$$

$$\pi_i^* = \arg \max (\hat{\tau}_{i,1}, \dots, \hat{\tau}_{i,K}) \quad ; \forall i \quad (3.6)$$

donde π_i^* corresponde al tratamiento con el mayor *uplift* o respuesta incremental para el individuo o unidad i . Debe destacarse que las suposiciones establecidas previamente para datos observacionales siguen siendo válidos ante este enfoque multitratamiento.

La literatura no sólo diferencia por número de tratamientos aplicados, sino también por la naturaleza de la variable de respuesta o resultado. Así, se identifican actualmente dos corrientes conocidas como Conversion Uplift Modeling y Revenue Uplift Modeling. El primero de ellos considera respuestas binarias (tal como se observa en la Equation 3.5), mientras que el segundo incorpora variables de respuesta continuas ($Y_i \in \mathbb{R}_0^+$) (Gubela et al., 2017). Con respecto a la estimación en el enfoque multitratamiento de uplift modeling, se observan dos métodos de procesamiento de datos (Olaya et al., 2020a). El primer método corresponde al Enfoque de Modelos Separados (SMA), el cual es un método de estimación indirecto y una generalización del Enfoque de Dos Modelos (Radcliffe, 2007) utilizado en modelos de un único tratamiento. El SMA entrena un modelo predictivo para cada grupo de tratamiento (incluyendo el de control), utilizando las características individuales como predictoras y la variable de respuesta como objetivo. Posteriormente, cada modelo es usado para calcular las probabilidades individuales condicionales, y las predicciones de cada tratamiento propuesto se sustraen de las predicciones generadas para el grupo de control. El segundo método de procesamiento de datos corresponde a la estimación directa basada en diversos algoritmos causales de machine learning adaptados a la configuración multitratamiento; dentro de estos modelos se encuentran los algoritmos de ramificación tales como los Bosques Causales, los Árboles de Decisión Incremental o de Uplifts con criterios de separación basados en métricas de divergencia (Rzepakowski y Jaroszewicz, 2012), los Bosques de Diferencias en Resultados (Becher y Krol, 2020) y los Bosques de Selección Contextual de Tratamiento (Zhao et al., 2017).

El principal objetivo del uplift modeling corresponde a personalizar la asignación de tratamientos para cada variable en estudio, enfocando esfuerzos en determinar aquella acción que genera el mayor impacto o efecto positivo dentro de un conjunto de datos determinado. Al mismo tiempo, esta área de machine learning busca segmentar a la población observada para reconocer a grupos de datos o nichos que probablemente tendrían una respuesta favorable bajo la aplicación de un tratamiento óptimo. La evaluación de desempeño de estos modelos plantea un reto para los investigadores debido al problema fundamental de inferencia causal, lo que implica que el rendimiento de las predicciones causales encontradas no pueden ser directamente comparadas con los resultados reales (que se revelarían *a posteriori*). Las técnicas de evaluación para algoritmos de uplift modeling se presentan dentro de la metodología, específicamente en la Sección 4.4.

Capítulo 4

Metodología

En este capítulo se establece el marco de referencia causal dual propuesto, el cual revela conexiones causales entre políticas macroeconómicas, el PIB real y el Índice de Precios al Consumidor, caracterizando cambios en el crecimiento económico de diferentes países bajo distintos intervalos de tiempo. Los efectos causales encontrados son capturados a través de los enfoques multitratamiento de Conversion Uplift Modeling y Revenue Uplift Modeling.

4.1 Datos observacionales

El presente estudio considera datos trimestrales de 34 países pertenecientes a la OCDE, entre los años 1979 y 2021. En total se consideran 4.036 observaciones, donde las economías tienen distintas cantidades de datos (países como Estados Unidos, Australia o Canadá cuentan con 168 observaciones cada uno, mientras que Chile que se unió recientemente a esta organización posee 69 observaciones). Cabe destacar que la información recolectada representa un conjunto de datos observacional, en el sentido que los tratamientos aplicados no pueden ser asignados a conveniencia del estudio. Las variables macroeconómicas estudiadas en un período t se muestran a continuación:

- GDP_t : Producto Interno Bruto en el trimestre t .
- C_t : Gasto Final de Consumo Privado en el trimestre t .
- I_t : Formación Bruta de Capital en el trimestre t .
- G_t : Gasto final de consumo del gobierno general en el trimestre t .
- EX_t : Exportaciones en el trimestre t .
- IM_t : Importaciones de bienes y servicios en el trimestre t .

- P_t : Índice de Precios al Consumidor (IPC) en el trimestre t .
- U_t : Tasa de desempleo en el trimestre t .
- INT_t : Tasa de interés de largo plazo en el trimestre t .

Estas variables se obtienen a través de estimaciones de volumen (excepto por el IPC, la tasa de desempleo y la de interés de largo plazo), lo que permite una medición correcta de la actividad económica de los países en estudio al considerar valores reales (en términos de bienes y servicios) en vez de valores nominales, es decir, se remueve el efecto de la inflación (Balk y Reich, 2008). La variable de Formación Bruta de Capital se utiliza para determinar el nivel de inversión doméstica de capital de un país. De igual manera, la Tasa de Interés de Largo Plazo se utiliza para caracterizar la oferta monetaria de una economía (ya que esta última impacta a la tasa de interés a través del equilibrio en los mercados domésticos de saldos monetarios reales o de dinero).

4.2 Procesamiento de datos y propuesta metodológica

El conjunto de datos iniciales comentados previamente se utilizan para obtener variaciones porcentuales, de manera de poder comparar el crecimiento económico entre los diferentes países analizados sin considerar su tamaño como economías. Para el caso particular de las variables de tasa de desempleo (U_t) y de las tasas de interés (INT_t) se obtienen las primeras diferencias para caracterizar el cambio porcentual trimestral (al ser unidades en tasas o porcentajes). El resto de variables continuas no porcentuales (incluyendo el IPC que se encuentra medido como indicador y no como tasa) se procesan a través de la primera diferencia logarítmica para obtener varianzas más homogéneas (Luetkepohl y Xu, 2009). Debe notarse que las variaciones porcentuales son obtenidas para cada una de las economías en estudio, en busca de generar una estructura de datos de panel para la evaluación de los cambios en el crecimiento económico y en las políticas económicas aplicadas a través de economías representativas durante el horizonte temporal definido en esta investigación.

Posteriormente, se definen las políticas económicas expansivas como un conjunto de tratamientos para analizar sus posibles efectos causales sobre el crecimiento económico. Las políticas económicas expansivas (políticas expansivas, de aquí en adelante) corresponden a cambios porcentuales positivos en las variables de Gasto General del Gobierno G_t (política fiscal expansiva) y cambios porcentuales negativos en la tasa de interés de largo plazo INT_t (política monetaria expansiva). Esta última se explica por alzas en la oferta monetaria por parte de los bancos centrales (suponiendo que la demanda de dinero permanece invariante),

lo cual disminuye la tasa de interés para asegurar el equilibrio del mercado de dinero. Formalmente, los tratamientos aplicados en el trimestre t corresponden a:

- **FE**: Política fiscal expansiva pura ($\Delta\%G_t > 0, \Delta\%INT_t \geq 0$).
- **FEME**: Política expansiva mixta ($\Delta\%G_t > 0, \Delta\%INT_t < 0$).
- **ME**: Política monetaria expansiva pura ($\Delta\%G_t \leq 0, \Delta\%INT_t < 0$).

donde la política expansiva mixta corresponde a la aplicación conjunta de políticas fiscales y monetarias expansivas. Estos tratamientos utilizan como umbral a la variación porcentual nula o cero de un período t con respecto al anterior ($t - 1$), y se incorporan en el modelo como variables dicotómicas (siendo 1 en caso de que se aplique la política expansiva y 0 en caso contrario). La variable de respuesta o resultado corresponde a la variación porcentual del PIB (GDP_t), la cual se espera que presente uplifts positivos al aplicar alguno de estos tratamientos con respecto al caso de control que implica el uso de al menos una política económica contractiva (variaciones porcentuales no positivas en el gasto general del gobierno o variaciones porcentuales no negativas en la tasa de interés de largo plazo). La hipótesis de esta generación de tratamientos es que la aplicación de políticas expansivas ejercidas por entidades gubernamentales y bancos centrales estimula el crecimiento en la producción real de bienes y servicios de una economía, dado un conjunto de covariables macroeconómicas que caracteriza el desempeño económico de un país determinado. Cabe destacar que dentro de la estructura de datos de panel estudiada no se encuentran presentes casos en los cuales ambas variables de tratamientos presenten a la vez variaciones porcentuales nulas con respecto al trimestre anterior.

El conjunto de datos de panel con variaciones porcentuales se divide en datos de entrenamiento para generar los uplifts con modelos causales y en datos de evaluación o testeo para evaluar el rendimiento de las predicciones otorgadas por estos algoritmos, utilizando un enfoque multitratamiento de Revenue Uplift Modeling (con variable de respuesta continua). Como criterio de separación de datos, se utiliza el 90 % de los períodos iniciales compartidos por cada economía para determinar el conjunto de datos de entrenamiento, de manera que los modelos causales para determinar las respuestas incrementales sobre el PIB real en base a las políticas expansivas se generan con observaciones entre los trimestres Q1-1980 y Q2-2017¹. Los períodos restantes, los cuales consideran 612 observaciones equitativamente distribuidas entre cada economía, se utilizan para analizar la calidad de las predicciones de uplift de acuerdo a ciertas métricas de evaluación causales, las cuales se abordan en la Sección 4.4.

¹la letra “Q” hace referencia a la palabra en inglés *quarter*, la cual traducida corresponde a “trimestre”. Así, Q1-1980 corresponde al primer trimestre del año 1980, por ejemplo.

Una vez que se capturan las señales de uplift sobre el PIB real a través de las políticas expansivas, se generan modelos causales bajo el enfoque de Conversion Uplift Modeling (con respuesta binaria), utilizando cada una de las políticas económicas previamente determinadas como tratamientos como variables de respuestas potenciales, y estableciendo dos nuevos tratamientos para explicar los efectos causales que se pueden generar sobre las políticas expansivas en el período t : las variaciones porcentuales del PIB real y del Índice de Precios al Consumidor, de acuerdo a unos umbrales definidos *a priori*:

- **TGDP**: Caída del PIB real ($\Delta\%GDP_{t-1} < 0.582$, $\Delta\%P_{t-1} \geq 0.611$).
- **TPGDP**: Caída conjunta del PIB real y del IPC ($\Delta\%GDP_{t-1} < 0.582$, $\Delta\%P_{t-1} < 0.611$).
- **TP**: Caída del IPC ($\Delta\%GDP_{t-1} \geq 0.582$, $\Delta\%P_{t-1} < 0.611$).

donde se utilizan las variaciones porcentuales trimestrales promedio del PIB real y del IPC entre 1979 y 2021 como puntos de inflexión para generar estos indicadores dicotómicos (1 en caso de experimentar dichas variaciones en el período $t - 1$ con respecto al trimestre $t - 2$ y 0 en caso contrario). Bajo este contexto, tanto la matriz de covariables como el vector de tratamientos se encuentran rezagados en un período, en un intento de explicar un uplift positivo sobre las políticas expansivas del conjunto de datos de entrenamiento. La idea detrás de este enfoque es que las entidades a cargo de las políticas económicas generan estrategias para controlar los indicadores macroeconómicos de acuerdo a los cambios en el nivel general de precios y en las variaciones de la producción de bienes y servicios del trimestre anterior, estableciendo así un supuesto: las políticas económicas expansivas se ajustan de acuerdo al comportamiento macroeconómico del corto plazo (rezago de un trimestre).

La Figura 4.1 muestra el marco de referencia propuesto en esta investigación para un trimestre t determinado. Este marco de referencia está compuesto de dos fases: en la primera fase se modelan los uplifts o efectos causales sobre las políticas económicas expansivas en el período $t - 1$ (a través de los cambios porcentuales en el gasto general del gobierno y en las tasas de interés de largo plazo) con Conversion Uplift Modeling utilizando los datos de entrenamiento. Este enfoque considera la matriz X_p de covariables macroeconómicas rezagadas (que no considera el Índice de Precios al Consumidor), además de los tratamientos del PIB real y del IPC como variaciones porcentuales entre los trimestres $t - 2$ y $t - 1$. En la segunda fase, se utiliza Revenue Uplift Modeling en los datos de entrenamiento para estimar efectos causales o uplifts ejercidos por las políticas expansivas aplicadas en el trimestre $t - 1$ sobre la variación porcentual del PIB real en el período t , dada la matriz X_g de covariables macroeconómicas (que se compone de la matriz X_p y de la variable correspondiente al Índice




Figura 4.1: Marco de referencia de doble causalidad propuesto. Se considera las matrices de covariables X_p y X_g (la diferencia es que esta última posee la variable correspondiente al IPC), además de los tratamientos de las políticas expansivas y el cambio porcentual del PIB real. Las variables *Country* y *t* representan el nombre del país y el período analizado, respectivamente.

de Precios al Consumidor). Posteriormente en esta fase, los resultados son generalizados al predecir la causalidad sobre el crecimiento económico utilizando métricas propias del uplift modeling para evaluar el desempeño de los modelos bajo el conjunto de datos de evaluación. Bajo este marco de referencia el Índice de Precios al Consumidor sirve para caracterizar al PIB real (en conjunto con otras covariables macroeconómicas) pero tendría un efecto causal sobre las variables del gasto general del gobierno y de las tasas de interés de largo plazo que condicionan a las políticas económicas expansivas previamente mencionadas. Estas dos últimas variables, en conjunto con el PIB Real, actuarían tanto como variables de respuesta y tratamiento (los uplifts sobre el gasto general del gobierno y las tasas de interés de largo plazo serían estimadas a través de la primera fase por el PIB real y el Índice de Precios al Consumidor, y en la segunda fase servirían para predecir efectos causales sobre el crecimiento económico). Así, esta metodología propuesta busca capturar una causalidad dual intertemporal entre el PIB real (que indica el crecimiento económico de los países) y las políticas expansivas aplicadas por diferentes organizaciones gubernamentales y entidades monetarias en un conjunto de economías mundialmente representativas.

4.3 Algoritmos de Uplift Modeling

Para capturar el efecto causal entre los diferentes tratamientos y variables de respuesta o resultado, esta investigación utiliza métodos o algoritmos basados en árboles, tanto para la estimación directa como indirecta de los uplifts, dentro de los cuales algunos son previamente adaptados al caso multitratamiento. Debe notarse que los datos económicos son extremadamente limitados comparados con otras bases de datos experimentales, por lo cual el uso de *ensemble learning* permite obtener un rendimiento predictivo razonable.

En la primera fase propuesta se utiliza el enfoque de Conversion Uplift Modeling a través de los siguientes métodos:

- CT: Árbol Causal
- CF: Bosque Causal
- SMA lr: Enfoque de modelos separados con regresión logística
- SMA rf: Enfoque de modelos separados con Bosque Aleatorio

Estos algoritmos permiten incorporar a múltiples tratamientos de manera dicotómica para predecir uplifts sobre un vector de respuesta binario. En la segunda fase del marco de referencia se aplica Revenue Uplift Modeling a través de los siguientes modelos:

- CT: Árbol Causal
- CF: Bosque Causal
- CTS: Bosque de Selección Contextual de Tratamiento
- DOM: Bosque de Diferencias en Resultados
- SMA dt: Enfoque de modelos separados con Árbol de Decisión
- SMA rf: Enfoque de modelos separados con Bosque Aleatorio

Estos métodos se basan en la predicción de uplifts sobre un vector de respuesta continuo. Con respecto al método DOM, se evalúan diferentes criterios de ramificación para escoger la máxima ganancia que produce los *splits* y permite la creación de nuevos nodos hijos; las métricas evaluadas permiten diferenciar entre los modelos *DOM simple* (cuyo método de ganancia evalúa la suma de diferencias cuadráticas entre tratamientos de cada potencial nodo hijo), *DOM frac* (el cual calcula la ganancia como un promedio ponderado de diferencias cuadráticas entre tratamientos de cada potencial ramificación, tomando en cuenta

la proporción de datos de cada subconjunto) y *DOM max* (que considera las diferencias cuadráticas entre las predicción más alta y el resto de predicciones con otros tratamientos de cada potencial nodo).

Todos los métodos expuestos anteriormente consideran para su generación un total de 100 árboles (a excepción de los modelos de Árboles Causales y de Decisión que claramente contienen una sola ramificación), con un número mínimo de 10 observaciones por nodo (que permite obtener predicciones como promedios para el nodo padre o generar subconjuntos para predicciones en nodos hijos dependiendo de si se cumple o no este criterio adicional de ramificación) y una selección aleatoria de 4 covariables (para encontrar la mayor ganancia necesaria para determinar los *splits* y generar los nodos hijos correspondientes).

4.4 Métodos de evaluación para uplift modeling

El principal desafío de la inferencia causal es la imposibilidad de determinación del verdadero tratamiento de una observación individual. Por lo tanto, no se puede utilizar la métrica de error entre los valores actuales de las respuestas y las predicciones de los algoritmos. Considerando los métodos propuestos y comunmente utilizados en la literatura alrededor de efectos causales, se utilizan las métricas de *Revenue Qini Curve* y *Modified Uplift Curve* para el análisis causal entre las variables de tratamiento y de respuesta. Estas métricas permiten trabajar bajo un enfoque multitratamiento con vectores de resultados binarios y continuos (Zhao et al., 2017) (Gubela y Lessmann, 2020). A continuación, se muestra el desarrollo de ambos métodos de evaluación causal.

4.4.1 Qini Curve y Revenue Qini Curve

Sea n el número de predicciones en el conjunto de datos de evaluación y $\hat{\mu}_1, \dots, \hat{\mu}_n$ las predicciones de uplift ordenadas por individuo. Sea $\phi \in [0, 100]$ un determinado cuantil y $N_\phi = \{i, \hat{\mu}_i \geq \hat{\mu}_{\phi n}\} \subset \{1, \dots, n\}$ el subconjunto de individuos o unidades con los $\phi n/100$ uplifts de mayor magnitud. Se define el uplift incremental o Curva de Qini (*Qini Curve*) para el cuantil ϕ como:

$$h(\phi) = \sum_{i \in N_\phi} y_i \tau_i - \sum_{i \in N_\phi} y_i (1 - \tau_i) \cdot \frac{\sum_{i \in N_\phi} \tau_i}{\sum_{i \in N_\phi} (1 - \tau_i)} \quad (4.1)$$

con $h(0) = 0$. En este caso, $y_i \in [0, 1]$ corresponde a la respuesta binaria de una observación i , mientras que $\tau_i \in [0, 1]$ corresponde a la asignación óptima de un tratamiento para un individuo. La Curva de Qini se construye a través del uplift incremental de cada uno de

los cuantiles. Extendiendo esta métrica para vectores de respuesta continua con múltiples tratamientos, la Curva de Ingresos Qini o *Revenue Qini Curve* se utiliza para el caso de K tratamientos. Sea $Y_{i,k}$ y $Y_{i,0}$ las respuestas continuas de una variable con un tratamiento distinto del control y con un tratamiento de control, respectivamente. Adicionalmente, $N_{\phi,k}$ y $N_{\phi,0}$ corresponden al número de observaciones por cuantil con algún tratamiento asignado distinto de control y con el tratamiento de control, respectivamente. La *Revenue Qini Curve* para el cuantil ϕ corresponde a:

$$R(\phi) = \sum_{i \in N_\phi} Y_{i,k} - \sum_{i \in N_\phi} Y_{i,0} \cdot \frac{N_{\phi,k}}{N_{\phi,0}} \quad (4.2)$$

Para el caso multitratamiento, el subconjunto de individuos se define como $N_\phi = \{i, \hat{\mu}_{i,k} \geq \hat{\mu}_{\phi n,j}\}$, $k, j \in \{1, \dots, K\}$, ordenando las observaciones de manera descendiente de acuerdo al tratamiento k con el mayor uplift o respuesta incremental $\pi_{i,k}^*$ entre todas las predicciones obtenidas dentro del conjunto de datos de evaluación.

4.4.2 Expected Outcome y Modified Uplift Curve

Sea $T_s = \{0, \dots, K\}$ el conjunto de tratamientos (incluyendo el grupo de control) y p_t la probabilidad de que el tratamiento óptimo sea $t \in T_s$. Sea $u(X)$ la predicción de un modelo de uplift dado un vector X de covariables un tratamiento asignado t para el individuo i . La variable aleatoria $Z_{i,\phi}$ de una observación para un cuantil ϕ dado se define como:

$$Z_{i,\phi} = \sum_{t \in T_s} \frac{Y_{i,\phi}}{p_t} \cdot \mathbb{I}\{u(X) = t\} \cdot \mathbb{I}\{T = t\} \quad (4.3)$$

con $\mathbb{I}(\cdot) \in \{0, 1\}$ la función indicatriz y $Y_{i,\phi}$ la respuesta del individuo i en dicho cuantil. El Resultado Esperado (*Expected Outcome*) de un método de uplift multitratamiento se obtiene como:

$$\bar{z}_\phi = \frac{1}{n} \sum_{i=1}^n Z_{i,\phi} \quad (4.4)$$

con $\bar{z}$ un estimador insesgado del valor esperado de la variable de respuesta si el modelo es utilizado para asignar un tratamiento. Esta métrica trata con potenciales sesgos que pueden resultar cuando los tamaños de los grupos de tratamiento están relativamente desbalanceados. Para obtener la Curva Modificada de Uplift (*Modified Uplift Curve*), se reordenan las observaciones de manera decreciente de acuerdo al máximo uplift $\pi_{i,k}^*$, para posteriormente establecer los cuantiles respectivos. El Resultado Esperado inicial $\bar{z}_0$ se obtiene asumiendo que todas las predicciones de tratamiento óptimo indican que las observaciones pertenecen al

grupo de control. El *Expected Outcome* $\bar{z}_\phi$ de los siguientes cuantiles $\phi \in (0, 100]$ se obtienen al reemplazar todos los tratamientos óptimos de las observaciones que no pertenecen a N_ϕ por el tratamiento de control.

Capítulo 5

Resultados

5.1 Análisis estadístico

En primer lugar, se lleva a cabo un análisis estadístico sobre el PIB real, el cual caracteriza el crecimiento económico de los países bajo estudio. La Tabla 5.1 muestra los rangos y la media del crecimiento del PIB trimestral, así como su variabilidad, la simetría y la curtosis de su distribución en las economías analizadas. Se puede observar que el crecimiento económico es heterogéneo entre los países de la OCDE (caracterizado por los valores mínimos y máximos, la media, la desviación estándar, el coeficiente de variación, el coeficiente de asimetría y el de curtosis observado). Por ejemplo, una economía desarrollada como la de Estados Unidos posee un crecimiento trimestral promedio de 0,635 % con una variabilidad de 1,166 %, mientras que países en vías de desarrollo como Chile posee un crecimiento trimestral promedio mayor de 0,821 % y también una mayor desviación estándar de 2,227 %. En general, las tasas de crecimiento trimestral varían de manera distinta: algunos países perciben una mayor estabilidad de crecimiento (existen desviaciones estándar cercanas a 1,00 % en economías como Corea del Sur, Australia o Alemania) comparados con países de economías más volátiles (con desviaciones estándar cercanas al 2,00 %, como es el caso de Nueva Zelanda, Grecia o México).

En la Tabla 5.2 se muestran las estadísticas generales de los países bajo estudio en términos de las variaciones porcentuales sobre el PIB real, el gasto general del gobierno y las tasas de interés. Se observa que el PIB real de los países creció en promedio a una tasa de 0,582 % de manera trimestral entre 1979 y 2021, mientras se experimenta un crecimiento promedio del 0,509 % en el gasto fiscal y una leve caída en las tasas de interés de largo plazo del 0,071 %. Así, el crecimiento de la producción de bienes y servicios está acompañada de un incremento en el gasto general del gobierno y en menor medida de un decrecimiento en las tasas de interés de las economías. En términos del coeficiente de variación (el cual mide la dispersión

relativa alrededor de la media), las tasas de interés muestran una mayor variabilidad relativa en comparación con el PIB o con el gasto general del gobierno.

Tabla 5.1: Estadísticas del crecimiento del PIB real trimestral en los 34 países analizados entre 1979 y 2021. n : número de observaciones, x_{min} : valor mínimo, μ : media, x_{max} : valor máximo, σ : desviación estándar, CV : coeficiente de variación, γ : coeficiente de asimetría, k : coeficiente de curtosis.

Country	$x_{min}(\%)$	$\mu(\%)$	$x_{max}(\%)$	$\sigma(\%)$	CV	γ	k
Australia	-7.030	0.740	3.369	1.006	1.359	-2.526	20.164
Austria	-12.135	0.424	10.261	1.706	4.025	-1.806	32.590
Bélgica	-12.374	0.478	11.228	1.502	3.141	-1.814	48.910
Canadá	-11.701	0.557	8.603	1.373	2.467	-3.165	42.221
Chile	-13.118	0.821	5.906	2.227	2.714	-3.334	20.410
República Checa	-9.314	0.617	6.498	1.566	2.540	-2.734	19.319
Dinamarca	-6.266	0.419	5.916	1.255	2.995	-0.443	6.939
Finlandia	-6.697	0.432	4.907	1.401	3.242	-1.553	7.782
Francia	-14.461	0.427	17.043	1.941	4.541	0.922	54.786
Alemania	-10.532	0.297	8.657	1.517	5.105	-1.897	26.817
Grecia	-14.442	0.039	5.223	2.333	60.540	-2.701	14.368
Hungría	-15.362	0.635	10.844	2.240	3.527	-3.181	31.093
Islandia	-10.398	0.638	7.348	3.319	5.199	-0.668	0.716
Irlanda	-5.512	1.290	21.711	2.881	2.233	2.633	16.020
Israel	-9.540	0.944	8.290	1.637	1.734	-1.627	18.658
Italy	-13.503	0.153	14.853	2.050	13.423	0.353	35.619
Japón	-8.274	0.233	5.169	1.338	5.735	-1.987	13.552
Corea del Sur	-3.339	0.889	2.949	0.953	1.072	-1.802	6.814
Latvia	-7.323	0.773	5.417	2.313	2.991	-0.847	1.756
Lituania	-13.763	0.940	4.277	2.075	2.209	-4.619	29.147
Luxemburgo	-7.276	0.801	7.695	1.978	2.470	-0.200	4.704
México	-19.662	0.409	12.656	2.846	6.952	-3.465	32.444
Países Bajos	-8.748	0.562	7.237	1.215	2.164	-2.009	26.677
Nueva Zelanda	-9.697	0.689	12.864	2.052	2.977	0.031	14.332
Noruega	-4.770	0.564	4.390	1.317	2.336	-0.070	1.809
Polonia	-9.654	0.905	7.287	1.625	1.796	-2.469	21.802
Portugal	-16.546	0.341	13.691	2.280	6.681	-1.902	34.394
República Eslovaca	-10.093	0.843	8.682	2.087	2.476	-1.820	12.391
Eslovenia	-9.911	0.598	11.178	2.204	3.685	-0.301	11.751
España	-19.422	0.514	15.528	2.312	4.495	-2.719	48.857
Suecia	-8.104	0.533	6.750	1.269	2.380	-1.733	17.978
Suiza	-6.346	0.477	6.076	1.165	2.441	-1.296	17.153
Reino Unido	-21.629	0.523	16.188	2.320	4.433	-3.596	64.196
Estados Unidos	-9.362	0.635	7.276	1.166	1.838	-2.861	36.124

Considerando que las políticas económicas se basan en el gasto final de consumo del gobierno y en las tasas de interés de largo plazo para estimular o contraer la demanda agregada de una economía, el conjunto de datos inicial se separa de acuerdo al comportamiento observado de estas variables en términos de sus variaciones porcentuales con respecto al trimestre anterior. La Tabla 5.3 muestra el número de observaciones del comportamiento de estas variables, en donde se puede apreciar que existen relativamente pocos casos bajo los cuales las políticas económicas permanecen invariantes respecto al trimestre anterior. Más aún, se observa que de manera histórica el gasto general del gobierno tiende a incrementar y las tasas de interés de largo plazo tienden a decrecer. Separando los datos por los tratamientos asociados a la segunda fase del marco de referencia propuesto, es decir, formando grupos asociados a cada política expansiva y al grupo de control, se observa que el tamaño de estos conjuntos es variable. Existen 1.184 observaciones asociadas con políticas fiscales expansivas puras, 698 con políticas monetarias expansivas puras y 1.732 con políticas expansivas mixtas. El restante de 478 observaciones corresponde al caso de control, el cual plantea un desafío inicial en términos de qué tan válido puede llegar a ser la aplicación de modelos causales cuando el número de observaciones por tratamiento propuesto excede al tamaño del grupo de control.

Tabla 5.2: Estadísticas del crecimiento del PIB real, el gasto general del gobierno y de las tasas de interés de largo plazo entre 1979 y 2021. n : número de observaciones, x_{min} : valor mínimo, μ : media, x_{max} : valor máximo, σ : desviación estándar, CV : coeficiente de variación, γ : coeficiente de asimetría, k : coeficiente de curtosis.

	GDP	G	INT
$x_{min}(\%)$	-21.629	-19.699	-7.527
$\mu(\%)$	0.582	0.509	-0.071
$x_{max}(\%)$	21.711	16.650	6.797
$\sigma(\%)$	1.872	1.528	0.519
CV	3.217	3.000	7.354
γ	-1.353	-0.487	-0.146
k	34.709	24.658	31.201

La Tabla 5.4 muestra las estadísticas asociadas a las variaciones porcentuales del PIB real, del gasto final de consumo del gobierno general y de las tasas de interés de largo plazo según las diferentes políticas económicas expansivas aplicadas en el horizonte temporal analizado. Se observa que los coeficientes de variación tanto del gasto del gobierno como de las tasas de interés son similares entre los grupos. Analizando el PIB real, destaca el hecho de que las observaciones con políticas económicas expansivas logran mayores valores esperados que la respuesta promedio del grupo de control. Un dato adicional de relevancia corresponde a que la variabilidad relativa del PIB es considerablemente mayor bajo el grupo de control que

bajo el conjunto de datos con alguna política expansiva.

Tabla 5.3: Número de observaciones para cada política económica entre 1979 y 2021. $\Delta\%G_t$ corresponde al cambio porcentual en el gasto general del gobierno en el período t , $\Delta\%INT_t$ a la variación porcentual en las tasas de interés de largo plazo del trimestre t .

Política Económica	N° de observaciones
$\Delta\%G_t > 0, \Delta\%INT_t = 0$	31
$\Delta\%G_t > 0, \Delta\%INT_t < 0$	1732
$\Delta\%G_t > 0, \Delta\%INT_t > 0$	1153
$\Delta\%G_t < 0, \Delta\%INT_t = 0$	19
$\Delta\%G_t = 0, \Delta\%INT_t < 0$	1
$\Delta\%G_t < 0, \Delta\%INT_t > 0$	451
$\Delta\%G_t < 0, \Delta\%INT_t < 0$	607
$\Delta\%G_t = 0, \Delta\%INT_t > 0$	8
$\Delta\%G_t = 0, \Delta\%INT_t = 0$	0

La Tabla 5.5 muestra las estadísticas de crecimiento porcentual en términos del PIB Real, del gasto general del gobierno y de las tasas de interés de largo plazo entre el conjunto de datos de entrenamiento y el de evaluación o testeo. De acuerdo a estos datos, la producción promedio de bienes y servicios ha decaído en los últimos trimestres del horizonte temporal (entre Q3-2017 y Q4-2021), mientras que el gasto fiscal y las tasas de interés han aumentado en promedio. Adicionalmente, la variabilidad relativa de estas variables macroeconómicas también ha aumentado, lo cual se observa al comparar los coeficientes de variación entre los datos de entrenamiento y de testeo. Esto implica que el comportamiento económico de los países en estudio es diferente en el conjunto de datos de evaluación, por lo cual existe un desafío en términos de la flexibilidad y la generalización de resultados que deben enfrentar los modelos causales propuestos.

Tabla 5.4: Estadísticas del crecimiento trimestral del PIB real, del gasto general del gobierno y de las tasas de interés de largo plazo por política económica entre 1979 y 2021. x_{min} : valor mínimo, μ : media, x_{max} : valor máximo, σ : desviación estándar, CV : coeficiente de variación, γ : coeficiente de asimetría, k : coeficiente de curtosis.

	Política fiscal expansiva			Política expansiva mixta		
	GDP	G	INT	GDP	G	INT
$x_{min}(\%)$	-19.422	0.001	0.000	-10.532	0.002	-7.527
$\mu(\%)$	0.774	1.082	0.300	0.680	1.023	-0.329
$x_{min}(\%)$	11.188	12.603	5.703	21.711	16.650	-0.001
$\sigma(\%)$	1.572	1.162	0.379	1.854	1.116	0.350
CV	2.030	1.074	1.264	2.727	1.091	1.063
γ	-2.689	3.480	5.003	2.385	5.135	-6.735
k	36.714	18.692	46.856	30.043	51.263	108.443
	Política monetaria expansiva			Control		
	GDP	G	INT	GDP	G	INT
$x_{min}(\%)$	-21.629	-19.699	-5.884	-19.662	-11.861	0.000
$\mu(\%)$	0.322	-0.868	-0.404	0.082	-1.019	0.374
$x_{min}(\%)$	7.582	0.000	-0.001	9.289	0.000	6.797
$\sigma(\%)$	1.755	1.444	0.477	2.533	1.587	0.493
CV	5.458	1.664	1.180	30.824	1.556	1.319
γ	-4.689	-6.200	-4.925	-4.037	-3.630	5.773
k	50.280	59.899	43.152	22.290	15.387	61.186

Tabla 5.5: Estadísticas del crecimiento del PIB real, el gasto general del gobierno y de las tasas de interés entre el conjunto de datos de entrenamiento y el de evaluación. x_{min} : valor mínimo, μ : media, x_{max} : valor máximo, σ : desviación estándar, CV : coeficiente de variación, γ : coeficiente de asimetría, k : coeficiente de curtosis.

	Datos de entrenamiento			Datos de evaluación		
	GDP	G	INT	GDP	G	INT
$x_{min}(\%)$	-13.763	-13.431	-7.527	-21.629	-19.699	-1.273
$\mu(\%)$	0.607	0.483	-0.078	0.445	0.653	-0.030
$x_{max}(\%)$	21.711	12.603	6.797	17.043	16.650	1.333
$\sigma(\%)$	1.277	1.395	0.550	3.728	2.113	0.293
CV	2.105	2.886	7.056	8.369	3.237	9.765
γ	0.390	-0.540	-0.116	-1.111	-0.458	-0.018
k	35.423	15.635	28.978	9.596	26.860	3.003

5.2 Importancia de las variables en la predicción del crecimiento económico

En busca de entender el impacto que tienen las variables económicas sobre el crecimiento económico, se genera un modelo de Bosque Aleatorio (*Random Forest*) para modelar el cambio porcentual del PIB real utilizando la matriz de covariables mencionada previamente. Para la generación de este algoritmo se consideran 100 árboles que permitirán obtener predicciones a través de un promedio de las inferencias calculadas en cada árbol. El período analizado corresponde al mismo horizonte temporal de la investigación (1979-2021). Como hiperparámetros se define un número mínimo de 10 observaciones por nodo y una selección aleatoria de cuatro variables para la generación de las particiones.




Figura 5.1: Importancia de las variables sobre el PIB real de acuerdo al modelo de Bosque Aleatorio con 100 árboles.

La Figura 5.1 muestra los resultados asociados con la importancia de las covariables, es decir, el impacto que tiene en promedio cada una de estas variables en el decrecimiento de la impureza de cada nodo (basada en el índice de Gini) (Yuan et al., 2021). Se observa que el Gasto Final de Consumo Privado y las Exportaciones de bienes y servicios permiten explicar de mejor manera al crecimiento económico, seguidos de las Importaciones y de la Formación Bruta de Capital. Además, el modelo generado permite identificar la heterogeneidad de los crecimientos económicos de cada país ya que la variable dicotómica asociada a la identificación de los países es relevante en términos del impacto sobre el PIB real. En contraste, las variables de Gasto del gobierno, Índice de Precios al Consumo y Tasas de interés de largo plazo contribuyen relativamente poco al modelamiento del crecimiento económico. Estos resultados justifican la separación de las políticas fiscales y monetarias expansivas del resto de variables macroeconómicas para ser incorporadas como tratamientos que pueden afectar

incrementalmente al PIB si es que llegasen a ser aplicadas (las variaciones porcentuales del Índice de Precios al Consumidor no se consideran como un tratamiento ya que en las economías analizadas no existen agencias o entidades encargadas de fijar el precio general de los bienes y servicios basados en objetivos de crecimiento a corto o largo plazo).

5.3 Predicciones de efectos causales para el crecimiento económico

Para capturar los efectos causales sobre el crecimiento económico de los países, los algoritmos correspondientes al enfoque de Revenue Uplift Modeling son generados utilizando como información de modelamiento al conjunto de datos de entrenamiento. Los efectos individuales de los tratamientos (ITEs) se predicen sobre el conjunto de datos de evaluación para ser procesados a través de las métricas de las Curvas de Uplift Incrementales (*Qini curves*) y las Curvas modificadas de Uplift por deciles. La Figura 5.2 muestra las curvas de Qini y de Resultado Esperado (*Expected Outcome*) generadas por las métricas causales de evaluación.

En términos de las curvas de Qini, se puede observar que los algoritmos de uplift modeling utilizados logran presentar un mejor uplift con las predicciones de los tratamientos propuestos, comparados con el caso en el que la asignación de tratamientos hubiese sido aleatoria (lo cual está representado por la línea recta de la figura de Uplift Incremental). Así, los resultados indican que la aplicación de políticas económicas expansivas generan efectos causales incrementales positivos sobre el crecimiento económico a través del PIB real. Más aún, este efecto es de mayor magnitud dentro de los deciles más altos, y el uplift aumenta de manera decreciente a medida que se avanza a los deciles más altos. En general, se confirma que las políticas expansivas logran aumentar el PIB real de las economías de manera significativa (relativo al caso de políticas no expansivas) en el 20 % de las observaciones de los datos de evaluación. Con respecto al desempeño o rendimiento de los modelos, el Árbol Causal (CT), el Bosque Causal (CF), el Bosque de Diferencias de Resultados son particiones basadas en ganancias ponderadas (DOM frac) y el Enfoque de Modelos Separados con Bosque Aleatorio como *base learner* (SMA rf) presentan estimaciones de uplift incrementales de mayor magnitud que el resto de algoritmos. Debe notarse que el rendimiento del Enfoque de Modelos Separados con un Árbol de Decisión como *base learner* (SMA dt) es similar al de la asignación aleatoria para los últimos deciles, por lo cual el efecto causal estimado para este modelo no es relevante cuando se considera todo el conjunto de datos de evaluación.




Figura 5.2: Curvas de Qini y de Resultado Esperado sobre las variaciones porcentuales del PIB mediante Revenue Uplift Modeling.

De acuerdo con la Curva de Resultado Esperado (*Expected Outcome Curve*), la asignación de únicamente tratamientos de control genera resultados esperados negativos. Esto implica que la no-aplicación de políticas expansivas no genera cambios porcentuales positivos en el PIB real, sino que al contrario disminuye el crecimiento económico. A medida que las predicciones óptimas de tratamiento de cada modelo se incorporan en los primeros deciles, las curvas generadas van tomando valores mayores (menos negativos e incluso más positivos a medida que se considera todos los datos de evaluación). En particular, la aplicación de políticas económicas expansivas en los primeros dos deciles de mayor uplift genera un Resultado Esperado considerable para el Árbol Causal (CT), el Bosque Causal (CF), el Bosque de Selección Contextual de Tratamiento (CTS), el Bosque de Diferencias de Resultados tanto con criterio de partición simple (DOM simple) como con criterio de ganancia basado en ponderaciones (DOM frac), y el Enfoque de Modelos Separados con Bosque Aleatorio como *base learner* (SMA rf). Estos modelos son a su vez los que presentan mejor desempeño (en términos de las métricas causales de evaluación) en torno a la totalidad del conjunto de datos de evaluación. Así, los resultados indican que la aplicación de políticas expansivas generan uplifts significativos sobre el 20 % de las observaciones, concidiendo así con los resultados entregados por la curva Qini. A través del gráfico de Resultados Esperados se observa que el rendimiento es mayor en las predicciones del modelo de Bosque Causal (CF) en comparación con el Árbol Causal (CT), lo cual justifica el uso de *ensemble learning* para obtener mejores estimaciones de efectos causales (esto no queda del todo claro con la curva Qini). Adicionalmente, el Bosque Causal (CF) presenta predicciones de Resultado Esperado de mayor magnitud que el resto de los algoritmos generados, lo que implica que bajo este modelo el uplift sobre el PIB real es mayor que en el resto de algoritmos utilizados bajo la aplicación de alguna política expansiva determinada.

Analizando los primeros dos deciles con los modelos de mejor respuesta en cada una de las métricas analizadas, se observa que las predicciones de mayor uplift se encuentran dentro de las 34 economías estudiadas (a excepción de Corea del Sur bajo el modelo de Diferencias de Resultados con criterio de partición basado en ganancias ponderadas), lo que permite generalizar los resultados no solo para todas las economías sino para el conjunto de datos de evaluación como tal.

La Figura 5.3 muestra el porcentaje medio acumulado de tratamientos óptimos para cada decil. En este gráfico se considera el peso promedio de cada uno de los tratamientos óptimos (predicciones de tratamiento) con respecto al tamaño de la totalidad del conjunto de datos de evaluación. Se observa que la mayoría de observaciones tienen asignado un tratamiento distinto al de control, correspondiendo al 92,994 % de los casos. En particular, un 49,174 % de las observaciones presenta políticas fiscales expansivas puras que generan mayores uplift




Figura 5.3: Porcentaje promedio acumulado de los tratamientos óptimos basados en políticas expansivas por decil

sobre el crecimiento del PIB real, seguido de un 30,045 % de los datos con políticas expansivas mixtas y un 13,235 % con políticas monetarias expansivas puras. Estos resultados indican que la aplicación de políticas monetarias expansivas por sí solas no contribuyen a mejores uplift sobre el crecimiento económico. Por otro lado, la aplicación conjunta de ambas políticas expansivas predomina en los deciles con mayor uplift, y a medida que se incorporan más observaciones hay una mayor ponderación de políticas fiscales expansivas puras. Así, las políticas fiscales expansivas y las políticas expansivas mixtas predominan sobre el crecimiento económico, y en particular los mayores incrementos sobre el PIB real logran ser explicados de manera causal bajo la aplicación conjunta de políticas fiscales y monetarias expansivas.

La Tabla 5.6 muestra el porcentaje de aciertos entre las asignaciones óptimas de los algoritmos causales propuestos y los reales observados dentro de los datos de evaluación. En promedio la tasa de acierto es de un 84,15 % lo cual es bastante aceptable (considerando además que los primeros deciles presentan incrementos significativos con respecto al tratamiento de control). Dentro de los algoritmos analizados, los modelos de Bosques Causales, Bosques de Diferencias en Resultados con criterio de separación simple y con ganancias basadas en ponderaciones son los que poseen una mayor precisión. Si bien esta métrica no puede ser evaluada posteriormente en nuevos conjuntos de datos observacionales debido al problema de inferencia causal, destaca el hecho de que las predicciones obtenidas no solo tienen un significado económico sino que además se ajusta en gran medida a lo que realmente ha ocurrido con las políticas expansivas durante los últimos años.

Tabla 5.6: Porcentaje de aciertos entre predicciones de algoritmos de Revenue Uplift Modeling y asignaciones reales sobre el conjunto de datos de evaluación.

Modelos Causales	Porcentaje de aciertos
CT	80,23%
CF	86,27%
CTS	84,80%
SMA dt	77,94%
SMA rf	82,68%
DOM simple	86,60%
DOM frac	88,73%
DOM max	85,95%

5.4 Importancia de las variables en la predicción de políticas económicas expansivas

Considerando al conjunto de datos de entrenamiento para el modelamiento de los efectos causales sobre las políticas económicas expansivas (determinadas previamente como tratamientos) a través de las variaciones porcentuales del Índice de Precios al Consumidor y del PIB real por encima o debajo de sus promedios históricos (en el horizonte temporal evaluado, no solo en los datos de entrenamiento), se separan los datos por tratamiento aplicado, observando que el tamaño de los grupos generados es más homogéneo comparado al análisis realizado con la separación inicial (en datos de entrenamiento y de testeo). En total, existen 707 casos en donde el PIB real cae por debajo de su media histórica, 969 casos bajo los cuales el IPC cae por debajo de su valor medio y 835 casos de control en donde cada variable creció o permaneció invariante con respecto a sus respectivas medias históricas. Dado que la separación de los grupos no implica desafíos de tamaño ni para los grupos de tratamiento ni para el grupo de control, se puede utilizar los nuevos tratamientos especificados con Conversion Uplift Modeling.

Posteriormente, los datos se dividen de acuerdo a las respuestas de cada política expansiva. Se genera un Bosque Aleatorio con 100 árboles en cada uno de estos subconjunto para caracterizar la implementación de políticas expansivas de acuerdo a variables macroeconómicas rezagadas a través de la importancia otorgada por los bosques generados. Al igual que en el estudio de la segunda fase, se considera un número mínimo de 10 observaciones por nodo y la selección aleatoria de cuatro variables para la partición de los datos. En este caso las variable de respuesta son de naturaleza binaria y corresponden a la aplicación exclusiva de alguna política expansiva (FE, FEME o ME). La Figura 5.4 muestra los resultados asociados a las políticas expansivas, en conjunto con la variable binaria “Expansionary” que resume




Figura 5.4: Importancia de las variables rezagadas sobre las políticas expansivas de acuerdo al modelo de Bosque Aleatorio con 100 árboles.

la aplicación de por lo menos una política económica expansiva (1 si se aplica alguna y 0 en caso contrario). Se puede observar que las políticas expansivas dependen fuertemente de la economía y del período bajo el cual se apliquen. El resto de variables son relativamente menos importantes, y su rendimiento o impacto es similar entre cada uno de los modelos generados. Así, la separación de las variables correspondientes al IPC y al PIB real como tratamientos con respecto al resto de covariables macroeconómicas no es tan explícita como en la formulación de los efectos de tratamientos sobre el crecimiento económico. Sin embargo, la teoría macroeconómica y la importancia que tienen estas variables en la política y en sectores económicos hace que su análisis como posibles efectos de las políticas expansivas sea interesante.

5.5 Predicciones de efectos causales para las políticas económicas expansivas

Basándose en los algoritmos multitratamiento correspondientes al enfoque de Conversion Uplift Modeling, se generan predicciones sobre los mismos datos de entrenamiento, de manera de poder caracterizar el ITE sobre las políticas económicas expansivas según la variación porcentual del Índice de Precios al Consumo y del Producto Interno Bruto. La Figura 5.5 muestra las curvas Qini de Ingresos (*Revenue Qini Curve*) y la de Resultados Esperados (*Expected Outcome Curve*) para las diferentes políticas expansivas aplicadas previamente.

Con respecto a las curvas de Qini, se observa que la mayoría de modelos (a excepción del Enfoque de Modelos Separados con regresión logística como *base learner*) obtienen un mejor desempeño que el caso de asignación aleatoria de tratamientos en términos del uplift incre-




Figura 5.5: Curvas de Qini y de Resultado Esperado sobre variaciones porcentuales de las políticas expansivas mediante Conversion Uplift Modeling. (a) Curva de Qini para política fiscal expansiva pura. (b) Curva de Qini para política expansiva mixta. (c) Curva de Qini para política monetaria expansiva pura. (d) Curva de *Expected Outcome* para política fiscal expansiva pura. (e) Curva de *Expected Outcome* para política expansiva mixta. (f) Curva de *Expected Outcome* para política monetaria expansiva pura.

mental generado. Las variaciones del PIB real y del IPC del último trimestre logran explicar de manera relevante la aplicación de políticas monetarias expansivas puras en el 20 % de las observaciones y la aplicación de políticas fiscales puras y mixtas expansivas hasta en un 60 % de las observaciones. En particular, se identifica que el Enfoque de Modelos Separados con Bosque Aleatorio presentan un mejor desempeño que otros modelos, y adicionalmente presenta mayor magnitudes de uplift cuando la variable de respuesta corresponde a las políticas expansivas mixtas. En contraste con el enfoque de Revenue Uplift Modeling, en estos modelos de respuesta binaria las políticas expansivas empiezan a experimentar decaimientos en el uplift a partir del sexto decil, lo que implica que los cambios porcentuales en el PIB y en el IPC empiezan a impactar de manera negativa en la implementación de las políticas expansivas. Más aún, el uplift en los casos de políticas fiscales expansivas puras terminan siendo negativos cuando se considera el total de observaciones, lo que limita la relevancia de los efectos causales capturados bajo estos métodos de uplift modeling.

Analizando las curvas de Resultado Esperado, también se logra observar que la variación porcentual rezagada del IPC y del crecimiento económico ejerce un efecto causal sobre las políticas expansivas. Las caídas del PIB real y del Índice de Precios al Consumidor por debajo de sus respectivas medias históricas logran generar de manera separada efectos significativos sobre las políticas monetarias expansivas puras hasta en un 20 % de las observaciones, y predecir uplifts importantes sobre las políticas fiscales puras y mixtas expansivas hasta en un 60 % del total de datos de entrenamiento. En este caso, el Enfoque de Modelos Separados con Bosque Aleatorio como *base learner* (SMA rf) destaca una vez más por presentar mayores predicciones de uplift en todas las variables de respuesta binaria, con especial énfasis en la aplicación de políticas expansivas mixtas.

La Figura 5.6 muestra la proporción promedio acumulada de tratamientos óptimos de cada decil para cada una de las variables de respuesta correspondientes a las políticas económicas expansivas. Con respecto a las políticas fiscales expansivas puras, se observa que los tratamientos distintos del grupo de control fueron aplicados en 72.239 % de las observaciones, y que el decrecimiento del IPC explica el 32,464 % del uso de este tipo de política económica. Este último tratamiento, a su vez, se encuentra presente mayoritariamente en los deciles más altos, por lo que se afirma que la caída en el Índice de Precios al Consumidor explica de mejor manera la aplicación de una política fiscal expansiva pura, seguida de una caída en el PIB (en este caso, la caída conjunta de las variables de tratamiento falla en explicar de manera significativa a esta política). Con respecto a las políticas expansivas mixtas, el 91,210 % de las observaciones tienen asignado un tratamiento distinto al de grupo de control, y en particular un 50,931 % de las observaciones tienen como tratamiento óptimo la caída conjunta del PIB y del IPC. Es claro que este tipo de política puede llegar a ser ex-

plicada significativamente por un decrecimiento económico y una caída general de los precios ya que este tratamiento está presente en la mayoría de deciles con respuestas incrementales de mayor magnitud, así como en el total de observaciones del conjunto de datos de entrenamiento. De acuerdo a los datos correspondientes a la aplicación de una política monetaria expansiva, se observa que el 90,792 % de las observaciones tienen un tratamiento óptimo distinto al control, y en un 39 % de las observaciones se asignó un tratamiento mixto bajo el cual decrecen tanto el PIB como el IPC (siendo este tratamiento el mayormente aplicado para obtener uplifts sobre esta variable de respuesta). En este caso, no existe una preferencia por algún tratamiento en específico, ya que el comportamiento es similar en cada uno de los deciles (aunque la aplicación conjunta de caídas en el PIB y en el IPC se hace más relevante a medida que se agregan observaciones).

Para finalizar esta sección, y en general este capítulo, los resultados indican que los fenómenos asociados con los ciclos económicos tienen un impacto diferente sobre las políticas económicas de los países estudiados. Las caídas en el Índice de Precios al Consumidor promueven una mayor expansión del gasto general del gobierno, mientras que la política monetaria expansiva pura es justificada levemente por el comportamiento tanto del PIB real como del IPC, sin tener una preferencia por alguna de estas variables. No obstante, la aplicación conjunta de políticas económicas expansivas incorpora de manera significativa a los cambios que ocurrieron con respecto al nivel de inflación y al crecimiento económico durante el trimestre pasado.




Figura 5.6: Porcentaje promedio acumulado de los tratamientos óptimos basados en el PIB y en el IPC por decil. (a) Porcentaje promedio acumulado para política fiscal expansiva pura. (a) Porcentaje promedio acumulado para política expansiva mixta. (a) Porcentaje promedio acumulado para política monetaria expansiva pura.

Capítulo 6

Conclusiones y Recomendaciones

El Uplift Modeling se ha generado con el motivo de predecir la diferencia entre los resultados potenciales de varios experimentos y de datos observacionales, y ha sido aplicado en múltiples áreas que involucran tanto la literatura como la industria. Esta investigación se enfocó en el uso de algoritmos de machine learning para capturar el uplift incremental sobre el crecimiento económico y la aplicación de políticas económicas expansivas sobre un conjunto de países pertenecientes a la OCDE. Para ello, se estableció un marco de referencia de doble causalidad intertemporal con datos macroeconómicos de acceso público.

Con respecto al conjunto de datos de panel analizado, se observó un comportamiento heterogéneo sobre el PIB real (el cual da fuertes indicios del crecimiento económico de un país). En general, se percibió un crecimiento de la producción de bienes y servicios, lo cual estuvo acompañado de un aumento en el gasto fiscal y una leve disminución en las tasas de interés de largo plazo. Más aún, se estableció previamente la hipótesis de una relación entre la aplicación de políticas económicas y el crecimiento económicos de los países.

De acuerdo a la generación de un modelo de Bosque Aleatorio para analizar el comportamiento de las respuestas a las covariables de cada etapa del modelo propuesto, los resultados indicaron que el crecimiento económico está caracterizado en gran medida por el consumo privado y las exportaciones de bienes y servicios de las economías estudiadas. Este mismo modelo se aplicó sobre las políticas expansivas, revelando que la aplicación de estas se ve fuertemente influenciada por el país y el período en el que se genere.

A través de curvas de uplift incremental y de uplift modificadas, se evidenció efectos causales positivos sobre el crecimiento económico cuyo efecto correspondía a la aplicación de las políticas económicas expansivas. Esto fue capturado a través de los modelos de Bosques Causales, Bosques de Selección Contextual de Tratamiento, Bosques de Diferencia en Resultados y el Enfoque de Modelos Separados con Bosque Aleatorio, demostrando su aplicabilidad para todas las economías analizadas. Del total de observaciones en el conjunto de datos de

entrenamiento, las predicciones de los modelos asignaron mayoritariamente a la aplicación de políticas fiscales expansivas puras como causas del crecimiento económico en los países, seguidas de las políticas expansivas mixtas y de las políticas monetarias expansivas puras. Adicionalmente, los mayores uplift de este conjunto de datos fueron explicados en su mayoría por la aplicación conjunta de políticas fiscales y monetarias expansivas.

Se utilizaron las mismas métricas de evaluación causal para modelar el efecto individual de los tratamientos (ITE) sobre las políticas expansivas definidas previamente de acuerdo a las variaciones porcentuales en el IPC y en el PIB real experimentadas durante el trimestre pasado (siendo así causas con un período de rezago). De acuerdo con los resultados, el efecto causal encontrado se diluyó a medida que se analizó todo el conjunto de datos de entrenamiento, y particularmente se presentaron respuestas poco favorables bajo la métrica asociada a la curva de Qini. No obstante, destacó la respuesta causal sobre la aplicación conjunta de políticas fiscales y monetarias expansivas a estas variables de tratamiento, intuitivo así una sensibilidad al ciclo económico de los países. Los efectos causales fueron capturados en mayor medida bajo el Enfoque de Modelos Separados con Bosque Aleatorio como *base learner*, tanto en la curva de Qini como en la de Resultado Esperado. De acuerdo con la proporción acumulada de tratamientos entre los modelos aplicados, se observó que la política fiscal expansiva pura respondía preferentemente a las caídas de los precios de los bienes y servicios en todos los deciles, y que los efectos causales eran significativamente mayores bajo la aplicación conjunta de políticas expansivas cuando se consideraban los efectos rezagados del crecimiento económico y del Índice de Precios al Consumidor a la vez. Los uplifts de las políticas monetarias expansivas puras fueron limitados, y no respondían de manera importante al ciclo económico experimentado en el período anterior por parte de los países analizados.

La generación de múltiples tratamientos binarios puede llegar a diluir la información respecto al comportamiento de las variables de respuesta, al encasillar los efectos causales en un conjunto de rangos previamente determinados (ignorando así posibles dinámicas que pueden existir en estudios observacionales). Futuras investigaciones deben tratar con este desafío bajo la aplicación de tratamientos de naturaleza continua para capturar efectos causales de mayor magnitud sobre el crecimiento económico de los países. Además, se sugiere la aplicación de nuevos métodos de uplift modeling para poder validar las respuestas generadas en el marco de referencia propuesto, en conjunto con incentivar el uso de modelos causales para ampliar el estudio sobre fenómenos de índole económica, ya que actualmente esta aplicación se encuentra limitada en términos de investigación con machine learning y tiene potencial en términos del impacto que puede llegar a tener en múltiples relaciones económicas alrededor del mundo.

Referencias

- Amiri, A. and Gerdtham, U.-G. (2012). Granger Causality Between Exports, Imports and GDP in France: Evidence from Using Geostatistical Models. *Economic Research Guardian*, 2(1):43–59.
- Athey, S. and Imbens, G. W. (2019). Machine learning methods that economists should know about. *Annual Review of Economics*, 11(1):685–725.
- Balk, B. and Reich, U.-P. (2008). Additivity of national accounts reconsidered. *Journal of Economic and Social Measurement*, 33:165–178.
- Beaudreau, B. C. (2010). On the methodology of energy-gdp granger causality tests. *Energy*, 35(9):3535–3539.
- Becher, M. and Krol, J. (2020). Multiple treatments for uplift modeling. <https://github.com/charlespwd/Matthias2193/APA>.
- Dempster, A. P. (1990). Causality and statistics. *Journal of Statistical Planning and Inference*, 25:261–278.
- Devriendt, F., Moldovan, D., and Verbeke, W. (2018). A literature survey and experimental evaluation of the state-of-the-art in uplift modeling: A stepping stone toward the development of prescriptive analytics. *Big Data*, 6(1):13–41.
- Dietterich, T. G. (2000). Ensemble methods in machine learning. In *Multiple Classifier Systems*, pages 1–15, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Granger, C. (1988). Causality, cointegration, and control. *Journal of Economic Dynamics and Control*, 12(2):551–559.
- Gubela, R. and Lessmann, S. (2020). Uplift forest for multiple treatments and continuous outcomes.

- Gubela, R., Lessmann, S., Haupt, J., Baumann, A., Radmer, T., and Gebert, F. (2017). Revenue uplift modeling.
- Gutierrez, P. and Gérardy, J.-Y. (2016). Causal inference and uplift modelling: A review of the literature. In *PAPIs*.
- Holland, P. W. (1986). Statistics and causal inference. *Journal of the American Statistical Association*, 81(396):945–960.
- Kalaitzidakis, P., Mamuneas, T. P., Savvides, A., and Stengos, T. (2001). Measures of human capital and nonlinearities in economic growth. *Journal of Economic Growth*, 6(3):229–254.
- Lo, V. and Pachamanova, D. (2015). From predictive uplift modeling to prescriptive uplift analytics: A practical approach to treatment optimization while accounting for estimation risk. *Journal of Marketing Analytics*, 3:79–95.
- Luetkepohl, H. and Xu, F. (2009). The role of the log transformation in forecasting economic variables. *Empirical Economics*, 42.
- Mitchell, J., Smith, R. J., Weale, M. R., Wright, S., and Salazar, E. L. (2005). An Indicator of Monthly GDP and an Early Estimate of Quarterly GDP Growth. *The Economic Journal*, 115(501):F108–F129.
- Olaya, D., Coussement, K., and Verbeke, W. (2020a). A survey and benchmarking study of multitreatment uplift modeling. *Data Mining and Knowledge Discovery*, 34.
- Olaya, D., Vásquez, J., Maldonado, S., Miranda, J., and Verbeke, W. (2020b). Uplift modeling for preventing student dropout in higher education. *Decision Support Systems*, 134:113320.
- Radcliffe, N. (2007). Using control groups to target on predicted lift: Building and assessing uplift model. *Direct Marketing Analytics Journal*, pages 14–21.
- Rombaut, E. and Guerry, M.-A. (2019). The effectiveness of employee retention through an uplift modeling approach. *International Journal of Manpower*, ahead-of-print.
- Rosenbaum, P. R. and Rubin, D. B. (1983). The central role of the propensity score in observational studies for causal effects. *Biometrika*, 70(1):41–55.
- Roush, J., Siopes, K., and Hu, G. (2017). Predicting gross domestic product using autoregressive models. pages 317–322.

- Rubin, D. (1972). Estimating causal effects of treatments in experimental and observational studies. *ETS Research Bulletin Series*, 1972(2):i–31.
- Rzepakowski, P. and Jaroszewicz, S. (2012). Uplift modeling in direct marketing. *Journal of telecommunications and information technology*, pages 43–50.
- Shojaie, A. and Fox, E. B. (2022). Granger causality: A review and recent advances. *Annual Review of Statistics and Its Application*, 9(1):289–319.
- Wager, S. and Athey, S. (2018). Estimation and inference of heterogeneous treatment effects using random forests. *Journal of the American Statistical Association*, 113(523):1228–1242.
- Yuan, Y., Wu, L., and Zhang, X. (2021). Gini-impurity index analysis. *IEEE Transactions on Information Forensics and Security*, 16:3154–3169.
- Zhao, Y., Fang, X., and Simchi-Levi, D. (2017). *Uplift Modeling with Multiple Treatments and General Response Types*, pages 588–596.