*Elasticidades de los combustibles fósiles en México**

Elasticities of fossil fuels in Mexico

Journal of Economic Literature (JEL):
JEL: Q41, Q47, C22, H23, Q43

Palabras clave:
Combustibles fósiles
Elasticidades
pronósticos
impuestos

Keywords:
Fossil fuels
elasticity
forecasting
taxes

Fecha de recepción:
13 de octubre de 2021
Fecha de aceptación:
31 de marzo de 2022

Carlos Fernando Alkaid Castro Hernández
UAM Xochimilco
carlos_castroh@hacienda.gob.mx

Montserrat Colinas Picazo
montserrat_colinas@hacienda.gob.mx

Adán Enrique García Ramos
adan_garcia@hacienda.gob.mx

José Salvador Zamora Muñoz
jose_zamoramu@hacienda.gob.mx

Resumen

Convencionalmente, el crecimiento económico implica presión sobre los recursos materiales y energéticos del planeta, por consiguiente, también involucra contaminación y degradación del medio ambiente. En este marco, las emisiones de dióxido de carbono de origen antropógeno, por la quema de combustibles fósiles, es una de las principales causas de gases de efecto invernadero que han contribuido al calentamiento global y en consecuencia a los fenómenos relacionados con el cambio climático. Por otra parte, para afrontar las acciones necesarias que implican las metas de reducción de emisiones para el año 2030, es necesario conocer el sentido y magnitud de la respuesta en la demanda de combustibles en torno a la evolución de precios y del ingreso nacional.

El presente trabajo, mediante la metodología de corrección de errores propuesta por Engle-Granger devela, a largo y corto plazo, las relaciones mencionadas para los siguientes combustibles fósiles: gasolina regular, gasolina premium, diésel, turbosina, gas LP, queroseno, combustóleo, y gas natural; de forma complementaría se evalúa si tanto la implementación del Impuesto Especial a combustibles fósiles, a partir de 2014, como la política de liberación de precios influyeron en el comportamiento del

* Este documento fue preparado como parte de los trabajos de investigación dentro de la Unidad de Política de Ingresos No Tributarios (UPINT) de la Secretaría de Hacienda y Crédito Público (SHCP), con la finalidad de propiciar el intercambio y debate de ideas. El contenido de este trabajo, así como las conclusiones que de ellos se derivan, son responsabilidad exclusiva de los autores y no reflejan necesariamente las de la SHCP. Los autores agradecen a la Mtra. Karina Ramírez Arras, Titular de la UPINT, por las facilidades para elaborar el presente trabajo.

© 2022 Universidad Nacional Autónoma de México, Facultad de Economía. Este es un artículo Open Access bajo la licencia CC BY-NC-ND (http://creativecommons.org/licenses/by-nc-nd/4.0/).

consumidor medio a través de cambios estructurales en las demandas correspondientes. Finalmente, para brindar un marco base para la evaluación de políticas públicas, se realiza el pronóstico hasta el año 2030 de series las series de demanda a través del ajuste de modelos ARIMA y Redes Neuronales.

Abstract

Conventionally, economic growth implies pressure on the planet's material and energy resources, consequently, it also involves pollution and environmental degradation. In this framework, carbon dioxide emissions of anthropogenic origin, due to the burning of fossil fuels, is one of the main causes of greenhouse gases that have contributed to global warming and consequently to phenomena related to climate change. On the other hand, to face the necessary actions implied by the emission reduction goals for the year 2030, it is necessary to know the meaning and magnitude of the response in the demand for fuels around the evolution of prices and national income.

The present work, through the error correction methodology proposed by Engle-Granger, reveals, in the long and short term, the relationships mentioned for the following fossil fuels: regular gasoline, premium gasoline, diesel, jet fuel, LP gas, kerosene, fuel oil, and natural gas; In a complementary manner, it is evaluated whether both the implementation of the Special Tax on fossil fuels, as of 2014, and the price release policy influenced the behavior of the average consumer through structural changes in the corresponding demands. Finally, to provide a base framework for the evaluation of public policies, the forecast until the year 2030 of series of demand series is made through the adjustment of ARIMA and Neural Networks models.

Introducción

De acuerdo con Aguilar Ibarra, A., *et al.* (2010), históricamente el crecimiento económico se ha apoyado en el uso de recursos naturales, en este sentido Martínez Alier, J. y Roca Jusmet, J. (2000) señalan que habitualmente la relación aumentos de PIB implican mayor uso de energía y de materiales y por consiguiente conduce a degradación ambiental. Sin embargo, la relación no es igual entre distintas economías con diferentes niveles de desarrollo.

Conforme a la hipótesis planteada a través de la de la Curva Ambiental de Kuznets, la relación entre el nivel de ingreso per cápita y el deterioro de la calidad del medio ambiente se puede representar por una curva con forma de "U" invertida; esta hipótesis yace bajo el argumento de que mayores niveles de desarrollo implican un cambio en la estructura de la economía, donde los procesos de producción se basan en tecnologías más eficientes que ayudan a conservar los recursos naturales, y de esta manera, a reducir el deterioro del medio ambiente, es decir, durante las primeras etapas de desarrollo de un país el incremento en el ingreso ocasionará, hasta un cierto nivel de desarrollo, aumentos en los niveles de contaminación, una vez alcanzado éste punto, la relación entre ingresos y contaminación se vuelve negativa (Al-mulali, U. *et al.,* 2015).[1]

1 De acuerdo con Martínez Alier, J. y Roca Jusmet, J. (2000), la principal controversia en torno a la Curva Ambiental de Kuznets es que, conforme con su planteamiento, la única vía para conseguir un medio ambiente decente en la mayoría de los países es que se hagan ricos.

Con una muestra de ocho países seleccionados, cuatro de ingresos altos (Estados Unidos, Alemania, Reino Unido y Japón) y cuatro de ingresos medios (Brasil, China, India y México), se puede mostrar la evolución entre la relación PIB per cápita y emisiones CO_2 per cápita. Para 2018, Reino Unido (RU) y Estados Unidos (USA) muestran reducciones de 54.0 y 27.8% respecto de punto máximo de emisiones per cápita en 1970; Alemania (DEU) muestra una reducción de 28.8% respecto de 1980; y Japón (JPN) una reducción de 6.3% respecto de su punto máximo en el año 2000. Para los países seleccionados de ingresos medios, como China (CHN) e India (IND), la relación PIB per cápita y emisiones per cápita muestra ser positivas, mientras que para Brasil (BRA) y México (MEX) comienzan a mostrar signos de tendencia negativas, lo que sugiere mayor eficiencia ambiental en la generación de sus ingresos. Pese a ello, China, India, Brasil y México ha venido acompañado de mayores niveles de emisiones, con incrementos que van de 286.8, 179.4, 53.5 y 17.3% entre 1960 y 2018, respectivamente.

Figura 1. Emisiones CO_2 países de ingresos altos
(PIB corriente y emisiones per cápita, anual)

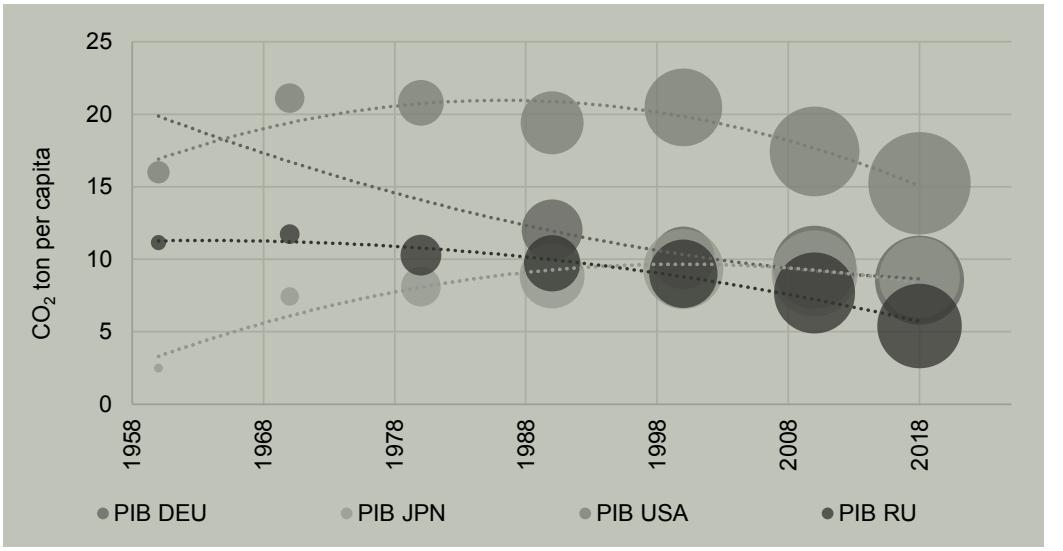

Fuente: elaboración propia con datos del Banco Mundial (2021).

Figura 2. Emisiones CO_2 países de ingresos medios
(PIB corriente y emisiones per cápita, anual)

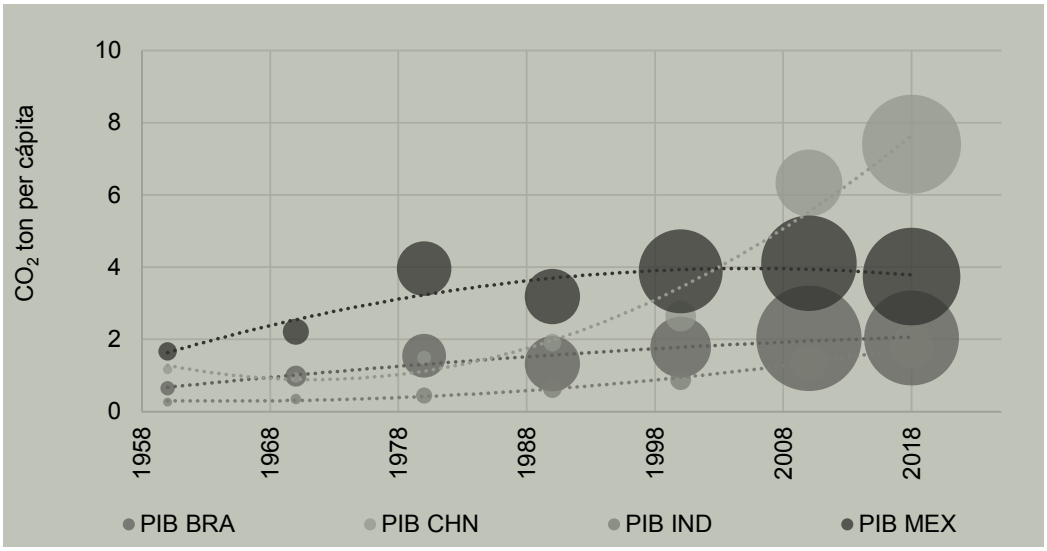

Fuente: elaboración propia con datos del Banco Mundial (2021).

A nivel global, es importante destacar, que desde el 2005 los países de ingreso medio han rebasado el total de emisiones anuales sobre los países de ingreso alto, mientras que los países de ingreso bajos mantienen niveles bajos y constantes de emisiones.

Figura 3. Emisiones mundiales de CO_2 por nivel de ingreso
(Millones de toneladas, anuales)

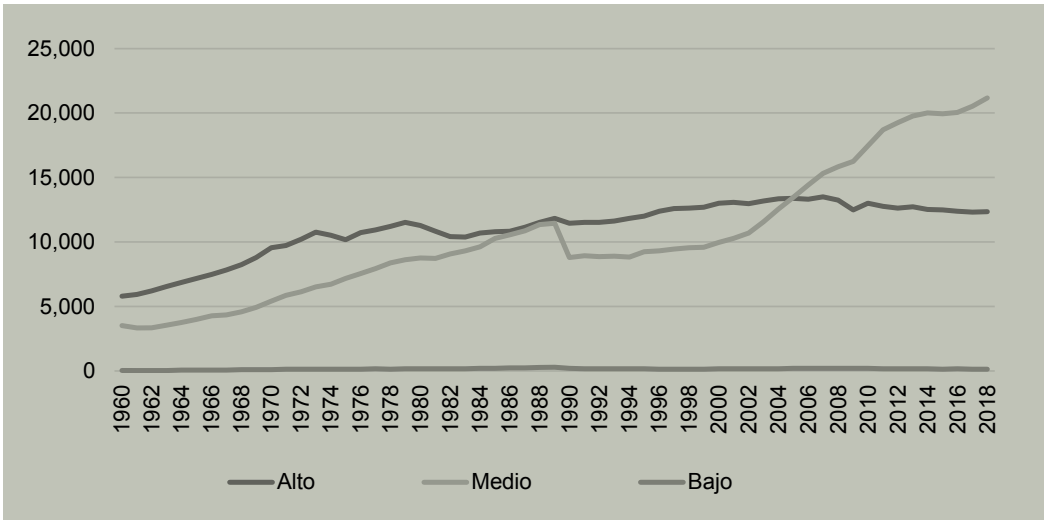

Fuente: elaboración propia con datos del Banco Mundial (2021).

En este sentido, el Panel Intergubernamental Para el Cambio Climático (IPCC por sus siglas inglés), ha señalado que el dióxido de carbono de origen antropogénico es el gas de efecto invernadero más importante, por lo que es uno de los principales factores que han contribuido al calentamiento global[2] y, por consiguiente, del cambio climático. Por lo que, en el marco del Acuerdo de París, los países firmantes se han comprometido a mantener el aumento de la temperatura media mundial muy por debajo de 2°C y de limitar el aumento de la temperatura a 1.5°C con respecto a los niveles preindustriales y a reducir rápidamente las emisiones de gases de efecto invernadero, para alcanzar un equilibrio entre las emisiones antropógenas para 2050; reconociendo que ello reduciría considerablemente los riesgos y los efectos del cambio climático.

De acuerdo con el Balance Nacional de Energía (SENER, 2021) para el caso de México, el consumo total de energía ha crecido 37.5% entre 1990 y 2019, encabezado por el crecimiento en el consumo de electricidad (208.5%), gasolinas y naftas (53.4%), diésel (46.9%). Lo que, en términos de emisiones se ha traducido en un aumento de 76.4%, pasando de 268 millones de toneladas de CO_2 (Mton CO_2) emitidas en 1990 a 472 Mton CO_2 en 2018.

Figura 4. Consumo total de energía secundaria por combustible (petajoules)

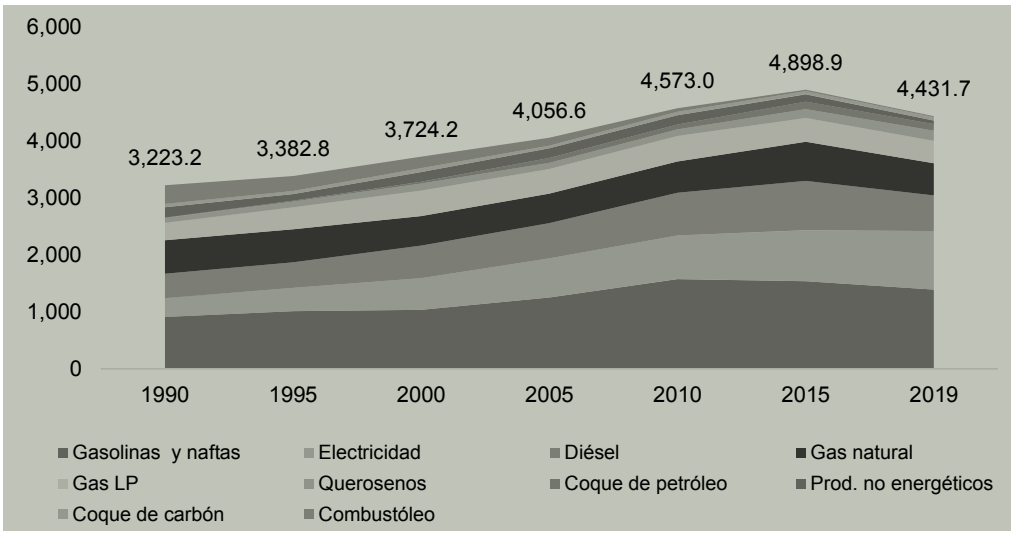

1/Productos no energéticos: Asfaltos, lubricantes, grasas, parafinas, etano.
Fuente: elaboración propia con datos del Balance Nacional de Energía, SENER.

2 La temperatura global de la superficie en las dos primeras décadas del siglo XXI (2001-2020) fue 0.99 °C (entre 0.84-1.10 °C) más alta que la de 1850-1909.

Por otra parte, para regular el consumo de combustibles fósiles en el país, en 2014, se implementó el Impuesto Especial sobre Producción y Servicios a Combustibles Fósiles (IEPS CO_2), el cual representa uno de los principales instrumentos de política pública para mejorar el bienestar de la población y a la vez permite ser una fuente de ingresos del gobierno. La regulación del consumo de combustibles fósiles a través IEPS CO_2 se basa en el principio fundamental de "quien contamina paga" y cuyo objetivo es internalizar el costo social de producir emisiones contaminantes, y con ello, inducir a la adopción de tecnologías más limpias para mejorar la calidad del aire, reducir enfermedades respiratorias, así como gastos en salud pública (DOF, 2013).

Además del IEPS CO_2, para favorecer y robustecer la competencia en el mercado nacional de hidrocarburos, el Gobierno mexicano fue dejando de establecer precios máximos al gas natural, gas LP, gasolinas regular y premium, así como al diésel, lo que se traduciría en menores precios, y, por consiguiente, se podría esperar incrementos en la demanda de combustibles.

Si bien, una característica del IEPS CO_2 es que se incorpora en la enajenación o importación del combustible (*midstream*), su monto total se traslada completamente (*pass-through*) en el precio del combustible a los consumidores finales (*downstream*), por lo que, es en el comportamiento de éstos últimos donde se busca incida el impuesto; en este sentido, el consumo de combustibles fósiles dependerá de la elasticidad de la curva de demanda, en cuya magnitud la oferta se ajustará (ver gráfico). Además, como se vio, la demanda de combustibles fósiles también responde al crecimiento de la economía, es decir, se espera que incrementos en el ingreso generen una mayor demanda de combustibles fósiles. Para ambas respuestas de los consumidores, se espera que las elasticidades precio e ingreso sean menores en corto plazo respecto de aquellas de largo plazo, debido a la presencia de costos de ajuste y de información que retrasan su respuesta al aumento de precios o de ingresos.

Figura 5. Esquema de un impuesto por unidad sobre la curva de demanda

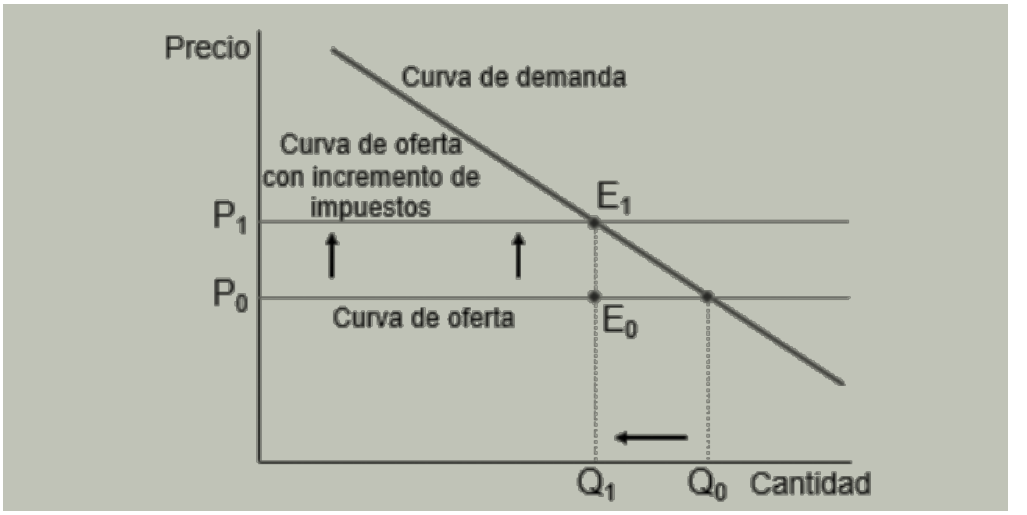

Fuente: (Stiglitz, J.E., 2000: 522).

En referencia a lo mencionado, el objetivo del presente trabajo es revelar las magnitudes de respuesta en la demanda de combustibles fósiles, en el corto y largo plazo, ante variaciones en el ingreso nacional y del precio, así como identificar si la política de precios a través de la incorporación del IEPS CO_2 y de liberación de precios dieron lugar a cambios en el comportamiento del consumidor. En específico, el presente trabajo estima la demanda de hidrocarburos en México respecto a la trayectoria de sus precios y el ingreso nacional para los siguientes combustibles fósiles: gasolina regular, gasolina premium, diésel, turbosina, gas LP, queroseno, combustóleo, y gas natural.

Para lograr tal cometido, el presente trabajo incorpora una revisión documental de 35 estudios de elasticidades precio e ingreso a largo y corto plazo de diversos energéticos (gasolinas, diésel, turbosina, gas LP y gas natural) tanto para México, como para diferentes países del mundo, con el fin de identificar sus principales resultados; a su vez, estima mediante el método de series de tiempo y de corrección de errores planteado por Engle-Granger las elasticidades precio e ingreso de la demanda; finalmente, con el fin de brindar posibles trayectorias en la demanda de combustibles fósiles al año 2030, se pronostican y se comparan sus demandas respectivas a través del ajuste de series de tiempo y redes neuronales.

A continuación, se presentan un compendio de los principales resultados de los trabajos consultados por tipo de combustible.

Revisión de estudios previos

Gasolinas

De la literatura consultada, 28 documentos comprenden estimaciones de elasticidades para las gasolinas abarcando nueve naciones de Asia, cuatro de América Latina, tres de Europa (además de la Unión Europea), una de África, y una de Oceanía (ver anexo I). A escala internacional, a largo plazo, se reportan elasticidades precio que van de -0.131 a -1.550, con un promedio de -0.055; mientras que en el corto plazo las elasticidades correspondientes se encuentran en el rango de -0.018 a -0.919 con un promedio de -0.222; en ambos casos, las elasticidades son negativas conforme a la teoría económica. Por su parte, las elasticidades ingreso a largo plazo se encuentran entre 2.682 y -0.320 con un promedio de 0.871, mientras que las correspondientes a corto plazo van entre 2.680 y 0.122 con un promedio de 0.847. Todas las elasticidades ingreso son positivas a excepción de la elasticidad a largo plazo de -0.320 de Ecuador, de acuerdo con los autores Morán Rugel, F. *et al.* (1998), este resultado se da debido a que, para ese tipo de gasolina, al ser de una calidad inferior, a medida que aumenta el ingreso, los consumidores preferirán comprar una gasolina de calidad superior.

Figura 6. Elasticidades de gasolina internacionales

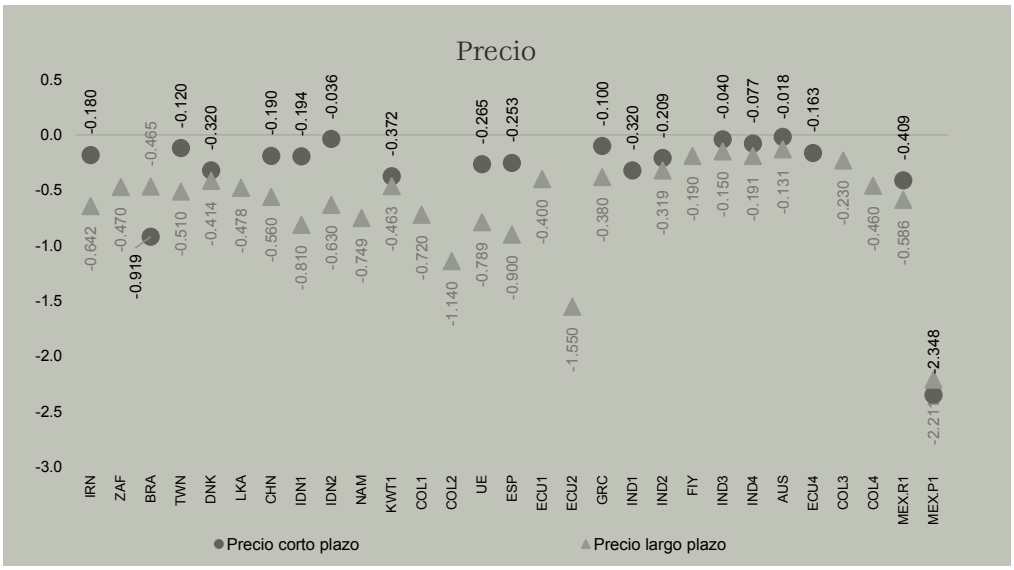

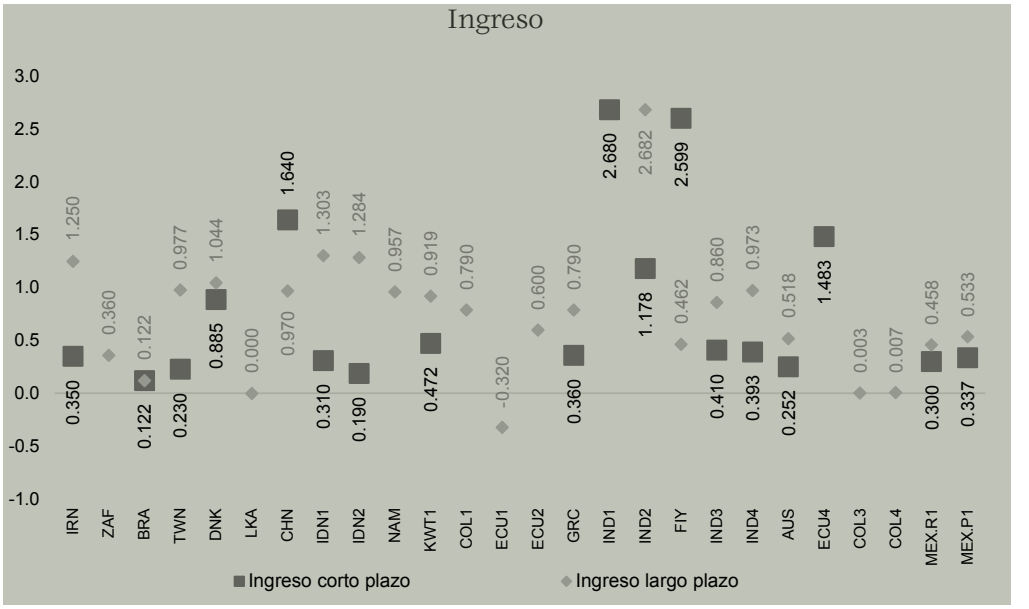

Fuente: elaboración propia con datos del cuadro 9 del Anexo I.

En el caso particular de México, se encontraron ocho estudios, de los cuales, cinco son de escala nacional y dos regionales (zona metropolitana del Valle de México y región fronteriza norte). A largo plazo, se presentan elasticidades precio negativas, que van de -0.046 a -2.530 con un promedio de -0.836. Las elasticidades ingreso van de 2.760 a 0.413 con un promedio de 1.075, todas presentan un signo positivo. En el corto plazo, las elasticidades precio, presentan valores que van de 0.001 a -0.310 con un promedio de -0.164, con un único valor positivo, aunque muy pequeño; mientras que las elasticidades ingreso presentan resultados con signo positivo que van de 0.836 a 0.050 con un promedio de 0.401.

Figura 7. Elasticidades de gasolina en México

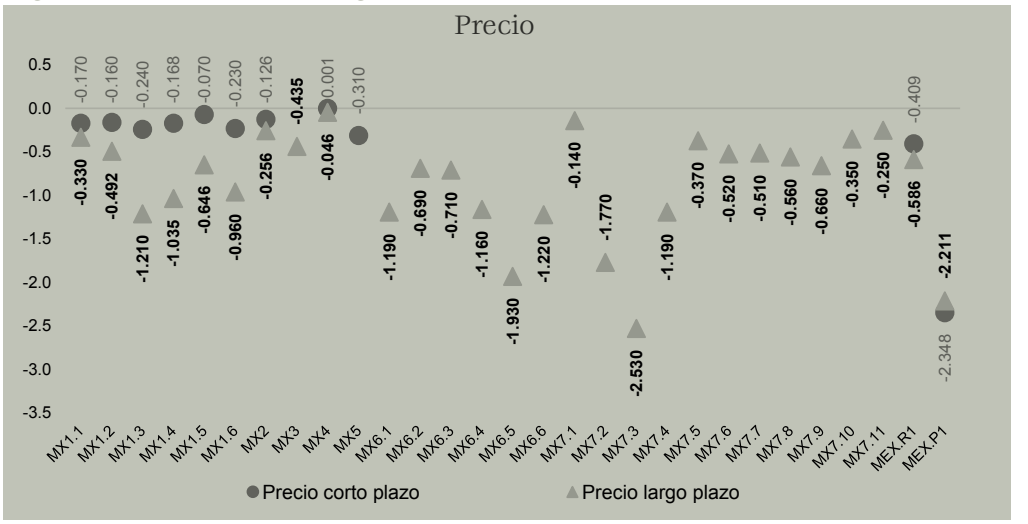

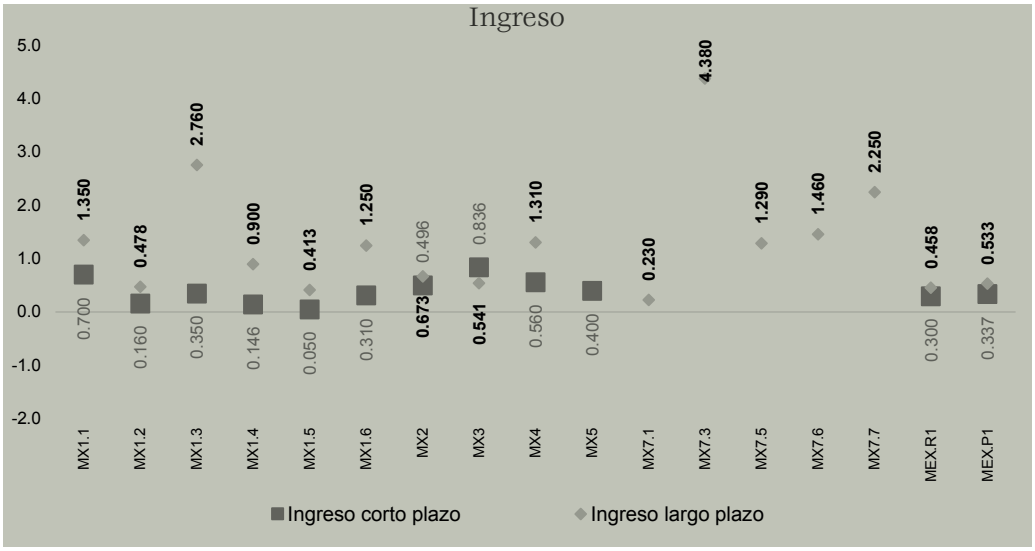

Fuente: elaboración propia con datos del cuadro 9 del Anexo I.

En referencia a las estimaciones del presente trabajo, en comparación con los resultados encontrados a nivel internacional, las elasticidades precio obtenidas a largo plazo (MEX.R1 -0.586 y MEX.P1 -2.211) y corto plazo y (MEX.R1 -0.409 y MEX.P1 -2.348) se encuentran en sintonía del resto de las elasticidades estimadas en otros países, ya que tanto en el largo como en el corto plazo se muestran resultados negativos de conformidad con la teoría económica. Aunque, en el caso de la gasolina premium (MEX.P1), resulta ser la elasticidad precio más grande, tanto para el corto y el largo plazo. Ningún otro país presenta resultados que muestren una sensibilidad tan alta al precio. En cambio, en los estudios nacionales, Sánchez, A. *et al*. (2015), presentan resultados de esta magnitud para el segundo decil. En cuanto a las elasticidades ingreso, obtenidas a largo plazo (MEX.R1 0458 y MEX.P1 0.533) y corto plazo (MEX.R1 0.300 y MEX.P1 0.337) coinciden a nivel nacional e internacional al ser positivas.

Diésel

En el caso del diésel, se encontraron nueve estudios para ocho países y para la Unión Europea; no se encontraron estudios específicos para México. En el largo plazo, las elasticidades precio van de -0.070 a -0.866 con un promedio de -0.462. Por su parte, las elasticidades ingreso presentan valores positivos que van de 2.164 a 0.543 con un promedio de 1.488. En el corto plazo, las elasticidades precio van de -0.018 a -0.385 con un promedio de -0.138. Mientras que las elasticidades ingreso, mantuvieron resultados de 2.149 a 0.420 con un promedio de 1.047. En todos los casos, las elasticidades precio e ingreso mantuvieron signos conforme a la teoría económica.

En este caso, los resultados obtenidos en las elasticidades precio a largo plazo (MEX.1 -0.066) y corto plazo (MEX.1 -0.029), muestran similitudes con los resultados obtenidos de Samimi, R. (1995), y Sa´ad, S. (2009), para Australia e Indonesia, al presentar elasticidades cercanas a cero en el corto y largo plazo. En cuanto a las elasticidades ingreso a largo plazo (MEX.1 0.860) y corto plazo (MEX.1 0.848), estas resultan ser singulares del resto al variar poco en el largo y corto plazo, como es el caso de Dahl, C. y Kurtubi (2001).

Figura 8. Elasticidades diésel

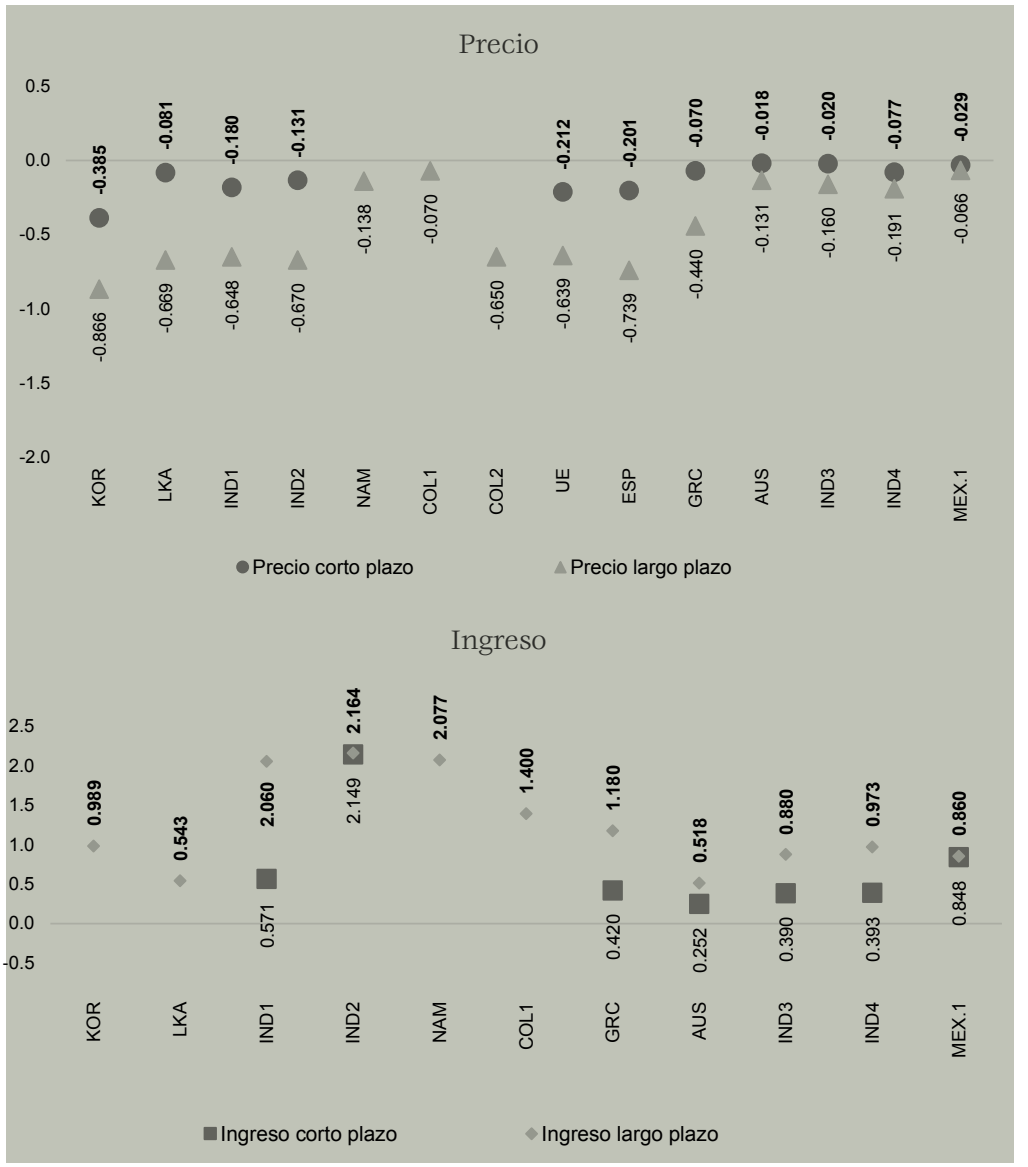

Fuente: elaboración propia con datos del cuadro 10 del Anexo I.

Gas LP

Únicamente se encontraron dos estudios en torno a las elasticidades precio-ingreso de este combustible. En ambos casos, Francos Rodríguez, M. (2006), y Sánchez, L. y Reyes, O. (2016) reportan valores muy similares, presentando valores para las elasticidades ingreso de 0.540 y 0.420; y precio de -0.164 y -0.290, respectivamente. Los datos obtenidos para el largo plazo en este trabajo (Precio: MEX.1 -0.113 e Ingreso: MEX.1 0.361) son consistentes con dichos estudios.

Gas natural

Las referencias en torno al gas natural presentan elasticidades precio de largo y corto plazo que van de -0.777 a -2.780 y de -0.046 a -0255, respectivamente. En cuanto a la elasticidad ingreso, solamente García, J.J. *et al*. (2016) presentaron un resultado de elasticidad ingreso de largo plazo de -0.37. Los resultados obtenidos en este estudio presentan elasticidades precio (LP: MEX.1, -0.007 y CP: MEX.1, -0.004) e ingreso (LP: MEX.1, 0.240 y CP: MEX.1, 0.217) resultan acordes a la teoría económica y con los estudios presentados.

Figura 9. Elasticidades gas LP y gas natural

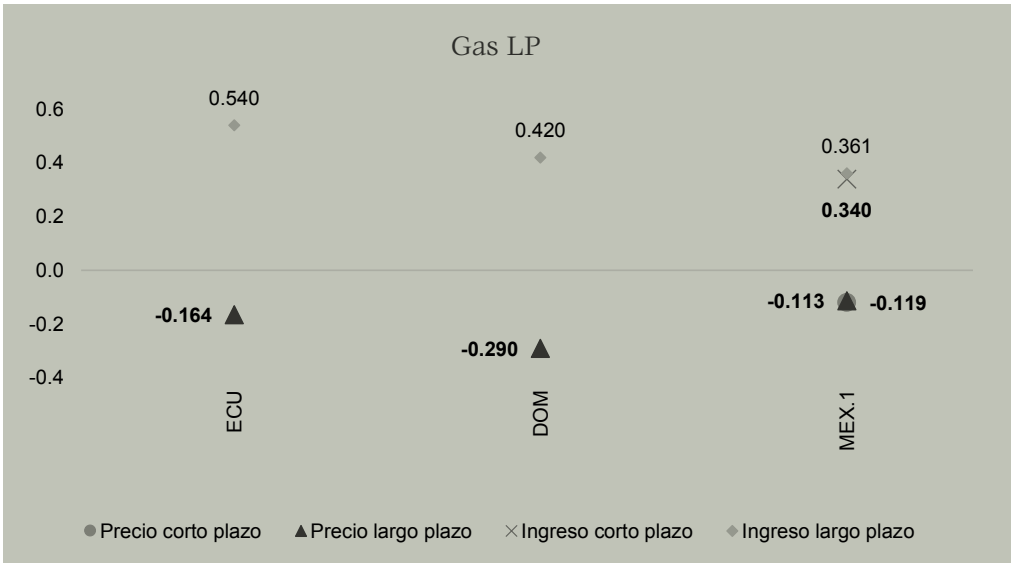

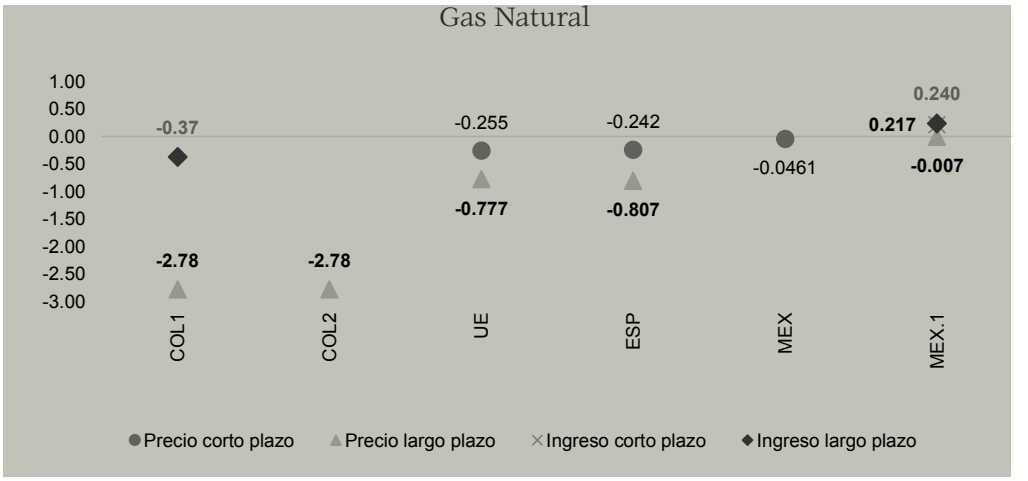

Fuente: elaboración propia con datos de los cuadros 11 y 12 del Anexo I.

Turbosina

Para el caso de la Turbosina, solo se encontró un antecedente en México de Berndt, E.R. y Botero, G. (1985), los autores reportan una elasticidad ingreso a largo plazo de -0.0004 tanto para la demanda de doméstica como internacional. Destacan los resultados obtenidos en nuestro trabajo al apuntar elasticidades precio positivas (CP: 0.053 y LP:0.048).

Petróleo

El objetivo del estudio desarrollado por Ashraf, H. *et al*. (2018), fue realizar un análisis comparativo entre China, India y Pakistán, países en vías de desarrollo. Los resultados obtenidos denotan una sensibilidad negativa al aumento de precios en el corto y largo plazo, mientras que, en el caso del ingreso se presentan elasticidades positivas en los tres países. Por su parte, el estudio de Hunt, L.C., *et al*. (1999), para el caso de Honduras, que carece de hidrocarburos y depende casi enteramente de energía hidroeléctrica para la generación de energía, en los cuales obtienen resultados similares a los obtenidos por Ashraf, H. *et al*.

Gasóleo

Para este combustible Amengual, D. y Cubas, G. (2002) y Francos Rodríguez, M. (2006), presentan para Uruguay y República Dominicana, respectivamente, encontrando resultados de elasticidad precio de -0.30 y -0.04, mientras que para la elasticidad ingreso se presentaron resultados de 1.13 y 0.8 respectivamente.

Nafta

Amengual, D. y Cubas, G. (2002), reportan para Uruguay elasticidades precio a largo plazo de -0.45 y elasticidades ingreso de 0.57.

Electricidad

Labandeira, X. *et al*. (2016), reportan elasticidades precio en el corto y largo plazo para España de -0.705 y -0.203, mientras que para la Unión Europea de -0.6 y -0215, respectivamente; por su parte, Sánchez y Reyes (2016) reportan para Ecuador con elasticidades precio e ingreso a largo plazo de -.22 y 0.509, respectivamente.

Tabla 1. Elasticidades turbosina, petróleo, gasoil, nafta y electricidad

País	Autor	Clave autor	Periodo de estimación	Tipo de datos	Elasticidad precio		Elasticidad ingreso	
					Corto plazo	Largo plazo	Corto plazo	Largo plazo
Turbosina								
México	SHCP	MEX.1	1999-2020	Tradicional	0.053	0.048	0.253	0.264
México	SHCP	MEX.2	1999-2020	Compuesto	0.042	0.038	0.250	0.264
México	Berndt, E.R. y Botero, G.	MEX (1985)	1960-1980	Series de tiempo	-	-	-	0.0004
Petróleo								
China	Ashraf, H. *et al*.	A, K, J (2018)	1971-2014	Series de tiempo	-0.18	-	1.02	-
India					-0.08	-0.96	0.00	0.07
Pakistán					-0.07	-0.30	0.04	-
Honduras	Hunt, Salgado y Thorpe	H, S, T (1999)	1971-1995	Series de tiempo	-	-0.236	-	1.578
Gasóleo								
Uruguay	Amengual, D. y Cubas, G.	A, C (2002)	1988-2001	Series de tiempo	-	-0.30	-	1.13
República Dominicana	Francos Rodríguez M.	M, F, R (2006)	1997-2006	Series de tiempo	-	-0.04	-	0.8
Nafta								
Uruguay	Amengual, D. y Cubas, G.	D, A, G, C (2002)	1988-2001	Series de tiempo	-	-0.45	-	0.57
Electricidad								
Unión Europea	Labandeira, X., *et al*.	L, L, L.a (2016)	1995-2014	Series de tiempo	-0.215	-0.6	-	-
España	Labandeira, X., *et al*.	L, L, L.b (2016)	1995-2014	Series de tiempo	-0.203	-0.705	-	-
Ecuador	Sánchez, L. y Reyes, O.	S, R (2016)	1985-2012	Series de tiempo	-	-0.22	-	0.509

Fuente: elaboración propia con datos de Berndt (1985), Ashraf, H. *et al*. (2018), Hunt. *et al* (1999), Amengual, D. y Cubas, G. (2002), Francos Rodríguez M. (2006), Labandeira, X., *et al*. (2016), y Sánchez, L y Reyes, O. (2016).

Metodología de series de tiempo

Una serie de tiempo es un conjunto de datos que se recopilan, observan o registran en intervalos de tiempo regulares (diario, semanal, trimestral, semestral, anual, etc.). Una característica propia de este tipo de datos es que, generalmente, hay dependencia entre observaciones adyacentes. Su análisis consiste en el uso de técnicas estadísticas para analizar esta dependencia, y requiere el desarrollo de modelos estocásticos y dinámicos para el modelado de estas series temporales.

En una serie de tiempo es posible observar cuatro tipos básicos de variaciones que contribuyen a los cambios observados en un periodo de tiempo, y dan a la serie su aspecto estocástico. Estos cuatro componentes son:

- **Tendencia:** Se caracteriza por patrones graduales que suelen suceder en periodos largos de tiempo y afectan su crecimiento o decrecimiento.
- **Variación estacional:** Representa su variabilidad debida a influencias de las estaciones, ya sean cambios anuales, semestrales, trimestrales.
- **Variación irregular:** Estas variaciones se debe a factores imprevisibles y aleatorios de corto plazo, por lo tanto, no es posible predecir su impacto sobre la serie de tiempo. Existen dos tipos de variación irregular: *a)* Las variaciones provocadas por acontecimientos especiales, fácilmente identificables y *b)* Variaciones aleatorias, cuyas causas no se pueden señalar en forma explícita, pero que tienden a equilibrarse al largo plazo
- **Variación cíclica:** Si después de remover la variación de la serie debido a sus componentes estacional e irregular, se siguen presentando valores de la serie por arriba y por debajo de su línea de tendencia, con una duración temporal prolongada (más de un año), se dice que la serie presenta una variación cíclica.

Existen diversos modelos estadísticos para analizar una serie de tiempo como son Modelo de Medias Móviles (MA), Modelo Autorregresivo (AR) y una combinación de ambos, conocida como Modelo Autorregresivo de Medias Móviles (ARMA), o metodología de Box-Jenkins (1970). Un modelo AR puede verse como una regresión lineal del valor actual de la serie contra uno o más de sus valores anteriores, que determinan el grado de relación o asociación del valor actual de esta serie con los valores anteriores. Si este número de valores es p, entonces se conoce como el orden del modelo autorregresivo y se denota como AR(p). En términos matemáticos queda escrito como:

$$X_t = \mu + \emptyset_1 X_{t-1} + \emptyset_2 X_{t-2} + \cdots + \emptyset_p X_{t-p} + \varepsilon_t$$

Con X_t el valor de la serie al tiempo, $t.Ø_i\ i=1,\ldots,p$ parámetros y ε_t término de error aleatorio, llamado ruido blanco y μ una constante que representa la media del modelo

Un modelo de MA es conceptualmente una regresión lineal del valor actual de la serie contra los errores (ruido blanco o choques aleatorios) de uno o más valores anteriores de la serie. Si se tiene una asociación con q de estos valores, entonces a q se le conoce también como el orden del modelo de medias móviles, y se denota como MA (q). Escrito como

$$X_t = \mu + \theta_1\epsilon_{t-1} + \theta_2\epsilon_{t-2} + \cdots + \theta_q\epsilon_{t-q} + \varepsilon_t$$

Con $Ø_i$ parámetros $i=1,\ldots,q$.

Como se mencionó, un modelo Autorregresivo de Medias Móviles involucra características de los dos modelos anteriores, por lo que su orden en la estructura autorregresiva es p y en la parte de medias móviles, q, lo que se denota como ARMA (p,q) se escribe:

$$X_t = \mu + Ø_1X_{t-1} + Ø_2X_{t-2} + \cdots + Ø_pX_{t-p} + \theta_1\epsilon_{t-1} + \theta_2\epsilon_{t-2} + \cdots + \theta_q\varepsilon_{t-q} + \varepsilon_t$$

Para implementar la metodología Box-Jenkins es necesario que la serie a modelar sea estacionaria, lo que significa que su distribución y parámetros no varían con el tiempo, concretamente, su media y varianza no cambian con el tiempo, y tampoco tiene tendencia. Una forma de transformación usual de una serie no estacionaria en estacionaria es a través de diferencias, definidas como:

$$\nabla X_t = X_t - X_{t-1};\ \nabla^2 X_t = \nabla(\nabla X_t);\ \cdots;\ \nabla^d X_t = \nabla(\nabla^{d-1}X_t)$$

Que representan las diferencias de orden 1, 2, y de orden d, en general.

Cuando la serie presenta una tendencia creciente o decreciente, es posible modelarla extendiendo un modelo ARMA que tome en cuenta esta característica, este modelo recibe el nombre de Modelo Autorregresivo Integrado de Medias Móviles (ARIMA). Si para lograr que la serie sea estacionaria es necesario diferenciarla d veces, entonces para la serie original sería un ARIMA (p,d,q) que puede escribirse como:

$$W_t = \mu + Ø_1W_{t-1} + Ø_2W_{t-2} + \cdots + Ø_pW_{t-p} + \theta_1\epsilon_{t-1} + \theta_2\epsilon_{t-2} + \cdots + \theta_q\varepsilon_{t-q} + \varepsilon_t$$

Con $W_t = {}^{d}X^t$

Si además de esta tendencia la serie presenta un comportamiento estacional, el modelo ARIMA se puede ampliar para dar origen al Modelo Autorregresivo Integrado Estacional de Medias Móviles (SARIMA). La notación para este modelo es SARIMA ((p,d,q) (P,D,Q)$_{[n]}$). Con (p,d,q) los parámetros del modelo ARIMA subyacente, y (P,D,Q) los parámetros para la parte estacional y [n] el periodo estacional o ciclo (periodo en el que la serie repite su comportamiento).

Pasos para modelar una serie de tiempo

Cuando se tiene una serie de tiempo real, es conveniente seguir una secuencia de pasos para realizar su modelación, a saber:

- Identificación del modelo. El modelo ARMA subyacente a los datos de la serie, se puede identificar a través de varias herramientas gráficas, entre las que destacan la función de autocorrelación (ACF) y la de autocorrelación parcial (PACF). Dada una serie estacionaria, el siguiente paso consiste en asociar la función de autocovarianza.

Para apoyar la identificación, se suelen utilizar los criterios de Akaike, H. (1974) y Bayesian Information Criterion (BIC). La siguiente tabla resume el comportamiento típico que deben seguir estas funciones para la identificación del modelo subyacente a los datos.

Cuadro 2. Identificación de modelo de datos

Modelo	ACF	PACF
AR (p)	Disminuye exponencialmente o con un patrón de onda sinusoide o ambos	Correlaciones significativas en los primeros p rezagos
MA (q)	Correlaciones significativas en los primeros q rezagos	Decrece exponencialmente
ARMA (p,q)	Comportamiento irregular de las primeras q autocorrelaciones y después convergencia a cero	Decrece exponencialmente

- **Ajuste del modelo.** Una vez realizada la identificación del modelo, es necesario estimar los parámetros que lo determinan, proceso que se conoce genéricamente como ajuste o estimación del modelo.
- **Diagnóstico del modelo.** En esta etapa se revisa que el modelo ajustado cumpla razonablemente con los supuestos sobre los que se construyó, de no hacerlo, es necesario regresar a la etapa de identificación para, probablemente, encontrar algún otro modelo más acorde a los datos de nuestra serie.

Regresión con series de tiempo

Las variaciones de todo tipo que sufre una serie de tiempo pueden estar influenciada por otras series relacionadas con ella. Entonces, es posible modelar esta influencia de manera similar a como se hace con un modelo de regresión estándar, solo que, en este caso tanto variable dependiente (exógena) como las variables independientes (endógenas), serán también series de tiempo. Cuando se modela, mediante una regresión lineal, la relación entre una variable endógena sin tendencia estacional y varias series exógenas, el modelo correspondiente recibe el nombre de Modelo Autorregresivo Integra-

do de Medias Móviles con Variables Exógenas (ARIMAX). Si la serie endógena posee además tendencia estacional, entonces recibe el nombre de Modelo Autorregresivo Integrado Estacional de Medias Móviles con Variables Exógenas (SARIMAX).

Estimación de los parámetros

Para realizar la estimación de todos los parámetros involucrados en cualquiera de los modelos anteriores, se parte del supuesto de que los errores tienen una distribución normal con media cero y varianza constante, σ^2, concretamente:

$$\varepsilon_t \sim N(0, \sigma^2)$$

Por lo que es posible realizar esta estimación a través de máxima verosimilitud. Además de realizar la estimación, se pueden llevar a cabo procesos de inferencia estándar de los parámetros como pruebas de hipótesis o intervalos de confianza.

Diagnóstico del modelo

Para el diagnóstico de un modelo ajustado de series de tiempo, se requiere calcular los residuos del modelo, definidos como:

$$u_t = X_t - \hat{X}_t, t = 1,2,\ldots,n$$

Con $\hat{X}_t$ el valor estimado por el modelo de la observación t de la serie. Ya que los verdaderos errores, u_t no son observables, se puede considerar a estos errores, r_t como la realización de ellos (o la observación de ellos). Entonces, todos los supuestos que se hacen sobre los errores verdaderos deben verificarse por medio de los residuos. Hay que constatar que cumplan con: Normalidad, no autocorrelación y varianza constante (homoscedasticidad).

Para comprobar normalidad es común usar la prueba Jarque-Bera o Anderson-Darling. En cuanto a autocorrelación se usa la prueba Durbin-Watson (autocorrelación de orden 1) o la prueba Q de Ljung-Box para autocorrelación de orden superior; para probar la homoscedasticidad se puede usar la prueba de Breusch-Pagan; y para heteroscedasticidad la prueba McLeod-Li.

Método de corrección de errores

Siguiendo a Gujarati, D.N. y Porter, D.C. (2009), el teorema de representación de Granger afirma que si dos variables y y x están cointegradas, la relación entre ambas se expresa como un mecanismo corrector de errores a través de los residuos, lo que permite obtener una relación de equilibrio en el corto plazo.

Suponiendo la siguiente regresión:

$$\log y_t = \beta_1 + \beta_2 \log x_t + u_t$$

Donde el término de error:

$$u_t = \log y_t - \beta_1 - \beta_2 \log x_t$$

Con el término de error es posible relacionar el comportamiento de corto plazo de con su valor de largo plazo:

$$u_t = \log y_t - \beta_1 - \beta_2 \log x_t - \beta_3 t$$

El modelo corrector de errores se expresa como:

$$\Delta \log y_t = \alpha_0 + \alpha_1 \Delta \log x_t + \alpha_2 u_{t-1} + \varepsilon_t$$

Donde ε_t es un término de error de ruido blanco y *ut-1* el valor rezagado del término de error, el cual se estima como:

$$u_{t-1} = \left(\log y_t - \widehat{\beta_2} - \widehat{\beta_2} \log x_t - \beta_3 t\right)$$

El modelo corrector de errores establece que $\Delta \log y_t$ depende de $\Delta \log x_t$ y también del término de error. Si este último es diferente de cero, el modelo no está en equilibrio.

Suponiendo que $\Delta \log x_t$ es cero y que u_{t-1} es positiva, lo que significa que $\Delta \log y_t$ está por encima de su valor de equilibrio $(\alpha_0 + \alpha_1 \Delta \log y_{t-1})$ como se espera que α_2 sea negativa, el término $\alpha_2 u_{t-1}$ es negativo, por lo tanto, $\Delta \log y_t$ será negativo, restableciendo el equilibrio, disminuyendo en el siguiente periodo a fin de corregir el error de equilibrio. Siendo este el mismo caso si u_{t-1} fuese positiva. De modo tal que, el valor absoluto de α_2 será el que determine la rapidez con la que se restablecerá el equilibrio

La metodología de Engle-Granger sugiere dos pasos para la prueba de cointegración. El primero, consiste en obtener los residuos de la ecuación cointegrante estimada por el método de Mínimos Cuadrados Ordinarios (OLS, por sus siglas en inglés); el segundo, en aplicar la prueba de raíz unitaria a los residuos, si se rechaza la hipótesis nula sobre la presencia de una raíz unitaria, existe evidencia sobre la cointegración. Esta metodología permite que los componentes de largo plazo de las variables obedezcan las restricciones de equilibrio, mientras que los componentes de corto plazo tienen una especificación dinámica flexible (Engle, R.F. y Granger C.W.J., 1987). Las etapas del método son: *(1)* Estimación de la estacionariedad de las series; (2) Estimación de la relación funcional de largo plazo de las series; (3) Pruebas de cointegración sobre los residuos; y (4) Método de corrección de errores.

Con las variables cointegradas, se demuestra la existencia de una relación equilibrio de largo plazo entre las variables, aunque es posible que en el corto plazo puedan presentar desequilibrios.

Fuentes de información

Demanda de combustibles y precios

Para estimar las elasticidades de la demanda de combustibles fósiles, se utilizó información mensual de ocho tipos de combustibles gasolina regular, gasolina premium, diésel, turbosina, gas LP, querosenos, combustóleo, y gas natural de enero de 1990 a diciembre 2019. Las fuentes de datos fueron: volumen de ventas de petrolíferos de Pemex; volumen de ventas internas de gas natural; y volumen total de importación de petrolíferos, se descargaron del Sistema de Información Energética (SIE) de la Secretaría de Energía (SENER).[3] Por su parte, el volumen de importación de gas natural se obtuvo del Prontuario Estadístico de Gas Natural de SENER[4] y del Balance Nacional de Gas Natural de las Estadísticas de gas natural y Petroquímicos de la SENER.[5] Todos los combustibles fueron convertidos de millones de barriles diarios (mbd) a consumo mensual en litros, con excepción del gas LP y del gas natural, los cuales fueron convertidos de millones de pies cúbicos millones de pies cúbicos (mmpcd) a metros cúbicos (m3), y de miles de barriles diarios (mbd) a kilogramos (kg), respectivamente.

Los precios mensuales para las gasolinas y el diésel de 1994 a 2016 se obtuvieron del SIE, de 2017 a 2020 se adquirieron de la Comisión Reguladora de Energía (CRE).[6] El precio del gas LP provienen de la Base de Datos Institucional de Pemex. Para los cuatro combustibles restantes (querosenos, combustóleo, turbosina y gas natural,) se realizó una estimación de su precio a través del volumen y el valor de ventas mensual reportados en el SIE. Todos los precios fueron deflactados a precios de 2018 a través del Índice Nacional de Precios al Consumidor (INPC) del INEGI.

Producto Interno Bruto (PIB)

Para el PIB, se realizó una aproximación mensual a través del Indicador Global de la Actividad Económica (IGAE). De acuerdo con Elizondo, R. (2012), es posible estimar el PIB mensual por medio de la construcción del logaritmo del PIB mensual al tiempo *t* como la suma entre la tasa de crecimiento del IGAE al tiempo *t* y el logaritmo del PIB rezagado un periodo. Es decir:

$$dif(\log(IGAE_t) = \log(IGAE_t) - \log(IGAE_{t-1})$$

Con la tasa de crecimiento del IGAE sólo se necesita conocer el valor inicial del logaritmo del PIB y así obtener las estimaciones subsecuentes de forma recursiva.

3 Sistema de Información de Energía (SIE): https://sie.energia.gob.mx/

4 Prontuario Estadístico de Gas Natural 2021: https://www.gob.mx/sener/articulos/prontuario-estadistico-2021-265456?state=published

5 Estadísticas de Gas Natural y Petroquímicos: https://estadisticashidrocarburos.energia.gob.mx/inicio.aspx

6 CRE, Precios de gasolinas y diésel: https://www.gob.mx/cre/articulos/precios-vigentes-de-gasolinas-y-diesel

$$\text{Primer mes del trimestre: } dif(\log(IGAE_t)) = \log(IGAE_t) - \log(IGAE_{t-1})$$

$$\text{Segundo mes del trimestre: } dif(\log(IGAE_{t+1}) = \log(IGAE_{t+1}) - \log(IGAE_t)$$

$$\text{Tercer mes del trimestre: } dif(\log(IGAE_{t+2}) = \log(IGAE_{t+2}) - \log(IGAE_{t-1})$$

Conforme a la metodología de cálculo, se utilizó el PIB trimestral constante a precios de 2013 y la serie original del IGAE mensual. Una vez obtenida la serie mensual del PIB, se realizó un cambio de base a fin de que la serie estuviese a precios de 2018 al igual que las series de precio de los combustibles.

Variables dicotómicas

Para capturar la posible incidencia de las decisiones de política económica en materia de precios de los combustibles fósiles, como son la incorporación del Impuesto Especial a los Combustibles Fósiles a partir de enero de 2014, así como las distintas fechas en que los precios de las gasolinas, el gas natural y gas LP se determinan libremente por condiciones de mercado, se incluyeron variables dicotómicas (*dummy*) para evaluar si tales decisiones influyeron en la demanda de combustibles, originando un cambio estructural en las series de datos y por lo tanto observar si existe un cambio en las elasticidades de los combustibles, las variables son las siguientes:

- D_1 = 1 para las observaciones de enero de 2014, fecha a partir de la cual se encuentra en vigor el IEPS al CO_2, a diciembre 2019.
- D_2 = 1 para las observaciones de enero 2018, fecha a partir de la cual los precios de las gasolinas se determinan libremente, a 2019.
- D_3 = 1 para las observaciones de 2015, fecha en que se detecta un salto importante en la demanda de gas natural, a 2019.
- D_4 = 1 Variable dicotómica que absorbe una perturbación atípica en la demanda en el gas LP correspondiente únicamente para el mes de abril de 2016 (ver gráfica de gas LP).
- D_5 = 1 para las observaciones de julio de 2017, fecha en que el precio de Venta de Primera Mano (VPM) del gas natural se determina mediante condiciones de mercado, a 2019.
- D_6 = 1 para las observaciones de enero de 2017, fecha en que el precio del gas LP se determina por condiciones de mercado, a 2019.

Modelo

Siguiendo a Koutsoyiannis, A. (2002) la función de demanda más utilizada en investigaciones aplicadas es la de elasticidad constante, la cual, para evitar la ilusión monetaria se expresa en términos reales mediante una función homogénea de grado cero[7] Cobb-Douglas:

7 La homogeneidad de grado cero se verifica: si $Q_x = f(P_i, P_j, Y)$; entonces $f(tP_i, tP_j, tY) = t^r Q_x$; si $r = 0$ hay ausencia de ilusión monetaria; si $r < 0$ o $r > 0$ entonces hay ilusión monetaria.

$$Q_x = \beta_0 \cdot P_i^{\beta_1} \cdot P_j^{\beta_2} \cdot Y^{\beta_3} \cdot e^{u_t}$$

Aplicando logaritmos obtenemos un modelo lineal en los parámetros (log-lineal) y por consiguiente un modelo de regresión lineal:

$$LnQ_x = Ln\,\beta_0 + \beta_1 \ln P_i + \beta_2 \ln P_j + \beta_3 \ln Y + u_t$$

Donde:

Q_i = Cantidad demandada de la mercancía i

$P_i = \frac{p_i}{p}$ Precio real de la mercancía i

$P_j = \frac{p_j}{p}$ Precio real de otra mercancía j

$Y = \frac{y}{p}$ Ingreso real

p = Índice de precios

β_1 = Elasticidad-precio de la demanda

β_2 = Elasticidad-cruzada de la demanda

β_3 = Elasticidad-ingreso de la demanda

e^{u_t} = Factor tendencial (e = base logaritmo natural)

En forma general las ecuaciones funcionales que conforman los modelos estimar, a largo y corto plazo, agrupados en modelos convencionales y con cambios estructurales se muestran a continuación:

- Convencionales: cálculo de elasticidades precio, ingreso y cruzadas entre combustibles sustitutos, empleando únicamente series de volumen precio y PIB.
- Cambios estructurales: se incorporaron variables dicotómicas (dummy) que permitan medir si han existido cambios estructurales en la demanda de combustibles fósiles a raíz de la incorporación del impuesto especial a los combustibles fósiles y de las fechas correspondientes de liberación de precios de los respectivos combustibles.

Modelos convencionales a largo plazo

$$lnVol_i = \beta_0 + \beta_1 lnPIB - \beta_2\, lnP_i + \beta_3\, lnP_{j\neq i} + u_i$$

Modelos convencionales a corto plazo

$$\Delta lnVol_i = \beta_0 + \beta_1 \Delta lnPIB - \beta_2\, \Delta lnP_i + \beta_3 \Delta\, lnP_{j\neq i} + u_{i(t-1)} + \varepsilon_i$$

Modelos con cambio estructural a largo plazo

$$lnVol_i = \beta_0 + \beta_1 D_n + \beta_2 lnPIB - \beta_3\, lnP_i + \beta_4\, lnP_{j\neq i} + \beta_5\, (D_n lnP_i) + u_i$$

Modelos con cambio estructural a corto plazo

$$\Delta lnVol_i = \beta_0 + \beta_1 D_n + \beta_3 \Delta lnPIB - \beta_4\, \Delta lnP_i + \beta_5 \Delta\, lnP_{j\neq i} + \beta_9\, (D_n \Delta lnP_i) + u_{i(t-1)} + \varepsilon_i$$

Donde:

$LnVol_i$ = corresponde al volumen en logaritmo natural del combustible i

$lnPIB$ = Logaritmo natural del PIB

lnP_i = Logaritmo natural del precio real del combustible i

$lnP_{j\neq i}$ = Logaritmo natural del precio real del combustible j, distinto a i

D_n = Variable dicotómica de política económica, con $n = 1 \ldots 6$.

u_i = termino de error a largo plazo del combustible i.

ε_i = termino de error a corto plazo del combustible i.

$i = j$ = gasolina regular, gasolina premium, diésel, turbosina, gas LP, queroseno, combustóleo y gas natural.

Resultados de los modelos

Pruebas de raíz unitaria

Para las estimaciones de las funciones de demanda de los combustibles fósiles basado en el proceso econométrico de corrección de errores de la metodología Engle-Granger, el primer paso fue realizar las pruebas de raíz unitaria, para identificar el orden de integración de las series. Dado que las series independientes muestran, en general, una tendencia creciente o decreciente y que las dependientes, además, son estacionales, se utilizaron las pruebas de hipótesis de raíz unitaria Dickey-Fuller Aumentada (ADF),[8] Kwiatkowski-Phillips-Schmidt-Shin (KPSS),[9] así como prueba Hegy. Para todas las series de volumen y precio, se realizaron las pruebas únicamente de tendencia. En el caso del PIB se muestra un cambio en su nivel, la prueba KPSS determina que el nivel cambia, pero la tendencia se mantiene. Finalmente, la prueba Hegy se utilizó para comprobar que las series dependientes, los volúmenes de estos hidrocarburos, tienen una tendencia estacional de periodo anual (12 meses), lo que resulta evidente observando sus respectivas series.

El conjunto de resultados indica que el PIB, la mayoría de la demanda de combustibles fósiles, así como sus respectivos precios,[10] son series no estacionarias de orden de integración I (1), o estacionarias en diferencias I (0).

8 Suponiendo una variable simple autorregresiva $x_t = ax_{t-1} + \varepsilon_t$, sustrayeno x_t de ambos lados, $\Delta_{xt} = (a\text{-}1)\, x_{t-1} + \varepsilon_t$; si $a > 1$, el coefciente de la variable dependiente rezagada será positivo, si $a = 1$, entonces $(a\text{-}1) = 0$; en ambos casos x_t será no estacionaría; la Ho de la prueba Dickey-Fuller es que $a = 1$, la H_a es que $a < 1$, es decir, $(a - 1) < 0$, lo que refleja un proceso estacionario. La prueba Dickey-Fuller aumentada considera la presencia de correlación serial en los residuos, por lo que incluye las suficientes variables rezagadas para remover los residuos de la correlación serial; un criterio de selección de rezagos es el de Scheartz, o por lo general, para datos mensuales con doce rezagos y cuatro rezagos para datos trimestrales.

9 En esta prueba, se parte del supuesto de que la serie es estacionaria; se asume un proceso para $y_t = \delta_t + \vartheta_t + \varepsilon_t$ con $\vartheta_t = \vartheta_{t-1} + u_t$ donde $u_t \sim iid\ (0, \sigma_u^2)$, la cual sigue una caminata aleatoria. La prueba $\sigma_u^2 = 0$ es para estacionariedad.

10 Con excepción del gas LP y combustóleo.

Tabla 3. Pruebas de raíz unitaria

Pruebas	ADF	HEGY	KPSS	Pruebas	ADF	KPSS
Hipótesis nula	Raíz unitaria		Estacionariedad	Hipótesis nula	Raíz unitaria	Estacionariedad
	P-value < 0.05	P-value < 0.05	P-value > 0.05		P-value < 0.05	P-value > 0.05
PIB	0.36	-	0.01	P Regular	0.805	0.01
V Regular	0.984	0.1	0.01	P Premium	0.79	0.01
V Premium	0.67	0.1	0.01	P Diésel	0.568	0.01
V Diésel	0.85	0.1	0.01	P Turbosina	0.436	0.01
V Turbosina	0.72	0.1	0.01	P Gas LP	0.010*	0.01
V Gas LP	0.010*	0.1	0.01	P Querosenos	0.435	0.01
V Querosenos	0.664	0.1	0.01	P Combustóleo	0.676	0.01
V Combustóleo	0.010*	0.1	0.01	P Gas Natural	0.158	0.01
V Gas Natural	0.46	0.1	0.01			

Adicionalmente, teniendo en cuenta lo mencionado por Mahadeva, L. y Robinson, P. (2009), en torno a los problemas de las pruebas de raíz en cuanto a que adolecen por tamaño de muestra y bajo poder, lo que puede conducir a cometer dos tipo de errores, rechazar una hipótesis nula verdadera (error tipo I) o aceptar una hipótesis nula siendo falsa (error tipo II); el tamaño de la prueba es la probabilidad de cometer un error tipo I, que se asocia con el nivel de significancia, es decir, si la probabilidad verdadera difiere respecto en la que en la prueba se está utilizando; por su parte, el poder de la prueba tiene una relación inversa de cometer un error tipo I, lo que influye en la probabilidad de rechazar una hipótesis nula falsa, por lo que, con una probabilidad verdadera distinta a la que se está probando, se podría concluir de forma equivocada que la variable tiene raíz unitaria.

Para evitar una posible regresión espuria y superar posibles problemas de autocorrelación y heteroscedasticidad, y por consiguiente que los términos de error pudieran estar sesgados en los modelos estimados, se utilizó el estimador Newey-West, que permite corregir los errores estándar de los parámetros estimados; Recordemos que la $var(x \pm y) = var(x) + var(y) \pm 2cov(x, y)$, y, si los errores no son independientes, estaríamos sobre o sub estimando la verdadera varianza de nuestro modelo por el doble del valor de la covarianza, por lo que, este método de corrección sirve para estimar esta varianza, y los errores estándar de los parámetros, corrigiendo por autocorrelación y heteroscedasticidad.

Coeficientes

Considerado el orden de integración de las series, el siguiente paso fue la estimación de los coeficientes de regresión para revelar las relaciones de demanda a largo plazo, posteriormente, mediante la metodología de corrección de errores se estimaron los coeficientes correspondientes a corto plazo. A continuación, se presentan las elasticidades de los modelos a largo plazo (LP) y corto plazo (CP), comenzando por los modelos convencionales seguido de los modelos con cambio estructural.

Tabla 4. Modelos convencionales

Modelos a largo plazo								
Variable independiente (PIB/Precio)	Variable dependiente (Volumen)							
	Regular	Premium	Diésel	Turbosina	Gas LP	Querosenos	Combustóleo	Gas Natural
PIB	0.458	0.533	0.86	0.264	0.361	0.272	0.755	0.24
Regular	-0.586	1.256						
Premium	0.33	-2.211						
Diésel			-0.066*					
Turbosina				0.048				
Gas LP					-0.113			-0.011*
Querosenos						0.042*		-0.039*
Combustóleo							0.388	-0.058
Gas Natural					-0.009*	0.009*	-0.127*	-0.007*
Modelos a corto plazo								
PIB	0.3	0.337	0.848	0.253	0.34	0.263	0.476	0.217
Regular	-0.409	1.413						
Premium	0.173*	-2.348						
Diésel			-0.029*					
Turbosina				0.053				
Gas LP					-0.119			-0.050*
Querosenos						0.044*		-0.040*
Combustóleo							0.151	-0.058
Gas Natural					0.929	0.012*	-0.06*	-0.004*

(*) Coeficiente no significativo.

En los modelos convencionales, para ocho combustibles analizados (gasolina regular, gasolina premium, diésel, turbosina, gas LP, queroseno, combustóleo y gas natural), las elasticidades ingreso de la demanda resultaron consistentes con la teoría económica al tener una relación positiva, tanto en el largo como en el corto plazo, así como de revelar coeficientes mayores a largo plazo respecto a los de corto plazo.

Los combustibles con mayor sensibilidad al ingreso son el diésel (0.860, LP y 0.848 CP) y el combustóleo (0.755, LP y 0.217 CP), debido a que la demanda de ambos hidrocarburos depende en mayor medida de la intensidad de la actividad económica; en contraste, el queroseno muestra elasticidades bajas (0.272, LP y 0.263 CP), debido a que generalmente es un combustible base para la producción de que turbosina y también es utilizado, en menor medida, para cocción de alimentos, alumbrado, motores, equipos de refrigeración y como insecticidas de uso doméstico (SENER, 2021). Por su parte, la elasticidad ingreso de la turbosina es baja (0.264, LP y 0.253 CP) debido a que el sector aéreo depende en gran medida de dinámicas externas, como pueden ser el crecimiento económico y competitividad monetaria del resto del mundo, esto se revela al tener en cuenta que en 2019 cerca de 44.6% de los vuelos registrados fueron vuelos internacionales (SCT, 2021).

En cuanto a las gasolinas, la gasolina premium (0.533, LP y 0.337 CP) muestra elasticidades ingreso mayores respecto a las correspondientes a la gasolina regular (0.458, LP y 0.300 CP), lo anterior podría ser señal de cambios en el parque automotriz hacia vehículos con mayores eficiencias en el uso de gasolinas.

El gas LP (0.361 LP y 0.340 CP) reporta elasticidades ingreso mayores respecto a las del gas natural (0.240, LP y 0.217 CP), lo cual puede ser reflejo de la mayor profundidad en su uso en comparación con el gas natural; de acuerdo con la Encuesta Nacional sobre el Consumo de Energéticos en Viviendas Particulares (ENCEVI) 2018, el gas LP es el combustible de mayor uso en el país para la cocción/calentamiento de alimentos con 79% del total, le sigue el uso de leña o carbón con 11%, el gas natural representa 7% (INEGI, 2018).

Respecto a las elasticidades precio, cinco combustibles muestran signo negativo conforme a la teoría económica, gasolina regular, gasolina premium, diésel, gas LP y gas natural, con elasticidades a largo plazo de -0.586, -2.211, -0.066, -0.113, -0.007, respectivamente; a corto plazo, las elasticidades estimadas fueron -0.409, -2.348, -0.029, -0.119 y 0.004, respectivamente; de estos combustibles el diésel y gas natural resultaron no significativos tanto a LP como a CP. Resaltan las elasticidades más que proporcionales de la gasolina premium, es decir, a corto plazo un incremento de 1% en el precio del combustible inducirá a una disminución de 2.348 en la demanda del hidrocarburo.

En cuanto a las elasticidades cruzadas de la demanda de las gasolinas regular y premium, en el largo plazo, un incremento de 1% en el precio de la gasolina premium, induce un incremento de 0.330 en la demanda de la gasolina regular; por su parte, un incremento de 1% en el precio de la gasolina regular, induce un incremento de 1.256 en la demanda de la gasolina premium; a corto plazo, dichas elasticidades cambian a 0.173 y 1.412, respectivamente.

Respecto, a los combustibles cuyas elasticidades precio no resultaron negativas, queroseno y combustóleo, a largo plazo las elasticidades obtenidas fueron: 0.042 y 0.388, respectivamente; mientras que en el corto plazo fueron: 0.044 y 0.151, respectivamente; las elasticidades correspondientes al queroseno resultaron no significativas. Por su parte, la explicación del signo contrario se puede encontrar en la rigidez que encuentran estos combustibles a tener sustitutos cercanos, sobre todo en el corto plazo y en periodos de alta volatilidad de precios, ejemplo de ello fue la emergencia climática del 15 al 20 de febrero de 2021, que ocasionó el frente frio No. 35 que trajo consigo bajas temperaturas en el norte y noreste del país, así como el congelamiento de ductos y el cierre de plantas de producción de gas natural en el estado de Texas, Estados Unidos (EU), generando un riesgo de déficit de capacidad de generación en las centrales eléctricas en México. Por lo que, casi la totalidad de la producción de EU fue destinada para abastecer su propia demanda, limi-

tando la exportación del insumo a territorio mexicano. Esto también ocasionó aumentos sin precedentes en el precio del gas natural. La CFE enfrentó la necesidad de comprar el hidrocarburo a altos precios adquiriendo el combustible en mercados nacionales e internacionales, así como el uso de combustibles alternos para generar electricidad (CFE, 2021).

La demanda de turbosina, como se mencionó, puede verse afectada por factores determinados internacionalmente, por lo que, su elasticidad precio no corresponde con lo predicho por la teoría económica, un incremento en su precio de 1%, responde con incrementos de demanda de 0.048 a largo plazo y 0.053 a corto plazo.

De forma complementaría se estimaron las elasticidades cruzadas del queroseno, y combustóleo respecto del gas natural como combustible sustituto, encontrando elasticidades: 0.009 y -0.127, respectivamente, en ningún caso resultaron significativas, por lo que el signo de las mismas no es concluyente. Por su parte, las elasticidades cruzadas del gas natural respecto del gas LP (-0.011), y querosenos (-0.039) resultaron no significativas, en referencia al combustóleo la elasticidad estimada resultó significativa, pero con signo contrario de -0.058. La no significancia sugiere rigideces en la sustitución de dichos combustibles por la alternativa de gas natural. La elasticidad cruzada del gas LP respecto del gas natural fue no significativa a largo plazo, mientras que en el corto plazo fue significativa, lo que señala que un incremento de 1% del precio del gas natural aumenta la demanda de gas LP en 0.929.

En cuanto a la estimación de elasticidades en los modelos con cambio estructural, las elasticidades ingreso a largo y corto plazos resultaron significativas para los nueve combustibles estudiados. Por otro lado, las elasticidades precio resultaron significativas a largo plazo para la gasolina regular, gasolina premium, diésel, turbosina queroseno y combustóleo, de éstos, la turbosina y queroseno obtuvieron signos positivos. Las elasticidades no significativas fueron en los combustibles de gas LP y gas natural.

Por su parte, las variables dicotómicas, para identificar cambios estructurales en el consumo por la implementación del Impuesto al carbono y liberación de precios (por simplificación solamente se reportan las correspondientes con resultado significativo estadísticamente), la elasticidad precio del diésel (-0.117), gas LP (-0.008) y combustóleo (-0.592), se vieron afectadas por la política de incorporación del IEPS a combustibles fósiles (D1), en -0.188, -0.427 y 1.003, respectivamente. A sí mismo, la política de liberación de precios (D2, D5 y D6), afecta las elasticidades de la gasolina premium (-2.320), el diésel (-0.117), gas LP (-0.008*) y gas natural (0.004*) con cambios en, 1.407, 0.829, 0.189 y 0.054, respectivamente (Tabla 5).

Tabla 5. Modelos originales con cambios estructurales

Modelos a largo plazo								
Variable independiente (PIB/ Precios)	Variable dependiente (Volumen)							
	Regular	Premium	Diésel	Turbosina	Gas LP	Querose-nos	Combus-tóleo	Gas Natural
PIB	0.305	0.516	0.831	0.264	0.343	0.273	0.44	0.226
Regular	-0.477	1.004						
Premium	0.209	-2.32						
Diésel			-0.117					
Turbosina				0.051				
Gas LP					-0.008*			-0.062
Querosenos						0.043		0.009*
Combustóleo							-0.592	-0.004*
Gas Natural					-0.021	0.009*	0.000*	0.003*
D1 Diésel			-0.188					
D1 Gas LP					-0.427			
D1 Combustóleo							1.003	
D2 Premium		1.407						
D2 Diésel			0.829					
D3 Gas Natural								-0.046
D5 Gas Natural								0.053
D6 Gas LP					0.189			
Modelos a corto plazo								
PIB	0.339	0.626	0.853	0.250	0.397	0.260	0.830	0.165
Regular	-0.312*	1.245*						
Premium	0.142*	-2.455						
Diésel			0.036*					
Turbosina				0.058				
Gas LP					0.033*			-0.063
Querosenos						0.048*		0.013*
Combustóleo							0.145*	-0.017*
Gas Natural					-0.028	0.011*	-0.099*	0.010*
D1 Gas LP					-2.074			
D1 Combustóleo							0.459	
D2 Diésel			0.969					
D3 Gas Natural								-0.068
D5 Gas natural								0.093
D6 Gas LP					1.714			

(*) Coeficiente no significativo.

En cuanto a los modelos con cambio estructural de corto plazo, solamente resultaron significativas las elasticidades precio de la gasolina premium (2.455) y la turbosina (0.058), en este tipo de modelos la política de incorporación del IEPS al CO_2 (D1), resultó significativa para el gas LP y combustóleo, por su parte, el diésel, gas LP y gas natural resultaron significativos a la política de liberación de precios.

Finalmente, la Tabla 6 muestra los resultados de las pruebas a los residuos para cada uno de los dos grupos de modelos con sus nueve combustibles contemplados en este trabajo: modelos convencionales a largo plazo y corto plazo y modelos con cambio estructural a largo plazo (LPCE) y corto plazo (CPCE). A continuación, se presentan las pruebas de normalidad, autocorrelación y estacionariedad sobre los residuos de cada modelo.

Tabla 6. Pruebas a los residuos

Modelo	Prueba	Anderson-Darling	Box-Pierce	Ljung-Box	DFA	KPSS
	H0	Errores Normales	No hay autocorrelación	No hay autocorrelación	Raíz unitaria	Estacionaria
		P-value > .05	P-value > .05	P-value > .05	P-value > .05	P-value > .05
Regular	LP	0.895	0.003*	0.003*	0.010	0.061
	CP	0.716	0.771	0.769	0.010	0.100
	LPCE	0.965	0.058	0.045*	0.010	0.062
	CPCE	0.917	0.89	0.889	0.010	0.100
Premium	LP	0.178	0.978	0.978	0.010	0.100
	CP	0.337	0.545	0.542	0.010	0.100
	LPCE	0.136	0.753	0.721	0.010	0.100
	CPCE	0.185	0.832	0.831	0.010	0.100
Diésel	LP	0.502	0.786	0.785	0.010	0.100
	CP	0.785	0.989	0.989	0.010	0.100
	LPCE	0.67	0.057	0.045*	0.010	0.076
	CPCE	0.715	0.086	0.070	0.010	0.100
Turbosina	LP	0.053	0.848	0.847	0.010	0.100
	CP	0.054	0.853	0.852	0.010	0.100
	LPCE	0.055	0.945	0.936	0.010	0.100
	CPCE	0.054	0.959	0.953	0.010	0.100
Gas LP	LP	0.003*	0.095	0.078	0.010	0.100
	CP	0.059	0.913	0.912	0.010	0.053
	LPCE	0.006*	0.046*	0.037*	0.010	0.100
	CPCE	0.370	0.959	0.959	0.010	0.077
Querosenos	LP	0.041*	0.848	0.847	0.010	0.100
	CP	0.047*	0.880	0.879	0.010	0.100
	LPCE	0.055	0.945	0.936	0.010	0.100
	CPCE	0.047*	0.961	0.954	0.010	0.100
Combustóleo	LP	0.155	0.706	0.705	0.010	0.100
	CP	0.141	0.827	0.826	0.010	--
	LPCE	0.233	0.361	0.323	0.010	0.100
	CPCE	0.141	0.289	0.255	0.010	0.100
Gas Natural	LP	0.000*	0.140	0.137	0.010	0.100
	CP	0.000*	0.383	0.380	0.010	0.100
	LPCE	0.568	0.004*	0.002*	0.010	0.100
	CPCE	0.173	0.611	0.575	0.010	0.100

(*) Coeficiente no significativo.

En general, los modelos cumplen con los supuestos esperados en los residuos, de normalidad, no autocorrelación y estacionariedad; en todos los modelos para superar posibles problemas de autocorrelación y heteroscedasticidad se corrigieron mediante el método *Newey-West* la varianza, y los errores estándar de los parámetros, para obtener estimadores más robustos.

Pronósticos de demanda

En esta sección se muestran los pronósticos de la demanda de combustibles a través de dos técnicas de estimación: metodología *Box-Jenkins* y de Redes Neuronales, así mismo se brinda una métrica de comparación sobre ambas métricas para identificar los pronósticos más precisos.

Aunque generalmente se considera que la metodología *Box-Jenkins* proporciona un rango de modelos, tanto estacionarios como no estacionarios,

que representan adecuadamente la mayoría de las series temporales, y por lo tanto, un modelo ajustado de series de tiempo puede tener múltiples usos, siendo el más común es el de pronóstico, sus principales críticas a este tipo de modelos es la dependencia de los valores futuros a la estructura de autocorrelación de los valores pasados u observados, por lo que, los intervalos de predicción pueden proporcionar niveles altos de incertidumbre, además, presentan incapacidad para ajustar comportamientos irreversibles en el tiempo, o irregulares (Olmedo, E., *et al*., 2004).

Como alternativa a los pronósticos con modelos ARIMA, las Redes Neuronales Artificiales (RNA) o Redes Neuronales son modelos computacionales inspirados en las neuronas del cerebro humano, conformadas por un conjunto de unidades de cómputo básico (neuronas) que están conectadas entre ellas de múltiples maneras. Estas conexiones estarán definidas por pesos que determinarán la fuerza o importancia de dichas conexiones, y durante el proceso de aprendizaje o entrenamiento de la red, estos pesos se irán ajustando con el fin de producir una salida adecuada según la entrada que se aplique a la red. De manera general, las redes neuronales están compuestas por una capa de entrada, una o más capas ocultas, y una capa de salida.

Como mencionan Ciaburro, G. y Venkateswaran, B. (2017), el objetivo principal de los modelos de redes neuronales es aprender modificándose a sí mismos automáticamente para realizar tareas complejas mediante programación basada en reglas.[11]

Las redes neuronales se han utilizado con mucho éxito en situaciones donde es necesario hacer predicciones. Mencionamos que el uso más común de la modelación de series de tiempo es justamente el de predicción, por lo tanto, tiene sentido hacerlo a través de una red neuronal. Además, tienen capacidad para predecir series de tiempo lineales y no lineales, este último comportamiento es frecuente es series temporales reales, además son capaces de capturar la correlación entre los datos y no requieren ningún conocimiento previo del problema que se esté modelando.

La aplicación de las redes neuronales en series de tiempo se considera una técnica de regresión no paramétrica y no lineal, con gran potencial para el pronóstico debido a sus capacidades de adaptabilidad, generalización, aprendizaje y la posibilidad de representar relaciones no lineales; contrario a los modelos propios de la metodología Box-Jenkins, que asumen series generadas a partir de procesos lineales. Existen varios artículos donde se comparan las capacidades predictoras de las RNA con la predicción realizada a través de la metodología Box-Jenkins. Por mencionar algunos, se encuentran Choon Ong, H. y Tze Chuin, J.L. (2008), Menacho, C. (2014) y Zhang, X., *et al*. (2018).

11 Una crítica al proceso de cálculo de las redes neuronales es que llega ser considerado poco claro y difícil de entender, al grado que varios autores lo catalogan como "una caja negra".

Métricas de comparación entre modelos de redes neuronales y modelos ARIMA

Fair (1986) analiza las medidas más comunes de precisión predictiva, las cuales, se utilizan para evaluar la precisión de los pronósticos *ex post* y *ex ante*,[12] entre las que se encuentran:

$$Error\ absoluto\ medio: MAE = mean(|e_t|)$$
$$Error\ cuadrático\ medio\ de\ raíz: RMSE = \sqrt{e_t^2}$$
$$Error\ porcentual\ absoluto\ medio: MAPE = mean(|p_t|)$$

Las medidas de precisión MAE y RMSE se basan únicamente en los errores son, por lo tanto, dependientes de la escala y no pueden usarse para hacer comparaciones entre series que involucran diferentes unidades. El *MAPE* viene dado por $p_t = 100*e_t/X_t$. Los errores porcentuales tienen la ventaja de carecer de unidades, por lo que se utilizan con frecuencia para comparar los resultados de las predicciones entre conjuntos de datos, posiblemente con distinta escala. Dada la forma en que se calculan estas medidas, es claro que la mejor predicción se logra con los modelos que tengan los valores más pequeños en ellas. La Tabla 7 muestra la comparación de estas tres métricas entre los pronósticos de redes neuronales y los ARIMA. En cada columna, el primer valor corresponde a los modelos de redes neuronales y el segundo los modelos ARIMA.

Tabla 7. Métricas de precisión predictiva

Combustible	MAE	RMSE	MAPE	Combustible	MAE	RMSE	MAPE
GLPkg	0.0035	0.0052	0.0169	Turbosina	0.0317	0.0454	0.1627
	0.0223	0.0319	0.1092		0.03	0.0407	0.1538
Regular	0.0027	0.0036	0.0124	Querosenos	0.0261	0.0361	0.134
	0.0152	0.0193	0.0699		0.0298	0.0405	0.1528
Premium	0.0246	0.0314	0.1228	Combustóleo	0.0441	0.0588	0.2124
	0.0306	0.0414	0.1532		0.143	0.1924	0.6938
Diésel	0.0002	0.0002	0.0002	GNm3	0.0164	0.0208	0.0742
	0.0200	0.0260	0.0942		0.0217	0.028	0.0979

Como puede verse, excepto para la turbosina, en el resto de los hidrocarburos la predicción a través de redes neuronales es más precisa que la del ARIMA, hecho que también puede apreciarse en las gráficas correspondientes, y en los estadísticos básicos de la siguiente tabla.

12 Un pronóstico *ex post* es uno en que se utilizan los valores reales de las variables exógenas; un pronóstico *ex ante* es aquel en el que se utilizan valores estimados de las variables exógenas (nuestro caso).

Tabla 8. Descriptivos pronósticos SARIMA y Redes Neuronales

Combustible	SARIMA				Redes neuronales			
	Mínimo	Máximo	Media	Desv. Est.	Mínimo	Máximo	Media	Desv. Est.
Regular	3,125.1	4,103.1	3,620.0	189.4	3,125.9	3,412.7	3,294.5	40.6
Premium	593.2	1,354.1	1,091.1	206.0	571.1	663.1	644.9	13.2
Diésel	1,645.6	2,966.6	2,385.0	351.1	1,713.6	2,114.8	1,977.9	101.6
Turbosina	399.6	563.0	483.3	39.1	372.1	461.6	410.3	27.4
Gas LP	652.2	866.3	734.0	53.6	696.7	876.0	846.0	34.8
Querosenos	380.5	518.8	450.3	34.2	341.1	433.2	366.9	22.9
Combustó-leo	215.6	511.0	330.0	75.7	339.6	765.4	606.9	65.3
Gas Natural	6,713.4	13,508.1	9,883.8	1,819.7	3,558.8	7,003.3	4,310.8	1,019.6

Figura 10. Gasolina regular (Redes neuronales / SARIMA)

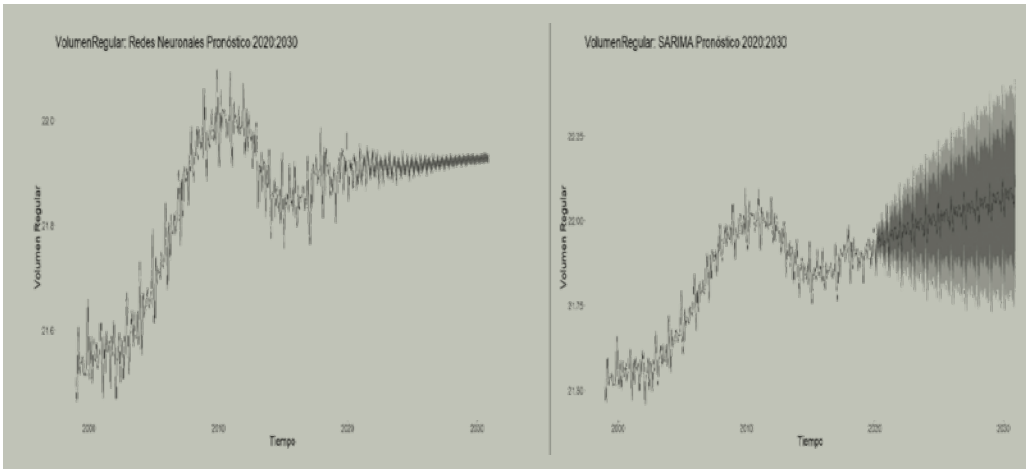

Figura 11. Gasolina premium (Redes neuronales / SARIMA)

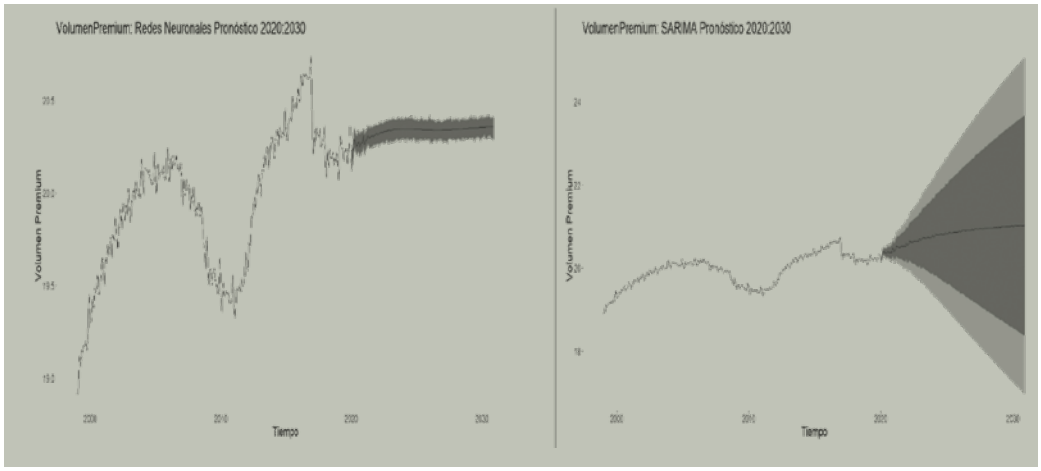

Figura 12. Diésel (Redes neuronales / SARIMA)

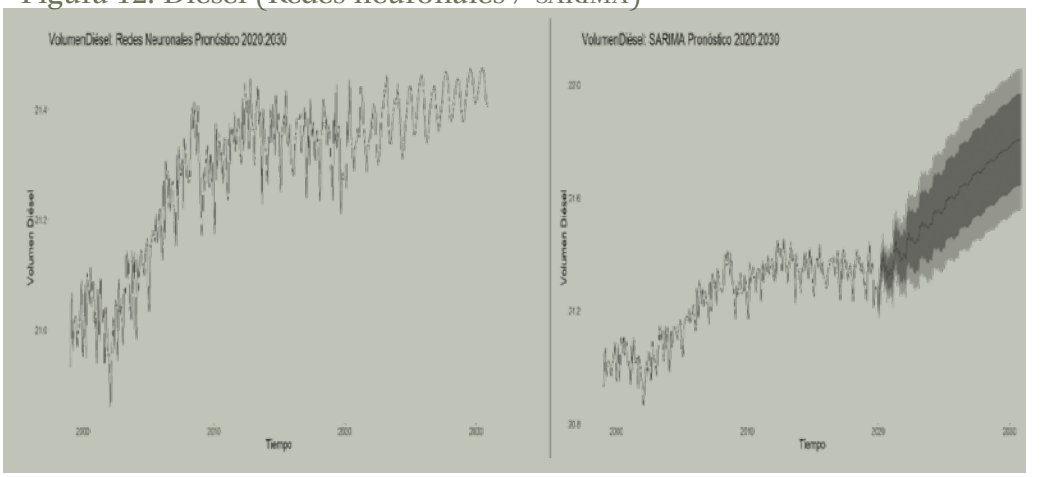

Figura 13. Turbosina (Redes neuronales / SARIMA)

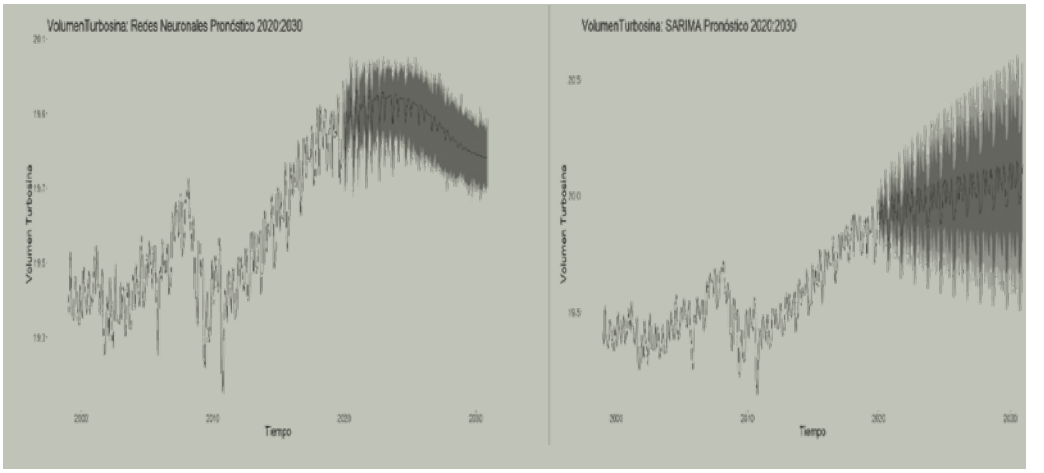

Figura 14. Gas LP (Redes neuronales / SARIMA)

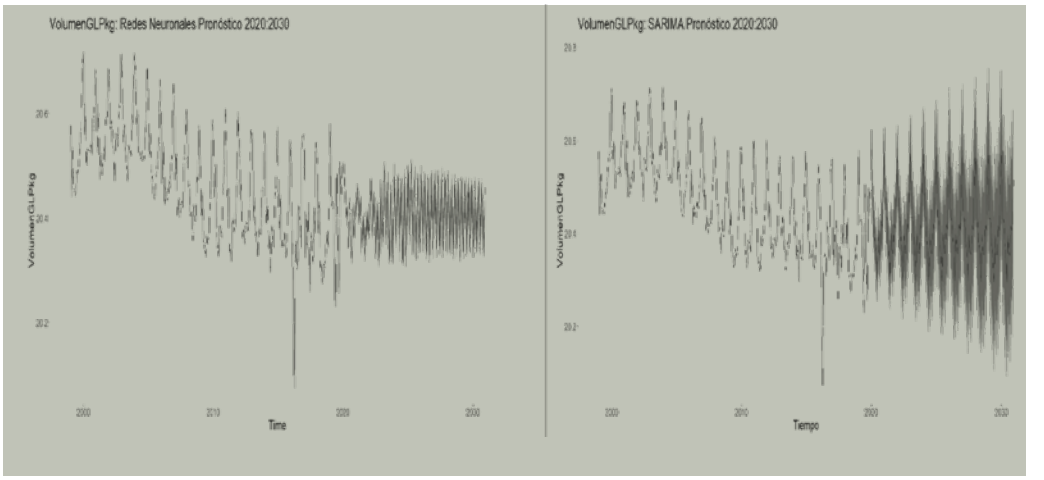

Figura 15. Queroseno (Redes neuronales / SARIMA)

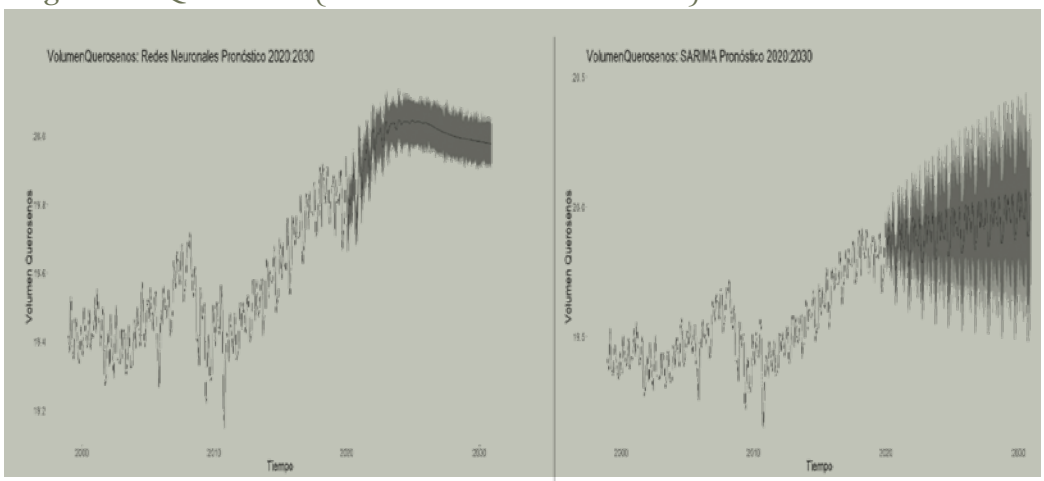

Figura 16. Combustóleo (Redes neuronales / SARIMA)

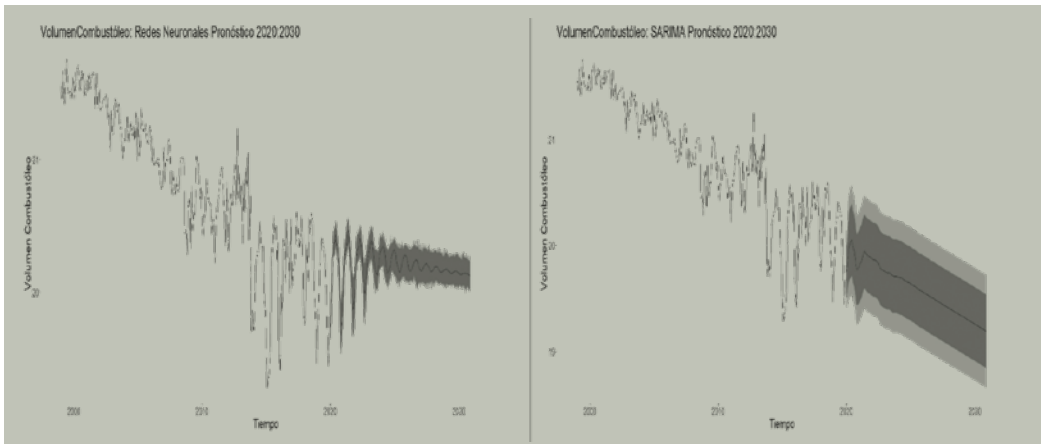

Figura 17. Gas natural (Redes neuronales / SARIMA)

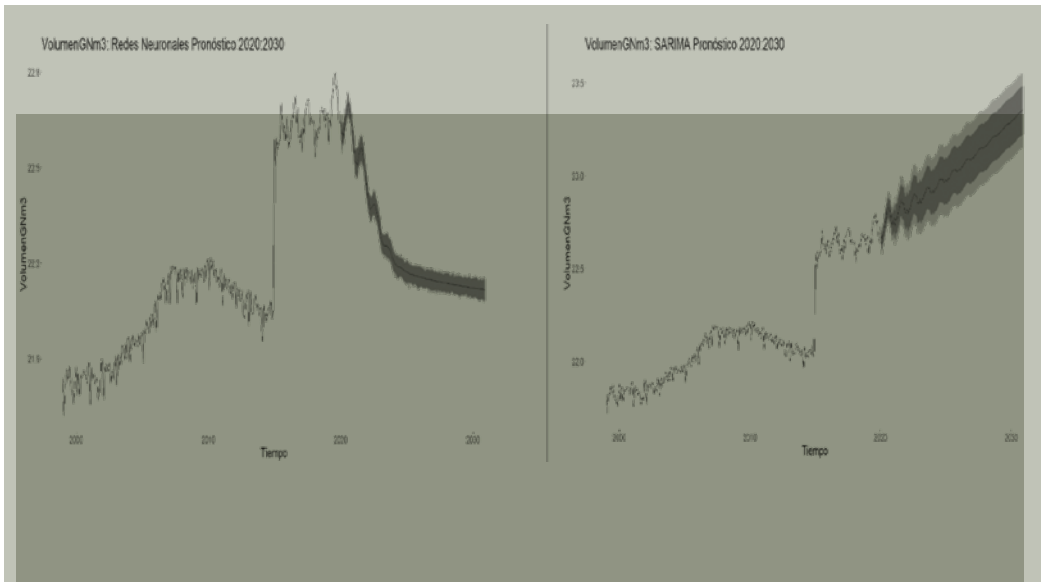

Conclusiones

La revisión de literatura con relación a estimaciones de elasticidades precio e ingreso de la demanda de combustibles fósiles, permitió dar cuenta de su concentración en estudios para gasolinas, en segundo lugar, diésel y en forma dispersa otros hidrocarburos como son el gas natural, gas LP, naftas, entre otros; los resultados de los estudios consultados muestran ser consistentes con predicho por la teoría económica.

Las estimaciones propias, para modelos convencionales, develan elasticidades ingreso de conformidad a lo esperado por la teoría económica para la gasolina regular, gasolina premium, diésel, turbosina, gas LP, queroseno, combustóleo y gas natural, así como de revelar coeficientes mayores a largo plazo respecto a los de corto plazo. En cuanto a las elasticidades precio, cinco combustibles mostraron signo negativo conforme a la teoría económica, gasolina regular, gasolina premium, diésel, gas LP y gas natural, en donde el diésel y gas natural resultaron no significativos tanto a LP como a CP. También se encontraron elasticidades más que proporcionales de la gasolina premium, por lo que incrementos en su precio inciden en la demanda más que proporcionalmente, también, en las elasticidades cruzadas de la demanda, se encontraron coeficientes significativos entre las gasolinas regular y premium.

Por su parte, para los combustibles turbosina, queroseno y combustóleo, sus elasticidades precio resultaron no negativas, y para el queroseno resultó no significativa. No se encontró evidencia significativa de las elasticidades cruzadas del queroseno y combustóleo respecto del gas natural como combustible sustituto. Ni tampoco del gas natural respecto del gas LP y querosenos, solamente se encontró significativa la elasticidad cruzada con el combustóleo

Por su parte, las elasticidades precio resultaron significativas a largo plazo para la gasolina regular, gasolina premium, diésel, turbosina queroseno y combustóleo, de éstos, la turbosina y queroseno obtuvieron signos positivos. Las elasticidades no significativas fueron en los combustibles de gas LP y gas natural.

En cuanto a los modelos con cambio estructural, las variables dicotómicas, para en el consumo por la implementación del Impuesto al carbono y liberación de precios solamente resultaron significativas a la incorporación del IEPS el diésel, gas LP y combustóleo; y frente a la política de liberación de precios solamente en la gasolina premium, diésel, gas LP y gas natural.

Finalmente, la estimación de pronósticos en la demanda de combustibles, a través de dos métodos de estimación, permite brindar escenarios alternativos para la evaluación de políticas públicas de forma consistente y sólida. No obstante, las medidas más comunes de precisión predictiva permiten inferir que el pronóstico a través de técnicas de redes neuronales es más preciso que la realizada mediante modelos ARIMA.

Referencias

Abad, S., 2014. Detención de anomalías cardíacas con aprendizaje automático (Machine Learning).

Aguilar Ibarra, A., Ávila Foucat, S. & Pérez Espejo, R., 2010. *Introducción a las economías de la naturaleza.* Ciudad de México: UNAM Universidad Nacional Autónoma de México IIEc.

Ahmadian, M., Chitnis, M. & Hunt, L. C., 2007. Gasoline Demand, Pricing Policy and Social Welfare in the Islamic Republic of Iran. *OPEC Review,* 31(2), pp. 105-124.

Akaike, H., 1974. A new look at the statistical modelo identification. *IEEE Transactions on Automatic Control*, 19(6), pp. 716-723.

Akinboade, O. A., Ziramba, E. & Kumo, W. L., 2008. Demand for Gasoline in South Africa: An Empirical Analysis Using Co-integration Techniques. *Energy Economics,* 30(6), pp. 3222-3229.

Al-mulali, U., Tang, C. F. & Ozturk, I., 2015. Estimating the Environmental Kuznets Curve hypothesis: Evidence fron Latin America and the Caribbean countries. *Renewable and Sustainable Energy Reviews,* Octubre, Volumen 50, pp. 918-924.

Alonso, J. C. & Semaán, P., 2010. Prueba de HEGY en R: Una guía. *Apuntes de Economía,* Junio.Issue 23.

Alves, D. C. & De Losso da Silveira Bueno, R., 2003. Short-Run, Long-Run and Cross Elasticities of Gasoline Demand in Brazil. *Energy Economics,* 25(2), pp. 191-199..

Amengual, D. & Cubas, G., 2002. Imposición óptima a las naftas y el gasoil: Un análisis empírico para Uruguay 1988-2001.

Ashraf, H., Khan, I. H., Javaid, A. & Awais, M., 2018. Price and Income Elasticities of Crude Oil Demand: Cross Country Analysis. *European Online Journal of Natural and Social Sciences,* 7(1), pp. 122-136.

Banaszak, S., Chakravorty, U. & Leung, P., 1999. Demand for Ground Transportation Fuel and Pricing Policy in Asian Tigers: A Comparative Study of Korea and Taiwan. *The Energy Journal,* 20(2), pp. 145-165.

Bentzen, J., 1994. An Empirical Analysis of Gasoline Deman in Denmark Using Cointegration Techniques. *Energy Economics,* 01 April, 16(2), pp. 139-143.

Berndt, E. R. y. G. B., 1985. Energy Demand in the Transportation Sector of México. *Journal of f Development Economics,* 17(3), pp. 219-238.

Bhaskara, R. B. & Rao, G., 2009. Cointegration and the Demand for Gasoline. *Energy Policy,* 37(10), pp. 3978-3983.

Carbonell Ferrer, J. & Escalante Semerena, R., 2014. Demanda de gasolina en la zona metropolitana del Valle de México: análisis empírico de la reducción del subsidio. *Revista de Economía del Rosario,* enero-junio, 17(1), pp. 89-117.

Catalán, H., 2014. Curva ambiental de Kuznets: implicaciones para un crecimiento sustentable. *Economía Informa*, Issue 389, pp. 19-37.

CFE, 2021. *Reporte Anual 2020.* [En línea] Available at: https://www.cfe.mx/finanzas/reportes-financieros/Reportes%20Anuales%20Documentos/Reporte%20anual%202020.pdf

Chandrasiri, S., 2006. Demand for Road-Fuel in a Small Developing Economy: The Case of Sri Lanka. *Energy Policy*, 34(14), pp. 1833-1840..

Cheung , K.-Y. & Thomson, E., 2004. The Demand for Gasoline in China: a Cointegration. *Journal of Applied,* 31(5), pp. 533-544.

Choon, O. H. & Tze Chuin, J. L., 2008. A comparison of neural network methods and Box-Jenkins model in time series analysis. *International Conference on Advances in Computer Science and Technology,* p. 344–350.

Ciaburro, G. & Venkateswaran, B., 2017. *Neural Networks with R.* Birmingham: Packt Publishing.

Dahl, C. & Kurtubi, 2001. Estimating oil product demand in Indonesia usign a cointegraiting error correction model. *OPEC Review,* pp. 1-25.

De Vita, G., Endresen, K. & Hunt, L., 2006. An Empirical Analysis of Energy Demand in Namibia, Energy Policy. 34(18), pp. 3447-3463..

DOF, 2013. *DECRETO por el que se reforman, adicionan y derogan diversas disposiciones del Código Fiscal de la Federación.* [En línea] Available at: http://dof.gob.mx/nota_detalle.php?codigo=5324942&fecha=25/04/1924

Elizondo, R., 2012. Estimaciones del PIB Mensual Basadas en el IGAE. *Banco de México: Documentos de Investigación,* Octubre.Issue 2012-11.

Eltony, M. N. & Al-Mutairi, N. H., 1995. Demand for Gasoline in Kuwait: An Empirical Analysis Using Cointegration Techniques. *Energy Economics,* 17(3), pp. 249-253.

Engle, R. F. & Granger, C. W. J., 1987. Co-Integration and Error Correction: Representation, *Estimation, and Testing. Econometrica,* 55(2), pp. 251-276.

Francos Rodríguez, M., 2006. *Estimación de la demanda de combustibles en República Dominicana,* s.l.: Secretariado Técnico de la Presidencia: Unidad de Análisis Económico.

Galindo, L. M., 2005. Short -and Long- run Demand for Energy in Mexico: A Cointegration Approach. *Energy Policy*, 33(9), pp. 1179-1185.

Galindo, L. M. y otros, 2015. Meta-análisis de las elasticidades ingreso y precio de la demanda de gasolina: implicaciones de política pública para América Latina. *CEPAL*, diciembre.Issue 117.

García, J. J., Pérez, D., Orrego P., M. & Castaño D., J. M., 2016. Un modelo Casi Ideal de Demanda de Combustibles para la Industria de Transporte. *Documentos de Trabajo: Economía y Finanzas,* Issue 16-03.

Gujarati, D. N. & Porter, D. C., 2009. *Econometría*. Quinta Edición ed. México: McGraw-Hill.

Hunt, L. C., Salgado, C. & Thorpe, A., 1999. The Policy of Power and Power of Policy in Honduras. *Journal of Energy and Development,* 25(1), pp. 1-36.

Hyndman, R. J. & Athanasopoulos, G., 2013. *Forecasting: principles and practice. s.l.:O Text.*

Ibarra Salazar , J. & Sotres Cervantes, L., 2008. La demanda de gasolina en México: El efecto en la frontera norte. *Frontera Norte,* enero-junio, 20(39), pp. 131-156.

Ibarrola, H. R. y. J., 2000. Cálculo de la elasticidad precio de la demanda de gasolina en la zona fronteriza norte de México. Volumen 11, pp. 237-262.

INEGI, 2018. *Encuesta Nacional sobre Consumo de Energéticos en Viviendas Particulares* (ENCEVI 2018). [En línea] Available at: https://www.inegi.org.mx/contenidos/programas/encevi/2018/doc/encevi2018_presentacion_resultados.pdf

IPCC, 2021. *AR6 Climate Change 2021: The Physical Science Basis.* [En línea] Available at: https://www.ipcc.ch/report/ar6/wg1/downloads/report/IPCC_AR6_WGI_SPM.pdf

Kleiber, C. & Zeileis, A., 2008. *Applied Econometric with R*. s.l.:Springer.

Koutsoyiannis, A., 2002. *Microeconomía Moderna.* s.l.:Amorrortu editores.

Labandeira, X., Labeaga, J. M. & López, X., 2016. Un metaanálisis sobre la elasticidad precio de la demanda de energía en España y la Unión Europea. *Papeles de Energía,* diciembre, Issue 2, pp. 65-93.

Mahadeva, L. & Robinson, P., 2009. *Prueba de raíz unitaria para ayudar a la construcción de un modelo. s*.l.:Centro de Estudios Monetarios Latinoamericanos.

Martínez Alier, J. & Roca Jusmet, J., 2000. *Economía ecológica y política ambiental.* s.l.:Fondo de Cultura Económica.

Menacho, C., 2014. Comparación de los métodos de series de tiempo y redes neuronales. *Anales Científicos,* 75(2), pp. 245-252.

Morán Rugel, F., Zúñiga Bastidas, J. & Marriot García, F., 1998. Estimación de las elasticidades de la demanda de gasolina en el Ecuador: un análisis empírico.

Olmedo, E., Valderas, J. M., Mateos, R. & Gimeno, R., 2004. Utilización de redes neuronales en la caracterización, modelización y predicción de series temporales económicas en un entorno complejo. *Revista Iberoamericana de Inteligencia Artificial,* 8(23).

Polemis, M. L., 2006. Empirical Assessment of the Determinants of Road Energy Demand in Greece. *Energy Economics,* 28(3), pp. 385-403.

Ramanathan, R., 1999. Short- and Long-Run Elasticities of Gasoline Demand in India: An Empirical Analysis Using Cointegration Technique. *Energy Economics,* 21(4), pp. 321-330.

Reyes Orlando, E. R. y. M. A., 2010. La demanda de gasolinas en México: Efectos y alternativas ante el cambio climático. *Economía: Teoría y Practica,* enero, Issue 32, pp. 88-111.

Rodríguez, M. F., 2006. Estimación de la demanda de combustibles en República Dominicana. *Secretariado Técnico de la Presidencia. Programa del Poder Ejectivo Unidad de Análisis Económico.,* Octubre.pp. 1-22.

Sa´ad, S., 2009. An Empirical Analysis of Petroleum Demand for Indonesia: An Application of the Cointegration Approach. *Energy Policy,* 37(11), pp. 4391-4396.

Samimi, R., 1995. Road Transport Energy Demand in Australia. *Energy Economics,* 17(4), pp. 329-339.

Sánchez, A., Islas, S. & Sheinbaum, C., 2015. Demanda de gasolina y heteregeneidad en los ingresos de los hogares en México. *Investigación Económica,* enero-marzo, LXXIV(291), pp. 117-143.

Sánchez, L. & Reyes, O., 2016. La demanda de gasolinas, gas licuado de petróleo y electricidad en el Ecuador: Elementos para una reforma fiscal ambiental. *Estudios del cambio climático en América Latina,* septiembre.

SCT, 2021. Aeronáutica Civil. [En línea]
Available at: https://www.sct.gob.mx/transporte-y-medicina-preventiva/aeronautica-civil/5-estadistica/53-estadistica-operacional-de-aerolineas-traffic-statistics-by-airline/estadistica-historica-1992-2020-historical-statistics-1992-2020/

SENER, 2021. *Balance Nacional de Energía 2019.* [En línea] Available at: https://www.gob.mx/sener/documentos/balance-nacional-de-energia-2019 [Último acceso: 3 junio 2021].

Stiglitz, J. E., 2000. *La economía del sector público.* Tercera ed. Barcelona: Antoni Bosch.

Villamarín Lafaurie, E., 2007. *Elasticidad Precio de la Demanda de Gasolina Corriente y ACPM.* s.l.:Universidad de los Andes: Facultad de Economía.

World Bank, 2021. *Data Bank, World Development Indicators.* [En línea] Available at: https://databank.worldbank.org/reports.aspx?source=2&series=EN.ATM.CO2E.PC&country=WLD

Zárate Martínez, I. M., Guzmán Soria, E., Hernández Martínez, J. & Rebollar Rebollar, S., 2015. Análisis económico del consumo de gas natural para generación de energía eléctrica en México: 2005-2014. *Pistas Educativas*, diciembre, Issue 115, pp. 167-180.

Zhang, X., Tianyuan, X. & Stanley, E. H., 2018. IEEE Access. *Special Section on Big Data Learning and Discovery,* Diciembre, Volumen 7, pp. 1647-1657.

Anexo I: Revisión documental

Cuadro 9. Gasolinas

Clave	Autor	Periodo de estimación	Tipo de datos	País	Elasticidad precio		Elasticidad ingreso		Notas
					Corto plazo	Largo plazo	Corto plazo	Largo plazo	
MEX.R1	SHCP-DEE	1999-2020	Tradicional	México	-0.409	-0.586	0.300	0.458	Regular
MEX.P1	SHCP-DEE	1999-2020	Tradicional	México	-2.348	-2.211	0.337	0.533	Premium
-	SHCP-DEE	1999-2020	Compuesto	México	-0.255	-0.476	0.339	0.305	Regular
-	SHCP-DEE	1999-2020	Compuesto	México	-1.442	-0.789	0.626	0.516	Premium
IRN	Ahmadian, Chitnis y Hunt	1968–2002	Series de tiempo (anuales)	Irán	-0.18	-0.642	0.35	1.25	STSM: modelos estructurales de series de tiempo (Structural Times Series Model)
ZAF	Akinboade, Ziramba y Kumo	1978-2005	Series de tiempo (anuales)	Sudáfrica	-	-0.47	-	0.36	ARDL: modelo autorregresivo de rezagos distribuidos y Cointegración, procedimiento de Pesaran, *et al*. (2001).
BRA	Alves y Bueno	1984-1999	Series de tiempo (anuales)	Brasil	-0.919	-0.4646	0.1216	0.1217	Cointegración y ECM: Modelo de corrección de error, procedimiento de Engle y Granger (1987)
TWN	Banaszak, Chakravorty y Leung	1973-1992	Series de tiempo (anuales)	Taiwán	-0.120	-0.51	0.23	0.977	MAP: Modelo de ajuste parcial.
DNK	Bentzen	1948-1991	Series de tiempo (anuales)	Dinamarca	-0.320	-0.414	0.885	1.044	Cointegración y ECM: Modelo de corrección de error, procedimiento de Engle y Granger (1987)
LKA	Chandrasiri	1964-2002	Series de tiempo (anuales)	Sri Lanka	-	-0.478	-	0. 134*	MAP: Modelo de ajuste parcial.
CHN2	Cheung y Thomson	1980-1999	Series de tiempo (anuales)	China	-0.19	-0.56	1.64	0.97	Cointegración y ECM: Modelo de corrección de error, procedimiento de Johansen
IDN1	Dahl y Kurtubi	1970-1998	Series de tiempo (anuales)	Indonesia	-0.194	-0.81	0.31	1.303	MAP: Modelo de ajuste parcial
IDN2	Dahl y Kurtubi	1970-1998	Series de tiempo (anuales)	Indonesia	-0.036	-0.63	0.19	1.284	Cointegración
NAM	De Vita, Endresen y Hunt	1980–2002	Series de tiempo (anuales)	Namibia	-	-0.749	-	0.957	ARDL: Modelo Autorregresivo de rezagos distribuidos (Autoregressive Distributed Lag)
KWT1	Eltony y Al-Mutairi	1970-1989	Series de tiempo (anuales)	Kuwait	-0.372	-0.463	0.472	0.919	Cointegración y ECM: Modelo de corrección de error, procedimiento de Engle y Granger (1987)

-	Galindo, Samaniego, Alatorre, Ferrer y Reyes	1960-2013	63 estudios de la literatura internacional sobre la demanda de gasolina (Estudio de metaanálisis)	Diversos países/ regiones (incluida Latinoamérica)1	-0.21	-0.44	0.34	0.63	Promedio de los estudios (tiene sesgo de publicación)
					-0.104	-0.314	0.267	0.461	Sesgo de publicación corregido
				Países de la OCDE (excluido Chile y México)2	-0.22	-0.41	0.24	0.55	-
				América latina3	-0.17	-0.31	0.26	0.69	-
				Resto del mundo4	-0.2	-0.37	0.29	0.79	-
				Diversos países/regiones (incluida Latinoamérica)5	-0.16	-0.35	0.29	0.49	Elasticidad en estudios que consideran el parque vehicular
					-0.21	-0.4	0.3	0.67	Elasticidad en estudios que no consideran el parque vehicular
					-0.32	-0.48	0.23	0.58	Elasticidad en estudios que consideran el precio de sustitutos (por ej. Etanol o biodiesel)
					-0.16	-0.38	0.31	0.62	Elasticidad en estudios que no consideran el precio de sustitutos
					-0.2	-0.46	0.33	0.62	Estudios que utilizan mínimos cuadrados ordinarios (MCO)
					-0.08	-0.2	0.49	0.67	Estudios que utilizan máxima verosimilitud
					-0.32	-0.11	0.21	0.27	Estudios que utilizan método generalizado de momentos (MGL)
COL1	García, Pérez, Orrego y Castaño	2003-2012	Series de tiempo mensual (datos a nivel nacional)	Colombia	-	-0.72	-	0.79	La elasticidad precio es marshalliana
COL2					-	-1.14	-	-	La elasticidad precio es hicksiana
UE	Labandeira, Labeaga y López	1995-2014	Series de tiempo (anuales)	Unión Europea	-0.265	-0.789	-	-	-
ESP	Labandeira, Labeaga y López	1995-2014	Series de tiempo (anuales)	España	-0.253	-0.900	-	-	-
ECU1	Morán, Zuñiga y Marriot	Enero de 1989-Diciembre de 1998	Series de tiempo mensuales (modelo en ln)	Ecuador	-	-0.4	-	-0.32	Gasolina Extra (bien inferior)
ECU2					-	-1.55	-	0.60	Gasolina Super (bien superior)
GRC	Polemis	1978-2003	Series de tiempo (anuales)	Grecia	-0.1	-0.38	0.36	0.79	Cointegración
IND1	Ramanathan	1972.1994		India	-0.32	-	2.68	-	-
IND2	Ramanathan	1973-1993	Series de tiempo (anuales)	India	-0.209	-0.319	1.178	2.682	Cointegración y ECM: Modelo de corrección de error, procedimiento de Engle y Granger (1987)

FIY	Bhaskara y Rao	1970-2005	Series de tiempo (anuales)	Fiyi	-	-0.19	2.599	0.462	Cointegración y ECM: Modelo de corrección de error ECM, procedimiento de Engle y Granger (1987)
IND3	Sa'ad	1973-2003	Series de tiempo (anuales)	Indonesia	-0.04	-0.15	0.41	0.86	ARDL: Modelo autorregresivo de rezagos distribuidos (Autoregressive Distributed Lag)
IND4	Sa'ad	1973-2007	Series de tiempo (anuales)	Indonesia	-0.077	-0.191	0.393	0.973	STSM: Modelos estructurales de series de tiempo (Structural Times Series Model).
AUS	Samimi	1980-1993	Series de tiempo (anuales)	Australia	-0.018*	-0.131	0.252	0.518	Cointegración y ECM: Modelo de correción de error, procedimiento de Engle y Granger (1987).
ECU2	Sánchez y Reyes	1985-2012	Series de tiempo (anuales)	Ecuador	-0.163	-	1,483	-	-
COL3	Villamarín Lafaurie Enrique	1980-1999	Series de tiempo (anuales)	Colombia	-	-0.23	-	0.003	-
COL3			Series de tiempo (trimestral)		-	-0.46	-	0.007	-
México									
MX1.1	Berndt y Botero	1960-1979	Series de tiempo anuales	México	-0.17	-0.33	0.7	1.35	Modelo 1: MAP Modelo de ajuste parcial y OLS; Mínimos Cuadrados Ordinarios
MX1.2					-0.15 a -0.17	-0.492	0.15 a 0.17	0.478	Modelo 2: Incluye distinción entre demanda cautiva y flexible
MX1.3					-0.24	-1.21	0.31 a 0.39	2.76	Modelo 3: Contempla la tasa de depreciación, la tasa de inversión en modernización y la tasa de utilización de la flota vehicular.
MX1.4		1973-1978			-0.168	-1.035	0.146	0.9	Se agregó los 32 estados en 14 regiones para considerar la demanda de gasolina en la frontera
MX1.5					-0.07	-0.646	0.05	0.413	
MX1.6					-0.23	-0.96	0.31	1.25	
MX2	Carbonell y Escalante	1980-2012	Series de tiempo anuales (forma log-lineal)	Zona metropolitana del Valle de México	-0.126	-0.256	0.496	0.673	-
MX3	Galindo	1965-2001	Series de tiempo (anuales)	México	0.890*	-0.435	0.836	0.541	Cointegración y ECM: Modelo de corrección de error, procedimiento de Johansen (1988 y 1992)

MX4	Galindo y Salinas	1987-1995	Series de tiempo (anuales)	México	0.001	-0.046	0.560	1.310	Cointegración y ECM: Modelo de corrección de error, procedimiento de Johansen (1988 y 1992)
MX5	Haro y Ibarrola	1999-2008	Series de tiempo (anuales)	México (zona fronteriza)	-0.31	-	0.4	-	-
MX6.1	Ibarra y Sotres	1997-2003	Series de tiempo mensuales (para 27 estados de México)	Región fronteriza norte	-	-1.19	-	-	-
MX6.2				Región no fronteriza	-	-0.69	-	-	
MX6.3				Zona de BC	-	-0.71	-	-	
MX6.4				Zona de Chihuahua	-	-1.16	-	-	
MX6.5				Zona de Sonora	-	-1.93	-	-	
MX6.6				Zona de Tamaulipas	-	-1.22	-	-	
MX7.1	Sánchez, Islas y Sheinbaum	1984-2010	Series de tiempo anuales (datos a nivel nacional). Logaritmos naturales.	México6	-	-0.14	-	0.23	Todo el país
MX7.2					-	-1.77	-	-	Decil 1
MX7.3					-	-2.53	-	4.38	Decil 2
MX7.4					-	-1.19	-	-	Decil 3
MX7.5					-	-0.37	-	1.29	Decil 4
MX7.6					-	-0.52	-	1.46	Decil 5
MX7.7					-	-0.51	-	2.25	Decil 6
MX7.8					-	-0.56	-	-	Decil 7
MX7.9					-	-0.66	-	-	Decil 8
MX7.10					-	-0.35	-	-	Decil 9
MX7.11					-	-0.25	-	-	Decil 10

1/ En el documento no se mencionan los países en específico.
2/ Australia, Austria, Bélgica, Canadá, República Checa, Dinamarca, Estonia, Finlandia, Francia, Alemania, Grecia, Hungría, Islandia, Irlanda, Israel, Italia, Japón, Corea, Luxemburgo, Países Bajos, Nueva Zelanda, Noruega, Polonia, Portugal, Eslovaquia, Eslovenia, España, Suecia, Suiza, Turquía, Reino Unido, Estados Unidos.
3/ En el documento no se mencionan los países en específico.
4/ En el documento no se mencionan los países en específico.
5/ En el documento no se mencionan los países en específico.
6/ Varias elasticidades ingreso no fueron significativas en algunos deciles, debido a eso no aparecen.
7/ * denota que no es significativo.

Tabla 10. Diésel

Clave	Autor	Periodo de estimación	Tipo de datos	País	Elasticidad ingreso		Elasticidad precio		Notas
					Corto plazo	Largo plazo	Corto plazo	Largo plazo	
MEX.1	SHCP-DEE	1999-2020	Tradicional	México	-0.029	-0.066	0.848	0.860	
-	SHCP-DEE	1999-2020	Compuesto	México	0.697	0.524	0.853	0.831	
KOR	Banaszak, Chakravorty y Leung	1973-1992	Series de tiempo (anuales)	Corea	-0.385	-0.866		0.989	OLS: Mínimos Cuadrados Ordinarios.
LKA	Chandrasiri	1964-2002	Series de tiempo (anuales)	Sri Lanka	-0.081	-0.669		0.543	SURE: Regresiones aparentemente no relacionadas. (Seemingly Unrelated Regression Equations)
IND1	Dahl y Kurtubi	1970-1998	Series de tiempo (anuales)	Indonesia	-0.180	-0.648	0.571	2. 060	OLS: Mínimos Cuadrados Ordinarios
IND2	Dahl y Kurtubi	1970-1998	Series de tiempo (anuales)	Indonesia	-0.131	-0.670	2.149	2.164	ECM: Modelo de corrección de error, procedimiento de Engle y Granger (1987)
NAM	De Vita, Endresen y Hunt	1980–2002	Series de tiempo (anuales)	Namibia		-0.138		2.077	Cointegración, procedimiento de Pesaran, *et al*. (2001)
COL1	García, Pérez, Orrego y Castaño	2003-2012	Series de tiempo mensual (datos a nivel nacional)	Colombia	-	-0.070	-	1.400	Elasticidad precio marshalliana
COL2					-	-0.650	-	-	Elasticidad precio hicksiana
UE	Labandeira, Labeaga y López	1995-2014	Series de tiempo (anuales)	Unión Europea	-0.212	-0.639	-	-	-
ESP	Labandeira, Labeaga y López	1995-2014	Series de tiempo (anuales)	España	-0.201	-0.739	-	-	-
GRC	Polemis	1978-2003	Series de tiempo (anuales)	Grecia	-0.070	-0.440	0.420	1.180	ECM: Modelo de corrección de error, procedimiento de Johansen (1988 y 1992)
AUS	Samimi	1980-1993	Series de tiempo (anuales)	Australia	-0.018*	-0.131	0.252	0.518	Cointegración y ECM: Modelo de corrección de error, procedimiento de Engle y Granger (1987)
IND3	Sa'ad	1973-2003	Series de tiempo (anuales)	Indonesia	-0.020	-0.160	0.390	0.880	Cointegración, procedimiento de Pesaran, *et al*. (2001)
IND4	Sa'ad	1973-2007	Series de tiempo (anuales)	Indonesia	-0.077	-0.191	0.393	0.973	STSM: Modelos estructurales de series de tiempo (Structural Times Series Model)

Cuadro 11. Gas LP

Clave país	Autor	Periodo de estimación	Tipo de datos	País	Elasticidad precio		Elasticidad ingreso		Notas
					Corto plazo	Largo plazo	Corto plazo	Largo plazo	
MEX.1	SHCP-DEE	1999-2020	Tradicional	México	-0.119	-0.113	0.340	0.361	
-	SHCP-DEE	1999-2020	Compuesto	México	-0.327	-0.246	0.397	0.343	
DOM	Francos Rodríguez Martín	1997-2006	Series de tiempo (anuales)	República Dominicana	-	-0.29	-	0.42	-
ECU	Sánchez y Reyes	1985-2012	Series de tiempo (anuales)	Ecuador	-	-0.164	-	0.54	-

Cuadro 12. Gas Natural

Clave país	Autor	Periodo de estimación	Tipo de datos	País	Elasticidad precio		Elasticidad ingreso		Notas
					Corto plazo	Largo plazo	Corto plazo	Largo plazo	
MEX.1	SHCP-DEE	1999-2020	Tradicional	México	-0.004	-0.007	0.217	0.240	
-	SHCP-DEE	1999-2020	Compuesto	México	0.034	0.014	0.165	0.218	
COL1	García, Pérez, Orrego y Castaño	2003-2012	Series de tiempo mensual (datos a nivel nacional)	Colombia	-	-2.78	-	-0.37	Elasticidad precio marshalliana
COL2					-	-2.78	-	-	Elasticidad precio hicksiana
MEX	Hernández, Guzmán, Rebollar y Zárate	2005-2014	Series de tiempo (anuales)	México	-0.0461	-		-	-
UE	Labandeira, Labeaga y López	1995-2014	Series de tiempo (anuales)	Unión Europea	-0.255	-0.777	-	-	-
ESP	Labandeira, Labeaga y López	1995-2014	Series de tiempo (anuales)	España	-0.242	-0.807	-	-	-