

**DETERMINANTES Y PREDICCIÓN DE LA INFLACIÓN DE ALIMENTOS Y
BEBIDAS EN ESTADOS UNIDOS: EL PAPEL DE LOS FACTORES EXTERNOS,
CLIMÁTICOS Y DE CONDICIONES DE MERCADO INTERNO**

LUIS EDUARDO GIRÓN CRUZ

**PONTIFICIA UNIVERSIDAD JAVERIANA CALI
FACULTAD DE CIENCIAS ECONÓMICAS Y ADMINISTRATIVAS
DOCTORADO EN CIENCIAS ECONÓMICAS Y DE GESTIÓN
SANTIAGO DE CALI
23 DE ABRIL DE 2026**

**DETERMINANTES Y PREDICCIÓN DE LA INFLACIÓN DE ALIMENTOS Y
BEBIDAS EN ESTADOS UNIDOS: EL PAPEL DE LOS FACTORES EXTERNOS,
CLIMÁTICOS Y DE CONDICIONES DE MERCADO INTERNO**

LUIS EDUARDO GIRÓN CRUZ

**Tesis doctoral presentada como requisito parcial para optar por el título
de Doctor en Ciencias Económicas y de Gestión**

**Director de la tesis doctoral: Lya Paola Sierra Suárez, Ph.D.
Economista**

**PONTIFICIA UNIVERSIDAD JAVERIANA CALI
FACULTAD DE CIENCIAS ECONÓMICAS Y ADMINISTRATIVAS
DOCTORADO EN CIENCIAS ECONÓMICAS Y DE GESTIÓN
SANTIAGO DE CALI
23 DE ABRIL DE 2026**

Santiago de Cali, 23 de abril de 2026

Doctor
Fabián Fernando Osorio Tinoco
Decano
Facultad De Ciencias Económicas y Administrativas
Pontificia Universidad Javeriana
La Ciudad

Por medio de la presente entrego a usted la Tesis Doctoral cuyo título es “**Determinantes y Predicción de la Inflación de Alimentos y Bebidas en Estados Unidos: El Papel de los Factores Externos, Climáticos y de Condiciones de Mercado Interno**”

Espero que esta Tesis cumpla con los requisitos académicos exigidos y que alcance el propósito para el cual fue elaborado.

Atentamente,




Luis Eduardo Girón Cruz
CC 16632200
Santiago de Cali, 23 de abril de 2026

Doctor
Fabián Fernando Osorio Tinoco
Facultad de Ciencias Económicas y Administrativas
Pontificia Universidad Javeriana
La Ciudad

Por medio de la presente me permito comunicarle, que en mi calidad de director de la tesis doctoral he leído detenidamente el informe final del estudio titulado “**Determinantes y Predicción de la Inflación de Alimentos y Bebidas en Estados Unidos: El Papel de los Factores Externos, Climáticos y de Condiciones de Mercado Interno**”, realizado por el estudiante del Programa de Doctorado en Ciencias Económicas y de gestión de la Facultad de Ciencias Económicas y Administrativas Luis Eduardo Girón Cruz identificado con número de cédula de ciudadanía 16632200, y considero que cumple con todos los requisitos requeridos para ser presentada a evaluación.

Atentamente,

A handwritten signature in black ink, reading "Lya Paola Sierra S.", with a horizontal line underneath.

Lya Paola Sierra Suárez, Ph.D.
Directora de la Tesis Doctoral

ARTÍCULO 23 de la resolución N° 13 de julio 6 de 1946

“La Universidad no se hace responsable por los conceptos emitidos por sus alumnos en sus trabajos de Tesis. Sólo velará porque no se publique nada contrario al dogma y a la moral católica y porque la Tesis no contenga ataques o polémicas puramente personales; antes bien, se vea en ellas al anhelo de buscar la Verdad y la Justicia”.

“DETERMINANTES Y PREDICCIÓN DE LA INFLACIÓN DE ALIMENTOS Y BEBIDAS EN ESTADOS UNIDOS: EL PAPEL DE LOS FACTORES EXTERNOS, CLIMÁTICOS Y DE CONDICIONES DE MERCADO INTERNO” Aprobado por el Comité de Trabajos de Grado en cumplimiento de los requisitos exigidos por la Pontificia Universidad Javeriana para optar por el título de Doctor en Ciencias Económicas.



Fabián Fernando Osorio Tinoco

Decano

Facultad de Ciencias Económicas y Administrativas

Julieth Ospina D.

Firmado digitalmente por Julieth
Ospina D.
Fecha: 2026.07.31 11:46:29 -05'00'

Julieth Emilse Ospina Delgado
Directora Doctorado.



José Ustorgio Mora Mora
Jurado 1



Isabel Cristina García Arboleda
Jurado 2.

Gustavo
Adolfo
Gómez Flórez

Firmado digitalmente
por Gustavo Adolfo
Gómez Flórez
Fecha: 2026.07.27
15:51:51 -05'00'

Gustavo Adolfo Gómez Florez
Jurado 3

Lya Paola
Sierra
Suárez

Firmado
digitalmente por Lya
Paola Sierra Suárez
Fecha: 2026.07.31
11:04:38 -05'00'

Lya Paola Sierra Suárez
Director(a).

Santiago de Cali, 15 de julio de 2026.

AGRADECIMIENTOS

Primeramente, a Dios, por su guía a través de su Espíritu Santo como fuente de la sabiduría.

A mi esposa María Esther y mis hijos, quienes me facilitaron mucho tiempo del que les correspondía a ellos y me apoyaron en aquellos momentos que quería desfallecer.

A mi directora Lya Paola Sierra Suárez, por su paciencia, rigurosidad y consejos, los cuales fueron fundamentales a lo largo de este proceso de formación.

A María del Pilar Poncela y Eva Senra, profesoras de La Universidad de Barcelona y Alcalá

Respectivamente, por su apoyo, rigurosidad y compromiso con el proceso de formación de los estudiantes.

A Luis Felipe Gómez Restrepo S.J, exrector de la Pontificia Universidad Javeriana Cali, por su apoyo incondicional para poder adelantar mis estudios de doctorado.

A todos los directivos que de una u otra forma apoyaron incondicionalmente para que pudiera adelantar mis estudios de doctorado.

A La dirección de Escuela de Estadística de la Universidad del Valle en cabeza del Dr. Rafael Tovar, por acogerme para realizar mi estancia doctoral

A Omar Alexander Ríos Saavedra por acompañarme durante mi estancia doctoral en Escuela de Estadística de la Universidad del Valle

A Sergio Barona, coordinador del Laboratorio de Economía Aplicada de la Universidad de Javeriana de Cali, por su apoyo incondicional en el procesamiento de datos.

A todos los colegas y personas de una u otra manera me apoyaron en este proceso de formación doctoral

TABLA DE CONTENIDO

INTRODUCCIÓN	15
CAPITULO 1: EL PAPEL DE LA CADENA DE SUMINISTRO GLOBAL Y LAS TENSIONES EN LOS PRECIOS DE LAS MATERIAS PRIMAS ALIMENTARIAS EN EL AUMENTO DE LA INFLACIÓN DE ALIMENTOS Y BEBIDAS EN ESTADOS UNIDOS	19
Resumen.....	19
Introducción	20
Métodos.....	27
Descripción de los datos.....	27
Metodología y modelación.....	30
Modelo de factores cuantílicos.....	31
Modelo FAVAR.....	34
Resultados y discusión	35
Prueba de robustez	43
Conclusiones	47
Referencias.....	49
Anexo 1.1 Clasificación de alimentos por categoría (Adaptado de FAO)	53
Anexo 1.2 Indicadores de la actividad económica y financiera de Estados Unidos.....	54
Anexo 1.3 Series de índices de precios internacionales de materias primas alimentarias después de la aplicación de los códigos de transformación (tcode).	55
CAPITULO 2. LOS EFECTOS DE LA VARIABILIDAD CLIMÁTICA, LA PRODUCTIVIDAD TOTAL DE LOS FACTORES AGRÍCOLAS Y LOS DETERMINANTES EXTERNOS SOBRE LA INFLACIÓN DE ALIMENTOS Y BEBIDAS EN LOS ESTADOS UNIDOS.....	57
Resumen.....	57
Introducción	59
Métodos.....	64
Descripción de los datos.....	64
Metodología y modelación.....	70
Modelo Factorial Cuantílico	71
Modelo FAVAR	73

Resultados	74
Robustez de los resultados	89
Modelacion Prepandemia	91
Modelación con variables adicionales	93
Modelos regionales	97
Conclusiones	99
Referencias	102
Anexo 2.1.	107
Descripción de los componentes del índice climático actuarial para Estados Unidos	107
CAPITULO 3. DESEMPEÑO PREDICTIVO DE MODELOS FACTORIALES Y REDES NEURONALES: UN ANÁLISIS COMPARATIVO DE LA INFLACIÓN DE ALIMENTOS Y BEBIDAS EN ESTADOS UNIDOS.	108
Resumen	108
Introducción.	109
Descripción de datos.	114
Metodología y Modelación	115
Modelo Autorregresivo AR(p)	115
Modelo Factorial Dinámico	116
Modelo Factorial Cuantílico	117
Codificador Denso de Series Temporales (TiDE)	118
Interpolación Jerárquica Neural para Series Temporales (NHITS)	119
Especificaciones de los modelos para el pronóstico	119
Resultados	121
Conclusiones	128
Referencias	129
CONCLUSIONES GENERALES, IMPLICACIONES PARA LA POLÍTICA ECONÓMICA Y LIMITACIONES	133
DIFUSIÓN DE RESULTADOS	138

LISTA DE FIGURAS

Figura 1.1 Inflación interanual de alimentos y bebidas en Estados Unidos. 1968 – 2022	21
Figura 1.2 Índices de precios internacionales de materias primas alimenticias y bebidas (2016=100). 1992:01-2023:06.....	28
Figura 1.3 Inflación interanual de alimentos y bebidas en Estados Unidos y el Índice de Presión de la Cadena Global de Suministro (GSCPI).....	30
Figura 1.4 Factores cuantílicos ExternalPrices, TensionPrices and USIncome.....	38
Figura 1.5 Respuestas acumuladas de la inflación de alimentos y bebidas ante choques en las variables del modelo.....	40
Figura 1.6 Respuestas acumuladas de la inflación de alimentos y bebidas ante choques en las variables del modelo usando como proxy la variación del IPP (VIPP).....	46
Figura 2.1 Índices de precios internacionales de materias primas alimenticias en Estados Unidos, 1992.01-2024.05.....	65
Figura 2.2 Variables macroeconómicas y financieras de los ingresos en Estados Unidos, 1992:01-2024:05.....	66
Figura 2.3 Productividad total de los factores en Estados Unidos (1992-2021)	69
Figura 2.4 Comportamiento de cada uno de los componentes como anomalía estandarizada del Índice Climático Actuarial (ACI) para Estados Unidos 1992:01–2024:05.....	75
Figura 2.5 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA).....	80
Figura 2.6 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de bajas temperaturas (DT10USA).....	83
Figura 2.7 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de la precipitación estandarizada (DPRECIUSA).....	84
Figura 2.8 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de los días secos consecutivos estandarizados (DCDDUSA).....	84
Figura 2.9 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de la velocidad del viento estandarizada (DWP90).....	85
Figura 2.10 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación del nivel del mar estandarizado (DSEAUSA).....	86
Figura 2.11 Respuestas acumuladas Cholesky de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA).....	90
Figura 2.12 Respuestas acumulativas de Cholesky de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de días secos consecutivos estandarizados (DCDDUSA).....	91

Figura 2.13 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA). Período prepandemia.	92
Figura 2.14 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de los días secos consecutivos estandarizados (DCDDUSA). Período prepandémico.....	93
Figura 2.15 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA), incluyendo la actividad económica global.	94
Figura 2.16 Respuestas acumulativas de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de días secos consecutivos estandarizados (DCDDUSA), incluyendo la actividad económica mundial....	95
Figura 2.17 Respuestas acumulativas de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA), incluyendo la tasa de interés real.	95
Figura 2.18 Respuestas acumulativas de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de los días secos consecutivos estandarizados (DCDDUSA), incluyendo la tasa de interés real.....	96
Figura 2.19 Respuestas acumulativas de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA) y el índice de precios de combustible y energía.....	96
Figura 2.20 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de los días secos consecutivos estandarizados (DCDDUSA) y el índice de precios de combustibles y energía.	97
Figura 2.21 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA) para la región del Medio Oeste.....	99

LISTA DE TABLAS

Tabla 3.1 <i>Desempeño predictivo fuera de muestra: ECM y ECM relativo.</i>	122
Tabla 3.2 <i>Test de Diebold–Mariano para la comparación de precisión predictiva (muestra completa)</i>	123
Tabla 3.3 <i>Desempeño predictivo por régimen inflacionario: ECM y ECM relativo</i>	125
Tabla 3. 4 <i>Test de Diebold-Mariano: comparación de precisión predictiva en régimen de inflación baja</i>	126
Tabla 3. 5 <i>Test de Diebold-Mariano: comparación de precisión predictiva en régimen de inflación alta.</i>	127

RESUMEN

La inflación de alimentos y bebidas en Estados Unidos ha adquirido una relevancia creciente tras el aumento sostenido de precios entre 2019 y 2023, con importantes implicaciones para el bienestar y la seguridad alimentaria. Esta tesis doctoral por compendio de artículos tiene dos objetivos: (i) analizar los determinantes de la inflación de alimentos y bebidas mediante un modelo VAR ampliado con factores extraídos de un modelo factorial cuantílico y (ii) evaluar el desempeño predictivo de modelos econométricos y de aprendizaje profundo.

El primer estudio muestra que las presiones en las cadenas de suministro globales y los precios internacionales de materias primas dominan la dinámica inflacionaria, evidenciando la primacía de los factores externos frente a los internos. El segundo estudio incorpora la variabilidad climática y la productividad agrícola, encontrando efectos climáticos limitados y una contribución moderada de la productividad, mientras que las disrupciones globales continúan siendo determinantes clave. El tercer estudio evalúa el desempeño predictivo, evidenciando que los modelos factoriales, particularmente aquellos que incorporan factores cuantílicos, mejoran la precisión en contextos de alta inflación, mientras que los modelos de aprendizaje profundo no presentan ventajas en horizontes de corto plazo.

Palabras clave: Inflación de alimentos; Factores externos; Factores cuantílicos; Modelos factoriales; Predicción.

ABSTRACT

Food and beverage inflation in the United States has gained increasing relevance following the sustained rise in prices between 2019 and 2023, with significant implications for welfare and food security. This doctoral thesis, composed of three essays, has two main objectives: (i) to analyze the determinants of food and beverage inflation using a VAR model augmented with factors extracted from a quantile factor model, and (ii) to evaluate the predictive performance of econometric and deep learning models.

The first study shows that global supply chain pressures and international commodity prices dominate inflation dynamics, highlighting the primacy of external over domestic factors. The second study incorporates climate variability and agricultural productivity, finding limited climate effects and a moderate contribution of productivity, while global disruptions remain key drivers. The third study evaluates predictive performance, showing that factor models—particularly those incorporating quantile factors—improve accuracy in high-inflation regimes, whereas deep learning models do not outperform in short-term horizons.

Keywords: Food inflation; External factors; Quantile factors; Factor models; Forecasting.

INTRODUCCIÓN

Desde una perspectiva teórica, la inflación ha sido tradicionalmente entendida como un fenómeno monetario en el largo plazo. No obstante, en horizontes de corto y mediano plazo, su dinámica responde a la interacción de factores de oferta y demanda, así como a la ocurrencia de choques externos. En los últimos años, y particularmente tras la pandemia de COVID-19, la inflación ha resurgido como uno de los principales desafíos macroeconómicos a nivel global, evidenciando limitaciones en los marcos analíticos convencionales para explicar episodios inflacionarios caracterizados por disrupciones simultáneas en múltiples frentes.

En este contexto, la inflación de alimentos y bebidas ha adquirido una relevancia particular debido a su impacto directo sobre el bienestar de los hogares y la seguridad alimentaria. En Estados Unidos, el aumento acumulado de más del 24% en los precios de alimentos y bebidas entre 2019 y 2023 constituye uno de los episodios inflacionarios más significativos de las últimas décadas. Este comportamiento ha estado estrechamente vinculado a choques globales, como la pandemia de COVID-19 —que generó disrupciones en las cadenas de suministro, escasez de insumos y aumentos en los costos de transporte— y el conflicto entre Rusia y Ucrania, que afectó la oferta internacional de productos clave como cereales, aceites y fertilizantes.

A pesar de la amplia literatura sobre inflación y sobre los precios de los alimentos, persisten vacíos importantes en la comprensión de la dinámica reciente de la inflación de alimentos y bebidas en economías desarrolladas. En particular, resulta fundamental determinar la importancia relativa de los factores externos —como los precios internacionales de materias primas y las tensiones en las cadenas de suministro— frente a factores internos, así como analizar el papel de

las dinámicas extremas en los precios internacionales. Asimismo, existe la necesidad de evaluar el desempeño de distintos enfoques metodológicos para la predicción de la inflación en contextos caracterizados por alta volatilidad y posibles cambios de régimen.

En este marco, la presente tesis doctoral por compendio de artículos tiene dos objetivos claramente diferenciados. Por un lado, analizar los determinantes de la inflación de alimentos y bebidas en Estados Unidos mediante un modelo VAR ampliado con factores extraídos a partir de un modelo factorial cuantílico. Por otro lado, evaluar el desempeño predictivo de distintos modelos econométricos y de aprendizaje profundo para pronosticar dicha inflación, considerando distintos regímenes inflacionarios.

Para cumplir con estos objetivos, la tesis se estructura en tres artículos interrelacionados. El primer artículo analiza la importancia relativa de los factores externos e internos en la inflación de alimentos y bebidas en Estados Unidos durante el período 1992.01–2023.06, evaluando el papel de los precios internacionales de materias primas y las presiones en las cadenas de suministro globales.

El segundo artículo amplía este análisis incorporando la dimensión climática y productiva, con el fin de evaluar el impacto de la variabilidad climática, la productividad agrícola y los factores externos sobre la inflación de alimentos en el período 1992.01–2024.05.

El tercer artículo aborda la dimensión predictiva, comparando el desempeño de modelos autorregresivos, modelos factoriales —incluyendo factores cuantílicos derivados de los precios internacionales— y arquitecturas de aprendizaje profundo, como el Codificador Denso para Series

Temporales (TiDE) y la Interpolación Jerárquica Neuronal para Series Temporales (NHITS), bajo un esquema de evaluación fuera de muestra.

Esta tesis contribuye a la literatura en cuatro dimensiones principales.

En primer lugar, aporta evidencia empírica robusta sobre la dominancia de los factores externos en la dinámica de la inflación de alimentos y bebidas en Estados Unidos.

En segundo lugar, introduce un enfoque metodológico basado en un modelo VAR ampliado con factores cuantílicos, lo que permite capturar dinámicas comunes en los extremos de la distribución de los precios internacionales de materias primas, aspecto que no es adecuadamente abordado por los modelos factoriales tradicionales.

En tercer lugar, integra la dimensión climática y productiva en un mismo marco empírico, ampliando la comprensión de los determinantes de la inflación.

En cuarto lugar, se evalúa de manera sistemática el desempeño de modelos econométricos y de aprendizaje profundo, evidenciando que su efectividad depende del régimen inflacionario.

En términos de relevancia aplicada, los resultados de esta investigación aportan elementos clave para el diseño de políticas económicas, al resaltar la importancia de los factores externos, las disrupciones globales y los riesgos asociados a movimientos extremos en los precios internacionales en la formulación de estrategias orientadas a contener la inflación de alimentos.

Finalmente, esta investigación se vincula con los Objetivos de Desarrollo Sostenible. En particular, contribuye al ODS 2: Hambre Cero, al analizar los factores que afectan la accesibilidad

y asequibilidad de los alimentos, y al ODS 13: Acción por el Clima, al incorporar la variabilidad climática y el papel de la innovación tecnológica como mecanismos de adaptación en el sector agrícola. De esta manera, la tesis aporta evidencia relevante para fortalecer la seguridad alimentaria y la resiliencia de los sistemas productivos frente a choques globales y climáticos.

CAPITULO 1: EL PAPEL DE LA CADENA DE SUMINISTRO GLOBAL Y LAS TENSIONES EN LOS PRECIOS DE LAS MATERIAS PRIMAS ALIMENTARIAS EN EL AUMENTO DE LA INFLACIÓN DE ALIMENTOS Y BEBIDAS EN ESTADOS UNIDOS

Resumen

La inflación en Estados Unidos fue del 19.2% entre 2019 y 2023, un aumento en los precios al consumidor no observado desde los años 80, que llevó a la FED a incrementar las tasas de interés en 3.10 puntos durante este período y tuvo costos elevados en términos del bienestar de los hogares. Los precios de alimentos y bebidas aumentaron más del 24% en el mismo período y fueron responsables del 17% de la inflación total. Este incremento en los precios de los alimentos se ha convertido en el centro del debate económico y social, siendo incluso un tema planteado en la campaña electoral de Estados Unidos de 2024.

Este estudio investiga los determinantes de la inflación de alimentos y bebidas en Estados Unidos. Más allá de determinantes comunes como factores externos o de demanda, se encontró que las presiones de la cadena de suministro global y los riesgos de presiones adicionales al alza en los precios de las materias primas desempeñan un papel significativo en la dinámica de la inflación de alimentos y bebidas en Estados Unidos, mientras que las condiciones macroeconómicas domésticas ejercen una influencia comparativamente limitada.

La metodología del artículo combina modelos de factores cuantílicos con un modelo vectorial autorregresivo aumentado por factores (FAVAR). Estos hallazgos proporcionan información relevante para comprender las vulnerabilidades inflacionarias y diseñar respuestas de política en presencia de choques en los precios de los alimentos impulsados por factores externos.

Palabras clave: inflación de alimentos y bebidas no alcohólicas, modelo de factores cuantílicos, modelo FAVAR.

Introducción

Desde un punto de vista teórico, la inflación es indudablemente un fenómeno monetario, especialmente en el largo plazo. Sin embargo, en el corto plazo, las fluctuaciones de precios pueden explicarse por contracciones del lado de la oferta o aumentos del lado de la demanda, o ambos. Debido a la dinámica inherente de los mercados, las economías no han sido inmunes a estos factores, y la inflación se ha convertido en un problema global significativo. Para muchos países, el período posterior a la pandemia se ha caracterizado por niveles de inflación por encima de los objetivos establecidos por sus bancos centrales. Esto ha causado una pérdida de poder adquisitivo y, en consecuencia, un deterioro en la calidad de vida de las personas al afectar, entre otras cosas, su acceso a los alimentos o, en otras palabras, su seguridad alimentaria. La inflación de los alimentos se ha convertido en un objeto de estudio de importancia fundamental.


Dos eventos recientes han impulsado significativamente la inflación global, particularmente en alimentos y bebidas. En primer lugar, la pandemia de COVID-19 condujo a aumentos pronunciados en los precios de materias primas clave como la soya, el maíz y el trigo, con el índice de precios del maíz aumentando por sí solo un 43% desde octubre de 2021 hasta octubre de 2022. El impacto de la pandemia se vio agravado por subsidios gubernamentales, confinamientos que interrumpieron las cadenas de suministro y una escasez de contenedores de transporte, lo que llevó a mayores costos de transporte y retrasos en las entregas de alimentos (Pakravan et al., 2021; Erokhin and Gao, 2020; Malakhail et al., 2023; Abdullaieva et al. 2022).

En segundo lugar, la guerra entre Ucrania y Rusia, que comenzó en febrero de 2022 y perturbó severamente el suministro global de materias primas esenciales como fertilizantes, cereales y aceite vegetal, impulsando aún más los precios y afectando la seguridad alimentaria global (Ben Hassen and El Bilali, 2022; Leal Filho et al., 2023; Barbir et al. 2023). La inflación de

los alimentos representa una amenaza seria para la seguridad alimentaria, particularmente para las poblaciones más pobres que destinan la mayor parte de sus ingresos a los alimentos, reduciendo así su ingreso real y su acceso a la nutrición esencial (Kalkuhl et al., 2016; Pakravan et al., 2021).

Estados Unidos, aunque es una de las economías más fuertes del mundo, no es inmune a las implicaciones de una alta inflación de alimentos. La tasa oficial de pobreza en 2022 fue del 11.5%, con 37.9 millones de personas viviendo en pobreza, y el 12.8% (17.0 millones) de los hogares en Estados Unidos experimentaron inseguridad alimentaria en algún momento de 2022 (Toossi and Jones, 2023).

Figura 0.1 Inflación interanual de alimentos y bebidas en Estados Unidos. 1968 – 2022



Fuente: Banco de la Reserva Federal de San Luis.

Como se puede observar en la Figura 1.1, los efectos de la pandemia y la guerra entre Ucrania y Rusia, que comenzó en febrero de 2022, han causado el mayor aumento en la inflación interanual de alimentos y bebidas en Estados Unidos desde los años 80, incrementándose más del

24% entre 2019 y 2023. La Figura 1.1 también refleja la crisis alimentaria de 2008, que generó una alta inflación del 6.33% en octubre como resultado de un incremento drástico en los precios internacionales de las materias primas. De acuerdo con Poncela et al. (2014) y Sierra et al. (2017), la financiarización en el mercado de materias primas condujo a una mayor comovilidad entre los precios de diferentes materias primas no energéticas después del final de 2003, así como al fortalecimiento de los vínculos intermercados entre las materias primas y el mercado accionario.

Este artículo analiza los determinantes de la inflación de alimentos y bebidas en Estados Unidos en el período 1992.01-2023.06, contribuyendo a la identificación de la principal fuente de inflación en este período. En particular, aborda la siguiente pregunta: ¿son los factores externos, como los precios internacionales de las materias primas alimentarias y las presiones de la cadena de suministro global, los principales factores determinantes de la inflación de alimentos en Estados Unidos, o son los factores internos, como la demanda doméstica y los ingresos de los hogares, la mayor fuente?

A partir de la pregunta de investigación anterior, se plantea la siguiente hipótesis de investigación: la inflación de alimentos en Estados Unidos presenta una naturaleza predominantemente externa, por lo que se espera que los factores asociados a las cadenas globales de suministro y a los mercados internacionales de materias primas ejerzan una influencia mayor sobre la dinámica de la inflación de alimentos que los factores internos relacionados con la demanda agregada.

Con el fin de contrastar esta hipótesis se plantea como objetivo evaluar la importancia relativa de los determinantes externos e internos de la inflación de alimentos en Estados Unidos.

Diversos estudios han explorado los determinantes de la inflación de alimentos en diferentes países y contextos. Iliyasu and Sanusi (2023), Bedasa and Bedemo (2023), y Ichoku et al. (2023) buscaron examinar los efectos del cambio climático, particularmente los cambios en la temperatura, sobre los precios internacionales de las materias primas. Encontraron que el cambio climático, en términos de temperatura, incrementa los precios de las materias primas, aumenta la inseguridad alimentaria y eleva la inflación de los precios de los alimentos. Mokni and Ben-Salha (2020), Sun et al. (2023), Raza et al. (2022), Ibrahim (2015), y Zmami and Ben-Salha (2019) exploraron la relación entre los precios del petróleo crudo y los precios globales de los alimentos utilizando diversas metodologías; encontraron que los precios del petróleo crudo son un determinante crítico de los precios de los alimentos.

Adicionalmente, Irz et al. (2013), Mahmoudinia (2021), Samal et al. (2022), Iddrisu and Alagidede (2020), Adjemian et al. (2023), y Cowley and Scott (2022) estudiaron los determinantes de la inflación de precios de los alimentos en diferentes países, identificando factores como los costos de insumos agrícolas, salarios, precios de la energía, política monetaria y tensiones en la cadena de suministro, con impactos que varían según el país y el contexto.

Para analizar la influencia de los determinantes externos sobre la inflación de alimentos y bebidas en Estados Unidos, se utilizó un Modelo Vectorial Autorregresivo Aumentado por Factores (FAVAR) desarrollado por Bernanke et al. (2005). En lugar de extender el modelo VAR con factores comunes, como fue propuesto por los autores anteriores, los factores se extraen a partir de un modelo de factores cuantílicos para capturar con mayor precisión los movimientos extremos en los precios internacionales de materias primas, particularmente en los cuantiles superiores e inferiores de la distribución. Estos cambios extremos podrían ser el resultado de

eventos importantes como la pandemia de COVID-19 y el conflicto entre Ucrania y Rusia.

El modelo de factores cuantílicos, propuesto por Chen et al. (2021), extrae factores comunes diferenciados para cada percentil a partir de un conjunto de variables vinculadas a la inflación de alimentos. Lo novedoso es que estos factores pueden variar en diferentes partes significativas de la distribución de las variables observadas, como en las colas, sin limitarse únicamente a la media, como lo hace el modelo de factores dinámicos.

Adicionalmente, tanto las cargas como los factores están condicionados por cuantiles, lo que añade un nivel adicional de detalle al análisis.

Para el análisis de la importancia de factores externos, como los precios internacionales de las materias primas alimentarias, en la determinación de la inflación de alimentos en Estados Unidos, se utiliza una base de datos compuesta por 28 series de precios internacionales proporcionadas por el Fondo Monetario Internacional (FMI). Considerando el fuerte impacto que tuvieron el COVID-19 y la guerra entre Ucrania y Rusia sobre los índices internacionales de precios de materias primas alimentarias, se utilizó el modelo de factores cuantílicos para extraer el primer factor del percentil 50 el cual captura la evolución mediana común de los índices de precios.

También se extrajo el primer factor del percentil 90, que se representa los movimientos que ocurren en la cola superior de las distribuciones de los índices internacionales de precios de materias primas alimentarias, capturando la dinámica común de los índices internacionales de precios en la cola superior de su distribución, asociada con escenarios de mayores tensiones inflacionarias. Este estudio no consideró lo que ocurre en la cola inferior de la distribución de los

índices internacionales de precios, ya que estos han tenido principalmente movimientos al alza debido al COVID-19 y la guerra entre Ucrania y Rusia.

En cuanto al análisis de factores internos como la demanda doméstica y el ingreso en Estados Unidos, se toman 28 series de actividad económica real y financiera de la base de datos proporcionada por el Federal Reserve Bank of St. Louis, denominada FRED-MD y desarrollada por McCracken & Ng. (2016). En este conjunto de series, se extrae el primer factor del percentil 50, relacionado con la evolución mediana del grupo de series vinculadas a la actividad económica real y financiera en Estados Unidos.

No se consideran factores en el extremo superior porque la actividad económica y financiera en el período analizado fue relativamente estable, excepto en el año en que ocurre el COVID-19.

Este estudio proporciona una comprensión más profunda del impacto de los altos precios internacionales de las materias primas alimentarias y de los determinantes de la inflación de alimentos en Estados Unidos. En este sentido, este artículo realiza tres contribuciones principales.

En primer lugar, proporciona nueva evidencia sobre la importancia relativa de los factores externos frente a los internos en la explicación de la dinámica de la inflación de alimentos en Estados Unidos.

En segundo lugar, propone un marco metodológico novedoso que combina modelos de factores cuantílicos con un Modelo Vectorial Autorregresivo Aumentado por Factores (FAVAR), permitiendo así el análisis conjunto tanto de las tendencias centrales como de la dinámica en la cola superior de los precios internacionales de materias primas. Específicamente, el marco incorpora el primer factor extraído del percentil 90 de los índices internacionales de precios de

materias primas alimentarias para capturar la dinámica común de los precios internacionales de las materias primas alimentarias en la cola superior de su distribución, asociada con escenarios de mayores riesgos inflacionarios.

A diferencia de los análisis estándar que se basan exclusivamente en el comportamiento mediano, este factor de cola representa el segmento superior de la distribución de precios y refleja el riesgo de intensificación de presiones durante períodos de aumentos globales en los precios de los alimentos, un enfoque consistente con el marco propuesto por López-Salido and Loria (2024). Por otro lado, también se incorpora el primer factor del percentil 50, que representa el movimiento común de las variables en condiciones normales. La principal novedad empírica reside en el tratamiento explícito del riesgo en las colas dentro de la estructura FAVAR.

En tercer lugar, el cálculo de las funciones de impulso-respuesta en este trabajo proporciona una evaluación rigurosa tanto de la magnitud como de la persistencia de los choques de la cadena de suministro global sobre la inflación de alimentos en Estados Unidos, a partir de un modelo que incorpora el Índice de Presión de la Cadena Global de Suministro (GSCPI). Aunque el GSCPI ha sido utilizado en estudios previos sobre inflación, su aplicación ha sido en gran medida descriptiva, como señalan Abbai et al. (2022).

Hasta donde alcanza el conocimiento de los autores, este es el primer estudio sobre inflación de alimentos que emplea un modelo FAVAR en el cual los factores se derivan de un modelo de factores cuantílicos, y en consecuencia, el primero en cuantificar la transmisión dinámica de los choques del GSCPI dentro de este entorno empírico enriquecido.

El resto del documento presenta la siguiente estructura. La Sección 2 (Métodos) presenta la descripción de los datos utilizados, la metodología desarrollada en esta investigación y la

modelación. La Sección 3 presenta los resultados. La sección 4 presenta las pruebas de robustez. La sección 5 presentan las principales conclusiones.

Métodos


Descripción de los datos

Esta sección describe los datos utilizados en el análisis de factores cuantílicos junto con otras variables observables adicionales. Para los dos modelos de factores cuantílicos, se examinan dos bases de datos: una de 28 series mensuales de índices de precios internacionales de materias primas alimentarias, obtenidas del Fondo Monetario Internacional (FMI); y otra de 28 series mensuales sobre indicadores macroeconómicos y financieros de Estados Unidos extraídas de la base de datos proporcionada por el Federal Reserve Bank of St. Louis, denominada FRED-MD y desarrollada por McCracken and Ng (2016).

El período para ambas bases fue de enero de 1992 a junio de 2023. La Figura 1.2 presenta algunas de las series mensuales de índices de precios internacionales de materias primas de alimentos y bebidas en cuatro paneles para una mejor apreciación de los movimientos de los índices.

La muestra presenta incrementos significativos en varios índices de precios de materias primas, particularmente aquellos relacionados con cereales y aceites vegetales, en 2008, así como durante los períodos de 2010-2011 y 2020-2021. El Anexo 1 presenta una lista de las materias primas utilizadas.

Figura 0.1 Índices de precios internacionales de materias primas alimenticias y bebidas (2016=100). 1992:01-2023:06.



Fuente: cálculos propios basados en los datos del FMI.

La segunda base de datos utilizada en este estudio comprende 28 series provenientes de FRED-MD, que cubren diversas variables macroeconómicas y financieras para Estados Unidos. Estos indicadores se agrupan en las siguientes categorías: Ingreso (2 variables), Producción (5), Consumo (4), Mercado laboral (5), Variables financieras (10), Transporte (1) y Sentimiento (1). Este amplio conjunto de datos incluye variables relacionadas con condiciones monetarias y financieras, como tasas de interés y otros indicadores financieros, que se incorporan en el análisis a través del factor latente extraído del modelo de factores cuantílicos. El Anexo 2 proporciona más detalles sobre cada una de las variables utilizadas.


Para el FAVAR, también se utilizó un conjunto de variables observables que podrían explicar teóricamente la inflación de alimentos y bebidas en Estados Unidos para el período analizado. Estas variables fueron la inflación excluyendo alimentos (NonFoodInf), que se

incorpora como una variable de control para aproximar las presiones inflacionarias distintas del componente alimentario. Dado que esta variable conserva el componente energético, ampliamente asociado en la literatura con la transmisión de choques de oferta y de costos hacia la inflación, se utiliza en este estudio como una aproximación a dichas presiones inflacionarias. Asimismo, se incorpora el Índice de la presión de la Cadena Global de Suministro (GSCPI), que es una medida parsimoniosa utilizada para evaluar la importancia de las restricciones de oferta sobre el desempeño económico.

La Figura 1.3 ilustra la relación entre la inflación interanual de alimentos y bebidas en Estados Unidos, la inflación interanual en Estados Unidos excluyendo alimentos y el GSCPI. En el lado izquierdo de la figura, se muestran la inflación interanual de alimentos y bebidas en Estados Unidos y el GSCPI. En el lado derecho, se presenta la inflación interanual en Estados Unidos excluyendo alimentos, junto con el mismo GSCPI, particularmente durante 2020 y 2021, lo que puede atribuirse a las disrupciones en los canales de comercialización tras la pandemia y la guerra entre Ucrania y Rusia.

Para validar esta relación, se calculó la correlación entre la inflación mensual de alimentos y bebidas y el GSCPI, encontrando una correlación de 0.48. En contraste, la correlación entre el GSCPI y la inflación mensual excluyendo alimentos es de solo 0.29. La mayor correlación entre el GSCPI y la inflación de alimentos y bebidas puede atribuirse a la naturaleza perecedera de los alimentos y bebidas, que tienen una vida útil limitada en comparación con otros bienes, y a su demanda inelástica, lo que los hace más susceptibles a disrupciones en las cadenas de suministro.

Figura 0.2 Inflación interanual de alimentos y bebidas en Estados Unidos y el Índice de Presión de la Cadena Global de Suministro (GSCPI).



Metodología y modelación

Esta sección presenta, en forma de resumen, el modelo de factores cuantílicos desarrollado por Chen et al. (2021) y el modelo VAR aumentado por factores (FAVAR), desarrollado por Bernanke et al. (2005), que serán utilizados en la sección empírica, el primero para extraer factores y el segundo para analizar la relación entre variables.

En este trabajo se combinan ambas metodologías ya que, de la misma manera que el estimador de Componentes Principales de factores y cargas desarrollado por Bai and Ng (2002) es consistente, el estimador de factores y cargas cuantílicas de Chen et al. (2021) también lo es.

Considerando que la base de datos de materias primas alimentarias proporcionada por el FMI presenta algunas materias primas en forma de índice y otras en precios en dólares, se decidió expresar todas las materias primas alimentarias como índices de precios con base 2016. Esto permite una mejor interpretación de la dinámica de los precios de las materias primas.

Los datos utilizados en esta investigación están desestacionalizados. En el caso de las 28 series de índices de precios internacionales de materias primas alimentarias del FMI, se aplicó el

test de Dickey-Fuller Aumentado para determinar la transformación apropiada de cada variable y obtener series estacionarias. Con base en estos resultados, se asignó a cada serie el código de transformación correspondiente (niveles, primeras diferencias, segundas diferencias y transformaciones logarítmicas, entre otros). Ver anexo 1.3

Para las 28 series de indicadores macroeconómicos y financieros de la base FRED-MD, se utilizaron los códigos de transformación suministrados por dicha base de datos (McCracken y Ng, 2016).

Posteriormente, siguiendo el procedimiento propuesto por Chen et al. (2021), las funciones auxiliares desarrolladas por dichos autores aplicaron automáticamente los códigos de transformación definidos para cada serie.

Finalmente, las series transformadas fueron estandarizadas para estimar el modelo de factores cuantílicos, evitando que diferencias de escala entre las variables dominen la estimación de los factores comunes. propone extender la propuesta de Bernanke et al. (2005) basado en factores comunes en la media hacia un enfoque de factores comunes cuantílicos

Modelo de factores cuantílicos

La inflación de alimentos es una variable macroeconómica cuya comprensión requiere considerar un conjunto de variables relacionadas como tasas de interés, tipo de cambio, precio de materias primas, precio internacional del petróleo, entre otras. Un aspecto importante de las materias primas y algunas variables macroeconómicas, según Pindyck and Rotemberg (1990), es su tendencia a presentar comovimientos como resultado de un mismo choque o choque inesperado, por ejemplo, la pandemia de COVID-19 o la guerra entre Ucrania y Rusia.

En este contexto, aparecen los modelos de factores dinámicos, que permiten describir las fluctuaciones estocásticas de un gran número de series a través de la combinación lineal de un pequeño conjunto de factores no observables o latentes, comunes al conjunto de series, y un término idiosincrático específico de cada serie que no es explicado por el componente común.

Estos modelos capturan principalmente comovimientos promedio y pueden fallar en reflejar adecuadamente fluctuaciones extremas en los precios de materias primas, particularmente durante períodos de alta volatilidad como la pandemia de COVID-19 y el conflicto entre Ucrania y Rusia.

El modelo de factores cuantílicos amplía el modelo de factores dinámicos al permitir que tanto los factores latentes como las cargas factoriales dependan del cuantil considerado. Los factores latentes se extraen del conjunto de variables asociadas con la inflación y pueden variar en diferentes partes relevantes de la distribución de las variables observadas, como las colas, y no únicamente en la media, como ocurre en el modelo de factores dinámicos tradicional. En consecuencia, tanto las cargas como los factores reflejan la dinámica específica de cada cuantil.

En particular, este estudio se enfoca en el percentil 50 para capturar la dinámica promedio del mercado y en el percentil 90 para identificar movimientos en la cola superior asociados con mayores presiones inflacionarias y riesgos inflacionarios en los mercados internacionales de materias primas.

En este trabajo, para obtener los factores no observables que se incorporan en el VAR, se aplicó el modelo de factores cuantílicos (QFM) propuesto por Chen et al. (2021). La estructura general de este modelo es la siguiente: Supongamos que la variable observada X_{it} with $i = 1, 2, \dots, N$ y $t = 1, 2, \dots, T$ es generada por un componente común más uno idiosincrático. Para

caracterizar la distribución de X_{it} , se tendrá un componente común diferente para cada cuantil de la distribución.

$$\lambda'_i(\tau)f_t(\tau) \text{ for } \tau \in (0,1)$$

donde los factores comunes $f_t(\tau)$ son vectores de variables aleatorias no observables de dimensión $r(\tau) \times 1$, $\lambda'_i(\tau)$ es un vector de cargas no aleatorias de dimensión $1 \times r(\tau)$ con $r(\tau) \ll N$. El QFM así definido permite que los factores, las cargas y el número de factores dependan de los cuantiles.

El modelo completo puede escribirse como:

$$X_{it} = \lambda'_i(\tau)f_t(\tau) + U_{it}(\tau) \quad (1)$$

donde el error idiosincrático dependiente del cuantil $U_{it}(\tau)$ satisface las siguientes restricciones:

$$P[U_{it}(\tau) \leq 0 | f_t(\tau)] = \tau \text{ y } Q_{U_{it}}[\tau | f_t(\tau)] = 0,$$

donde $U_{it}(\tau)$ es la perturbación aleatoria correspondiente al cuantil τ condicionado a $f_t(\tau)$.

El estimador aproximado de factores y cargas cuantílicas (AFQ), asumiendo que el número de factores es conocido, se define como:

$$\hat{\theta} = (\hat{\lambda}'_1, \dots, \hat{\lambda}'_N, \hat{f}'_1, \dots, \hat{f}'_T)' = \underset{\theta \in \Theta^r}{\operatorname{argmin}} \mathbb{M}_{NT}(\theta)$$

$$\text{donde } \mathbb{M}_{NT}(\theta) = \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T \rho_\tau(X_{it} - \lambda'_i f_t)$$

y $\rho_\tau(u) = (\tau - \mathbf{1}\{u \leq 0\})u$ es la función de verificación. Tanto las cargas como los factores estimados dependen de los cuantiles.

El estimador de factores y cargas comunes cuantílicos es consistente cuando tanto la dimensión temporal T como el tamaño de la sección transversal N tienden a infinito.

Resolver el problema de minimización anterior no produce una forma analítica cerrada. Por esta razón, Chen et al. (2021) desarrollan un algoritmo computacional denominado regresión cuantílica iterativa (RCI).

Los autores también proponen dos métodos para estimar el número apropiado de factores comunes en cada cuantil. El primero consiste en minimizar los rangos de ciertas matrices derivadas de los datos, lo que permite identificar el número de factores que mejor capturan la estructura de dependencia, mientras que el segundo utiliza criterios de información (IC) y es similar a los de Bai and Ng (2002). Ambos métodos producen estimadores consistentes. Para una descripción más detallada de los métodos, véase Chen et al. (2021).

Modelo FAVAR

Inspirados en Bernanke et al. (2005), se presenta un nuevo modelo VAR aumentado por factores (FAVAR), donde los factores provienen de un modelo de factores cuantílicos. Sea Y_t el vector de dimensión M de variables observadas (inflación mensual de alimentos, inflación excluyendo alimentos y el Índice de Presión de la Cadena Global de Suministro (GSCPI). Para incluir información que no se obtiene en Y_t , considérese el vector F_t de factores no observados de dimension $K \times 1$. Así, la dinámica conjunta de (F_t, Y_t) está dada por la siguiente ecuación

$$\begin{bmatrix} F_t \\ Y_t \end{bmatrix} = \Phi(L) \begin{bmatrix} F_{t-1} \\ Y_{t-1} \end{bmatrix} + v_t \quad (2)$$

donde $\Phi(L)$ es una matriz $(K+M) \times (K+M)$ de polinomios en el operador de rezago y el término de error v_t es ruido blanco multivariado, es decir, el vector $(K + M)$ $v_t \sim (0, Q)$.

Los factores incorporados en el modelo FAVAR se obtienen mediante un enfoque factorial por bloques. En particular, se consideran dos bloques de información diferenciados según su naturaleza económica. El primero está conformado por los índices de precios internacionales de

materias primas alimentarias, mientras que el segundo comprende las series de indicadores macroeconómicos y financieros de Estados Unidos. A partir de cada bloque se extraen los factores comunes cuantílicos que posteriormente se incorporan al modelo FAVAR.

En este caso, el modelo FAVAR incluye los primeros factores de los percentiles 50 y 90 de los índices de precios internacionales de materias primas alimentarias (en adelante denominados *ExternalPrices* y *TensionPrices*, respectivamente). Adicionalmente, incluye el primer factor del percentil 50 de las 28 series mensuales de indicadores macroeconómicos y financieros de Estados Unidos, al cual denominamos *USIncome*. Junto con estos factores, el modelo incorpora un conjunto de variables observables teóricamente vinculadas a la inflación de alimentos y bebidas en Estados Unidos durante el período analizado. Como se discutió en la sección anterior, estas variables observables incluyen la inflación mensual de alimentos (*FoodInfl*), la inflación excluyendo alimentos (*NonFoodInf*) y el Índice de Presión de la Cadena Global de Suministro (*GSCPI*). Por lo tanto, el modelo FAVAR analiza la relación entre las variables mencionadas anteriormente y los factores comunes cuantílicos de la siguiente manera:

:

$$\begin{bmatrix} F_t \\ Y_t \end{bmatrix} = \begin{bmatrix} \text{ExternalPrices}_t \\ \text{TensionPrices}_t \\ \text{USIncome}_t \\ \text{FoodInfl}_t \\ \text{NonFoodInf}_t \\ \text{GSCPI}_t \end{bmatrix} = \Phi(L) \begin{bmatrix} \text{ExternalPrices}_{t-1} \\ \text{TensionPrices}_{t-1} \\ \text{USIncome}_{t-1} \\ \text{FoodInfl}_{t-1} \\ \text{NonFoodInf}_{t-1} \\ \text{GSCPI}_{t-1} \end{bmatrix} + v_t \quad (3)$$

donde $\Phi(L)$ y v_t han sido definidos previamente.

Resultados y discusión

En esta sección se presentan los principales resultados empíricos de la investigación. En primer lugar, se describen las características estadísticas de las variables incorporadas en el modelo

FAVAR. Posteriormente, se analizan los factores cuantílicos estimados y, finalmente, se presentan las funciones de impulso-respuesta del modelo FAVAR para evaluar la importancia relativa de los determinantes externos e internos de la inflación de alimentos en Estados Unidos.

Tabla 1.1 Estadísticas descriptivas de las variables del modelo FAVAR

Variable	Descripción	Orden de integración	media	Desviación Estándar	Mínimo	Máximo
ExternalPrices	Primer factor cuantílico (P50) de índices precios internacionales de materias primas alimentarias	I(0)	0.005	1.002	-5.102	3.13
TensionPrices	Primer factor cuantílico (P90) de índices precios internacionales de materias primas alimentarias	I(0)	0.885	0.465	-0.532	3.06
USIncome	Primer factor cuantílico (P50) de indicadores macroeconómicos y financieros de EE.UU	I(0)	0.003	1.001	-14.197	5.33
FoodInfl	Inflación mensual de alimentos y bebidas	I(0)	0.228	0.251	-0.375	1.38
NonFoodInf	Inflación mensual excluyendo alimentos	I(0)	0.204	0.314	-2.114	1.51
GSCPI	Índice de presión de la Cadena Global de Suministro	I(0)	0.029	1.000	-1.57	4.32

Fuente: Cálculos propios


La Tabla 1.1 presenta las estadísticas descriptivas de las variables incorporadas en el modelo FAVAR. Todas las variables presentan un orden de integración I(0), condición necesaria

para la estimación del modelo. Los factores cuantílicos *ExternalPrices* y *USIncome* exhiben desviaciones estándar cercanas a la unidad, resultado esperado debido a la estandarización aplicada durante la estimación del modelo de factores cuantílicos. En contraste, el factor *TensionPrices* presenta una menor desviación estándar (0.465), lo que indica una menor variabilidad del componente común asociado al percentil 90 respecto al factor correspondiente al percentil 50.

Las variables de inflación (*FoodInfl* y *NonFoodInfl*) presentan una dispersión considerablemente menor que los factores y el GSCPI, reflejando que las tasas mensuales de inflación fluctúan dentro de un rango relativamente acotado durante el período de estudio. Por su parte, el GSCPI presenta una desviación estándar cercana a la unidad y el mayor valor máximo (4.32), evidenciando la existencia de episodios de fuertes presiones sobre las cadenas globales de suministro, particularmente durante la pandemia de COVID-19 y el conflicto entre Ucrania y Rusia.

Siguiendo el procedimiento desarrollado por Chen et al. (2021), se obtienen cinco factores para el percentil 50, tanto para la base de datos de índices de precios internacionales de alimentos como para la base de datos FRED. Para el percentil 90 del índice de precios internacionales de alimentos, solo se obtienen dos factores. Sin embargo, tanto para el percentil 50 como para el 90, solo se considera el primer factor porque explica la mayor proporción de la variabilidad. Recuérdese que el número de factores en el modelo de factores cuantílicos depende del percentil considerado.

Figura 0.3 Factores cuantílicos ExternalPrices, TensionPrices and USIncome.



La Figura 1.4 presenta los factores cuantílicos. En la parte superior izquierda se encuentra el factor ExternalPrices, en la parte superior derecha el factor TensionPrices, y en la parte inferior izquierda el factor USIncome. Estos factores, que serán incluidos en el modelo FAVAR, son estacionarios.

El factor TensionPrices, ubicado en la cola superior de la distribución, tiene una desviación estándar de 0.46, mientras que el factor ExternalPrices, ubicado en la mediana de la distribución, tiene una desviación estándar de 1.002. Esto indica que el factor común asociado al percentil 90 presenta una menor variabilidad que el factor común asociado al percentil 50.

Una posible interpretación económica de este resultado es que, durante episodios de incrementos extremos en los precios internacionales de las materias primas alimentarias, los choques globales comunes tienden a generar movimientos más sincronizados entre las distintas materias primas. En consecuencia, el factor común asociado al percentil 90 refleja una dinámica conjunta más homogénea que la observada alrededor de la mediana de la distribución, donde los precios responden en mayor medida a factores específicos de cada mercado.

Por su parte, el factor USIncome representa el ciclo económico en Estados Unidos, con las mayores recesiones en 2001, 2008 y 2020.


Por otro lado, para definir el número de rezagos del FAVAR se probaron diferentes especificaciones con diferentes órdenes de rezago y, para cada una de ellas, se aplicó la prueba LM Test para correlación serial. Se seleccionó el menor número de rezagos para el cual no se rechazó la hipótesis nula de ausencia de autocorrelación serial en los residuos, garantizando así una especificación adecuada del modelo y evitando la inclusión de rezagos innecesarios.

Adicionalmente, se construyeron variables de impulso en aquellos meses en los que hubo cambios repentinos y temporales en el comportamiento de la inflación de alimentos y bebidas. Estas variables se consideraron en septiembre de 2008, y en los meses de febrero, marzo, abril y mayo de 2020. Por otro lado, este estudio emplea las funciones de impulso-respuesta generalizadas (GIRFs) propuestas por Pesaran and Shin (1998) para rastrear los efectos dinámicos de los choques a través de las variables del sistema. A diferencia de las respuestas ortogonalizadas basadas en la descomposición de Cholesky, las respuestas de impulso generalizadas no dependen de restricciones de identificación impuestas a través del ordenamiento de las variables y son invariantes al orden de las variables en el sistema VAR.

La Figura 1.5 muestra la respuesta acumulada de la inflación de alimentos y bebidas en Estados Unidos ante choques relacionados con las diferentes variables del modelo. La Figura 5a muestra el impacto total de un choque al primer factor del percentil 50 (ExternalPrices). Como puede observarse, el impacto es creciente y sostenido a lo largo de un horizonte temporal considerado de 20 meses. Este resultado sugiere que existe una transmisión de los precios internacionales de materias primas hacia la inflación de alimentos en Estados Unidos, y que este

efecto es significativo y persistente, como lo muestra la función de impulso-respuesta. Este resultado coincide con los encontrados por Vos et al. (2022), quienes sugieren que el precio de algunas materias primas aumentó significativamente después de la pandemia. Desde una perspectiva de política, los resultados sugieren que las políticas orientadas exclusivamente a la gestión de la demanda podrían ser insuficientes para contener la inflación en alimentos y bebidas, dado que una parte importante de las presiones inflacionarias parece originarse en los mercados internacionales de materias primas y en las restricciones de las cadenas globales de suministro. En consecuencia, la mitigación efectiva de la inflación puede requerir medidas complementarias orientadas a reducir la vulnerabilidad a choques externos, tales como mejorar la resiliencia de la oferta y diversificar los canales de abastecimiento.

Figura 0.4 Respuestas acumuladas de la inflación de alimentos y bebidas ante choques en las variables del modelo.



Fuente: cálculos propios.

Un impacto similar sobre la inflación de alimentos y bebidas en Estados Unidos se observa cuando ocurre un choque en el factor de inflación internacional del percentil 90 (TensionPrices), el cual captura los riesgos de mayores presiones al alza que se acentúan cuando los índices de precios internacionales de materias primas alimentarias aumentan como resultado de un choque. Esto es consistente con la respuesta observada ante la guerra entre Rusia y Ucrania, véase, por ejemplo, la Figura 1.5b. Estos resultados están en línea con los hallazgos de Abdullaieva et al. (2022) y Malakhail et al. (2023), quienes señalan que la guerra entre Ucrania y Rusia, que comenzó en febrero de 2022, interrumpió los suministros de materias primas, generando escasez y, en consecuencia, impulsando al alza los precios de estas. De acuerdo con Martin-Roda et al. (2022), tanto Rusia como Ucrania desempeñan un papel central en el suministro de fertilizantes para el sector agrícola y de materias primas como cereales y aceite vegetal para diferentes sectores de la economía a nivel mundial. Cuando comenzó la invasión de Rusia a Ucrania, el 30% de las exportaciones internacionales de trigo provenían de estos dos países. También controlaban el 60% del mercado mundial de aceite de girasol y el 15% del mercado de maíz. A modo de ejemplo, según los cálculos realizados con información proporcionada por el FMI, el índice de precios del maíz aumentó entre octubre de 2021 y octubre de 2022 en un 42.1%, mientras que el del sorgo para el mismo período aumentó en un 25%. La relevancia de este factor de cola superior sugiere además que los responsables de política deberían monitorear no solo la dinámica promedio de los precios de las materias primas, sino también los movimientos extremos al alza en los mercados internacionales, ya que estos episodios pueden generar presiones inflacionarias desproporcionadamente grandes en los precios domésticos de los alimentos.

En contraste con los impactos sobre la inflación de alimentos y bebidas derivados de choques en *ExternalPrices* y *TensionPrices* (primeros factores de los percentiles 50 y 90, respectivamente), la Figura 1.5c muestra que un choque en *USIncome* (el primer factor del percentil 50 de las variables macroeconómicas y financieras promedio de Estados Unidos) no afecta significativamente la inflación de alimentos en Estados Unidos en un horizonte de 20 meses. Este resultado sugiere que el consumo de alimentos no aumenta proporcionalmente con el ingreso, como es ampliamente reconocido en la literatura económica; los alimentos presentan una menor elasticidad ingreso en comparación con los bienes no esenciales. En consecuencia, los precios de los alimentos no están significativamente influenciados por el estado general de la economía (representado por indicadores macroeconómicos y financieros). Este hallazgo es consistente con las leyes de Engel y Bennett, que implican que la demanda de alimentos es menos sensible a cambios en el ingreso y los precios, particularmente en niveles de ingreso más altos (Timmer et al., 1983). Por lo tanto, aunque un choque en *USIncome* puede impactar la inflación de alimentos, su efecto no es significativo. Este resultado también sugiere que las políticas contractivas convencionales orientadas a reducir la demanda agregada pueden tener una efectividad limitada para contener la inflación de alimentos cuando las presiones inflacionarias están predominantemente impulsadas por factores externos del lado de la oferta.

La Figura 1.5d muestra el impacto de los choques en las cadenas de suministro sobre la inflación de alimentos en Estados Unidos, utilizando la función de impulso-respuesta. Como puede observarse, el impacto es creciente y sostenido, lo cual puede explicarse por factores como la pandemia de COVID-19, que dio lugar a la crisis de contenedores. La falta de contenedores provocó la disrupción de la cadena de suministro, ya que muchos insumos o materias primas no

llegaron a tiempo, generando en algunos casos especulación. De igual forma, el inicio de la guerra entre Rusia y Ucrania provocó una escasez de insumos para la mayoría de los países, ya que la cadena de suministro a través del Mar Negro también se vio interrumpida, reduciendo las exportaciones de estos países en conflicto. Los resultados se alinean con los de Abbai et al. (2022) al destacar las disrupciones en la cadena de suministro como un determinante principal de la inflación en Estados Unidos. En términos de política, este resultado subraya la importancia de fortalecer la infraestructura logística y mejorar la resiliencia de la cadena de suministro como mecanismos complementarios para mitigar las presiones inflacionarias durante períodos de disrupción global.

Por otro lado, el impacto total de un choque en la inflación excluyendo alimentos sobre la inflación de alimentos es significativo, pero no persistente. A partir del mes 10, este impacto tiende a disminuir lentamente, véase la Figura 1.5e. Esto sugiere que las presiones generalizadas de precios domésticos pueden transmitirse a la inflación de alimentos en el corto plazo, aunque sus efectos parecen ser menos persistentes que aquellos asociados con los choques en materias primas internacionales y en la cadena de suministro.

Finalmente, la Figura 1.5f ilustra el impacto total de la inflación de alimentos y bebidas en Estados Unidos sobre sus propios precios. Como se muestra en la figura, este impacto aumenta durante los tres primeros períodos antes de disminuir gradualmente, estabilizándose finalmente en su valor de largo plazo.

Prueba de robustez

Para evaluar la robustez de los resultados, la variable inflación excluyendo alimentos (NonFoodInf) fue reemplazada por la variación del Índice de Precios al Productor (VIPP), el cual

incorpora el componente energético y constituye un indicador de la evolución de los costos de producción. Durante el período analizado, el VIPP presenta una correlación de 0.765 con la inflación excluyendo alimentos, lo que indica que ambas variables comparten una parte importante de su comportamiento y respalda su utilización como medida alternativa en la prueba de robustez. La Figura 1.6 presenta las funciones de impulso-respuesta acumuladas obtenidas con esta especificación alternativa del modelo FAVAR.

Las Figuras 1.6a y 1.6b muestran que las respuestas de la inflación de alimentos ante choques en los factores *ExternalPrices* y *TensionPrices* conservan prácticamente la misma dinámica observada en la especificación base. De igual forma, la Figura 1.6d indica que la respuesta frente a un choque en el Índice de Presión de la Cadena Global de Suministro (GSCPI) es muy similar a la obtenida cuando se utiliza la inflación excluyendo alimentos. Finalmente, la Figura 1.6e muestra que la respuesta de la inflación de alimentos a un choque en la VIPP también mantiene un comportamiento comparable al observado con la especificación original.


La principal diferencia se observa en la Figura 1.6c. Cuando la inflación excluyendo alimentos se utiliza como variable de control, el factor *USIncome* no presenta un efecto significativo sobre la inflación de alimentos. En contraste, al utilizar la VIPP, un choque en este factor genera una reducción transitoria de la inflación durante los tres primeros períodos. Posteriormente, el efecto pierde magnitud y converge gradualmente hacia cero a partir del período ocho.

En conjunto, estos resultados muestran que las principales conclusiones del estudio permanecen prácticamente inalteradas al sustituir la inflación excluyendo alimentos por la VIPP.

En consecuencia, la mayor importancia de los determinantes externos sobre la inflación de alimentos no depende de la variable proxy utilizada para representar las condiciones internas de precios, lo que constituye evidencia adicional de la robustez del modelo

Figura 0.5 Respuestas acumuladas de la inflación de alimentos y bebidas ante choques en las variables del modelo usando como proxy la variación del IPP (VIPP).

Accumulated Response of FoodInfl To.



Fuente: Cálculos propios

Adicionalmente, se realizaron otros ejercicios de robustez en relación con la inclusión del factor cuantílico de cola superior. Cuando el factor del percentil 90 fue excluido del modelo, los diagnósticos de los residuos revelaron autocorrelación sustancial en múltiples horizontes, indicando un deterioro en la especificación del modelo y subrayando la relevancia de incorporar la dinámica de precios de materias primas en la cola superior. Este hallazgo sugiere que el percentil 90 constituye un umbral más apropiado para capturar tensiones inflacionarias en los mercados internacionales de materias primas, reforzando así la consistencia de la especificación seleccionada y la robustez de las variables incluidas en el modelo base.

Conclusiones

La inflación de alimentos en Estados Unidos es un fenómeno complejo impulsado por múltiples factores. Sin embargo, los hallazgos de esta investigación indican que los factores externos son principalmente responsables, al menos en parte, de su variabilidad. Los dos eventos más influyentes que afectaron la inflación de alimentos y bebidas en Estados Unidos fueron la pandemia de COVID-19 y la guerra entre Rusia y Ucrania. Estos eventos interrumpieron las cadenas de suministro: primero, a través de la crisis de contenedores desencadenada por el COVID-19, y segundo, mediante una disminución en las exportaciones de cereales, trigo, aceite de girasol y fertilizantes desde Rusia y Ucrania hacia el resto del mundo a través del Mar Negro como consecuencia de la guerra. Las funciones de impulso-respuesta del modelo revelan un impacto positivo significativo de un choque en el Índice de presión de la Cadena Global de Suministro (GSCPI) sobre la inflación de alimentos y bebidas en Estados Unidos.

Los resultados muestran que las fluctuaciones que ocurren en la cola superior de las distribuciones de los índices de precios internacionales de materias primas alimentarias —que miden el riesgo de presiones inflacionarias al alza— tienen un efecto significativo sobre la inflación de alimentos y bebidas en Estados Unidos.

Por otro lado, la inflación excluyendo alimentos influye en la inflación de alimentos y bebidas, aunque este impacto comienza a disminuir alrededor del período 14. Las pruebas de robustez confirman la significancia de variables como el aumento de los precios de materias primas y las presiones en la cadena de suministro global sobre la inflación de alimentos y bebidas en Estados Unidos.

Además, los resultados sugieren que las condiciones macroeconómicas y financieras domésticas ejercen una influencia comparativamente limitada sobre la inflación de alimentos en Estados Unidos, ya que los choques asociados con el ingreso en Estados Unidos no producen efectos estadísticamente significativos en el horizonte analizado. Este hallazgo refuerza la idea de que la dinámica de la inflación de alimentos durante el período de muestra fue predominantemente impulsada por factores externos más que por factores internos. Adicionalmente, el análisis de robustez respalda la adecuación de la especificación del modelo propuesto, particularmente la inclusión del factor del percentil 90 como una medida relevante del riesgo inflacionario asociado con movimientos extremos en los precios internacionales de materias primas.

Se espera que estos hallazgos mejoren la comprensión de la inflación de alimentos, proporcionando información valiosa para orientar a los responsables de política en Estados Unidos.

Los resultados convergen con los de Auer et al. (2019) y Garrón et al. (2024) al enfatizar la creciente importancia de los factores internacionales en la configuración de la dinámica inflacionaria doméstica. En particular, se subrayan el papel de los encadenamientos internacionales de insumo-producto y la menor sensibilidad de la inflación en economías más desarrolladas a la actividad económica doméstica. Estos hallazgos resaltan la necesidad de que los responsables de política se enfoquen en las vulnerabilidades internacionales al diseñar e implementar la política monetaria.

Referencias

- Abbai, B., Akinci, O., Benigno, G., di Giovanni, J., Groen, J. J., Heymann, R. C., ... & Noble, A. I. (2022). *The global supply side of inflationary pressures* (No. 20220128). Federal Reserve Bank of New York.
- Abdullaieva, A., Andrusenko, N., Hromová, O., Martynova, L., Prutska, O., & Yurchyk, I. (2022). The Impact of the Russian-Ukrainian War on EU Food Security. *Economic Affairs*, 67(4s), 859-867.
- Adjemian, M. K., Li, Q., & Jo, J. (2023). *Decomposing Food Price Inflation into Supply and Demand Shocks. Working paper*, July 12.
- Bai, J., & Ng, S. (2002). Determining the number of factors in approximate factor models. *Econometrica*, 70(1), 191-221.
- Barbir, J., Lisovska, T., Lingos, A., & Baars, C. (2023). *How the War in Ukraine Affects Food Security*. *Foods*, 12(21), 3996
- Bedasa, Y., & Bedemo, A. (2023). The effect of climate change on food insecurity in the Horn of Africa. *Geojournal*, 88(2), 1829-1839.

- Ben Hassen, T., & El Bilali, H. (2022). *Impacts of the Russia-Ukraine War on Global Food Security: Towards More Sustainable and Resilient Food Systems?* *Foods*, 11(15), 2301.
- Bernanke, B. S., Boivin, J., & Elias, P. (2005). Measuring the effects of monetary policy: a factor-augmented vector autoregressive (FAVAR) approach. *The Quarterly Journal of Economics*, 120(1), 387-422.
- Chen, L., Dolado, J. J., & Gonzalo, J. (2021). Quantile factor models. *Econometrica*, 89(2), 875-910.
- Cowley, C., & Scott, F. (2022). Commodity Prices Have Limited Influence on US Food Inflation. *Economic Bulletin*, (September 23, 2022), 1-4.
- Erokhin, V., & Gao, T. (2020). Impacts of COVID-19 on trade and economic aspects of food security: Evidence from 45 developing countries. *International Journal of Environmental Research and Public Health*, 17(16), 5775.
- Furceri, D., Loungani, P., Simon, J., & Wachter, S. M. (2016). Global food prices and domestic inflation: some cross-country evidence. *Oxford Economic Papers*, 68(3), 665-687.
- Garrón, I., Rodríguez-Caballero, C. V., & Ruiz, E. (2024). *International vulnerability of inflation* (No. 2410.20628).
- Ibrahim, M. H. (2015). Oil and food prices in Malaysia: a nonlinear ARDL analysis. *Agricultural and Food Economics*, 3(1), 1-14.
- Ichoku, H., Anthony, I., Olushola, T., & Martins, A. (2023). Modelling Dynamic Linkage between Climate Change and Food Inflation in Nigeria. *International Journal of Environment and Climate Change*, 13(11), 1200-1217.

Iddrisu, A. A., & Alagidede, I. P. (2020). Monetary policy and food inflation in South Africa: A quantile regression analysis. *Food Policy*, 91, 101816. Monetary policy and food inflation in South Africa: a quantile regression analysis. *Food Policy*, 91, 101816.

Iliyasu, J., & Sanusi, A. R. (2023). Climate change's impact on commodity prices: a new challenge for monetary policy. *Portuguese Economic Journal*, 1-26.

International Monetary Fund (IMF). Primary Commodity Prices. (2023). <https://www.imf.org/en/Research/commodity-prices>

Irz, X., Niemi, J., & Liu, X. (2013). Determinants of food price inflation in Finland—The role of energy. *Energy Policy*, 63, 656-663.

Kalkuhl, M., von Braun, J., & Torero, M. (2016). Volatile and extreme food prices, food security, and policy: an overview. En Kalkuhl, M., von Braun, J., & Torero, M. (Ed.), *Food price volatility and its implications for food security and policy* (pp. 3-31). Springer Open

Leal Filho, W., Fedoruk, M., Paulino Pires Eustachio, J. H., Barbir, J., Lisovska, T., Lingos, A., & Baars, C. (2023). How the war in Ukraine affects food security. *Foods*, 12(21), 3996.

Lopez-Salido, D., & Loria, F. (2024). Inflation at risk. *Journal of Monetary Economics*, 103570.

Mahmoudinia, D. (2021). The asymmetric effects of monetary policy, currency crises and oil price on food inflation in Iran: An application of quantile regression. *Macroeconomics and Finance in Emerging Market Economies*, 1-23.

Malakhail, F., Debnath, D., & Wiesthoff, P. (2023). Causes of food inflation in North America: COVID-19 and the Russia-Ukraine war. *Studies in Agricultural Economics*, 125(2).

Mankiw, G. (2006). *Macroeconomía*, (6ta edición), ed. Antoni Bosch, España.

- McCracken, M. W., & Ng, S. (2016). FRED-MD: A monthly database for macroeconomic research. *Journal of Business & Economic Statistics*, 34(4), 574-589.
<http://research.stlouisfed.org/econ/mccracken/>
- Mokni, K., & Ben-Salha, O. (2020). Asymmetric causality in quantiles analysis of the oil-food nexus since the 1960s. *Resources Policy*, 69, 101874.
- Martín-Roda, E. M., & Yago, F. M. (2022) Perturbaciones agrarias derivadas de la guerra ruso-ucraniana. *ESPAÑA 2022 UN BALANCE* N° 181, 38.
- Pakravan-Charvadeh, M. R., Mohammadi-Nasrabadi, F., Gholamrezai, S., Vatanparast, H., Flora, C., & Nabavi-Pelesaraei, A. (2021). The short-term effects of COVID-19 outbreak on dietary diversity and food security status of Iranian households (A case study in Tehran province). *Journal of cleaner production*, 281, 124537.
- Pesaran, H. H., & Shin, Y. (1998). Generalized impulse response analysis in linear multivariate models. *Economics letters*, 58(1), 17-29.
- Pindyck, R. S., & Rotemberg, J. J. (1990). The excess co-movement of commodity prices. *The Economic Journal*, 100(403), 1173-1189.
- Poncela, P., Senra, E., & Sierra, L. P. (2014). Common dynamics of nonenergy commodity prices and their relation to uncertainty. *Applied Economics*, 46(30), 3724-3735.
- Raza, S. A., Guesmi, K., Belaid, F., & Shah, N. (2022). Time-frequency causality and connectedness between oil price shocks and the world food prices. *Research in International Business and Finance*, 62, 101730.
- Samal, A., Ummalla, M., & Goyari, P. (2022). The impact of macroeconomic factors on food price inflation: an evidence from India. *Future Business Journal*, 8(1), 1-14.

Sierra, L. P., Girón, L. E., & Osorio, C. (2017). Has Financialization in Commodity Markets Affected the Predictability in Metal Markets? The Efficient Markets Hypotheses for Metal Returns. *International Journal of Economics and Financial Issues*, 7(4), 15-22.

Sun, Y., Gao, P., Raza, S. A., Shah, N., & Sharif, A. (2023). The asymmetric effects of oil price shocks on the world food prices: Fresh evidence from quantile-on-quantile regression approach. *Energy*, 270, 126812.

Timmer, C. P., Falcon, W. P., Pearson, S. R., & World Bank. Agriculture and Rural Development Dept. Economics and Policy Division. (1983). Food policy analysis (Vol. 1983, pp. 1-301). Baltimore: Johns Hopkins University Press.

Toossi, S., & Jones, J. W. (2023). The food and nutrition assistance landscape: Fiscal year 2022 annual report (Economic Information Bulletin No. 274). U.S. Department of Agriculture. <https://ageconsearch.umn.edu/record/337564/?v=pdf>

Vos, R., Glauber, J., Hernández, M., & Laborde, D. (2022). 10. COVID-19 and food inflation scares. *2YEARS*, 64.

Zmami, M., & Ben-Salha, O. (2019). Does oil price drive world food prices? Evidence from linear and nonlinear ARDL modeling. *Economies*, 7(1), 12.

Anexo 1.1 Clasificación de alimentos por categoría (Adaptado de FAO)

Categoría	Subcategoría
Cereales	Cebada; Maíz; Arroz; Trigo y Sorgo
Carnes	Carne de res; Cordero; Cerdo; Aves y Camarón

Aceites	Aceite de Colza; Aceite de Oliva; Aceite de Palma; Aceite de Soya y Aceite de Girasol
Granos tostados secos	Café suave, Café robusto, cacao y maní
Sugar=azúcar	Azúcar
Bebidas	Tea= Té y Orange Juice=jugo de naranja
Legumes = legumbres	Soy= Soya y Beans=fríjoles
Flours= harinas	Soybean meal= harina de soya y fish meal= harina de pescado
Fruit = frutas	Banana= banano

Fuente: Materias primas obtenidas del Fondo Monetario Internacional y adaptadas a las categorías de la FAO







Anexo 1.2 Indicadores de la actividad económica y financiera de Estados Unidos.

Categoría	Indicadores
Income = Ingreso	Ingreso personal real e ingreso personal real antes de transferencias
Production = Producción	Manufactura real, ventas industriales y comercio, índice total de producción, horas promedio de producción de bienes, horas extra promedio en manufactura e índice de producto final
Consumption = Consumo	Gasto de consumo real, índice de bienes de consumo, índice de bienes de consumo duraderos e índice de bienes de consumo no duraderos
Labor Market = Mercado laboral	Fuerza laboral civil, empleo civil, tasa de desempleo civil, duración promedio del desempleo en semanas, empleo total no agrícola
Financial = financiero	Oferta monetaria real, índice compuesto de precios de acciones comunes, índice de precios de acciones industriales, tasa efectiva de fondos federales, tasa AA para papel comercial financiero a 3 meses, letras del tesoro a 3 meses, letras del tesoro a 6 meses, letras del tesoro a 1 año, letras del tesoro a 5 años y letras del tesoro a 10 años
Transport = Transporte	Índice de precios de transporte

Feelings = Sentimientos	Índice de confianza del consumidor
-------------------------	------------------------------------

Fuente: Indicadores proporcionados por el Federal Reserve Bank of St. Louis (McCracken & Ng, (2016).

Anexo 1.3 Series de índices de precios internacionales de materias primas alimentarias después de la aplicación de los códigos de transformación (tcode).



Nota: Las series corresponden al resultado de aplicar los códigos de transformación (tcode) definidos para cada variable con el fin de obtener series aproximadamente estacionarias. Posteriormente, estas series fueron estandarizadas antes de estimar el modelo de factores cuantílicos.

CAPITULO 2. LOS EFECTOS DE LA VARIABILIDAD CLIMÁTICA, LA PRODUCTIVIDAD TOTAL DE LOS FACTORES AGRÍCOLAS Y LOS DETERMINANTES EXTERNOS SOBRE LA INFLACIÓN DE ALIMENTOS Y BEBIDAS EN LOS ESTADOS UNIDOS

Resumen

Comprender la inflación de alimentos y bebidas en un país de altos ingresos como Estados Unidos es fundamental, ya que los aumentos persistentes en los precios de los alimentos afectan de manera desproporcionada a los hogares de bajos ingresos y generan preocupaciones sobre la seguridad alimentaria y la resiliencia del sistema alimentario. Este estudio examina la influencia de la variabilidad climática, la productividad total de los factores (PTF) agrícola y los factores externos sobre la inflación de alimentos y bebidas en Estados Unidos desde 1992.01 hasta 2024.05.

Para capturar las condiciones climáticas, se utilizaron los componentes del Índice Climático de Actuarios (Actuaries Climate Index, ACI) para Estados Unidos y Canadá. También se incorporó la PTF agrícola de Estados Unidos y Índice de Presión de la Cadena Global de Suministro (Global Supply Chain Pressure Index, GSCPI) para representadar las disrupciones globales de suministro.

Metodológicamente, se aplicó el modelo factorial cuantílico (Chen et al., 2021) para extraer dinámicas comunes y comovimientos extremos a partir de un amplio conjunto de índices de precios de materias primas y series de actividad macrofinanciera. Estos factores latentes, junto con variables observables, se integran en un marco FAVAR para evaluar sus efectos sobre la inflación de alimentos y bebidas.

Los resultados indican que, de los determinantes analizados, los factores externos capturados por los movimientos comunes en los percentiles 50 y 90 de los precios internacionales de materias primas alimentarias y por el GSCPI desempeñan un papel dominante en la

configuración de la inflación de alimentos y bebidas en Estados Unidos. Los impactos climáticos son más matizados.

Varios componentes del ACI, incluyendo la variación en la frecuencia estandarizada de bajas temperaturas en Estados Unidos (DT10USA), la variación en la precipitación estandarizada para Estados Unidos (DPRECIUSA), la variación en la velocidad del viento estandarizada para Estados Unidos (DWP90USA), la variación en el nivel del mar estandarizado para Estados Unidos (DSEAUSA) y la variación en los días secos consecutivos estandarizados para Estados Unidos (DCDDUSA), no presentan un efecto estadísticamente significativo sobre la inflación de alimentos y bebidas. La frecuencia de altas temperaturas (DT90USA) tiene una influencia desinflacionaria leve. Finalmente, la PTF agrícola contribuye modestamente a reducir la inflación de alimentos y bebidas.

En conjunto, los hallazgos resaltan las interacciones complejas y asimétricas entre la variabilidad climática, la productividad, las interrupciones globales y la dinámica de los precios de los alimentos dentro de una economía importante productora de alimentos.

Palabras clave: Inflación de alimentos y bebidas; Variabilidad climática; Productividad; Modelo Factorial Cuantílico.

Introducción

Gran parte de la investigación sobre variabilidad climática, productividad total de los factores y precios internacionales de materias primas estudia su impacto en el sector agrícola, dada la importancia de este sector en los cuatro pilares de la seguridad alimentaria (disponibilidad, acceso, utilización y estabilidad) (FAO et al., 2018).

Analizar estos impactos y su efecto sobre los precios de los alimentos es importante principalmente porque afecta el acceso a los alimentos de la población de menores ingresos, que puede verse perjudicada por posibles aumentos de precios debido a una eventual reducción en la oferta. En Estados Unidos, por ejemplo, el mayor impacto de este aumento de precios recaería sobre el 12.5% de la población que representa la tasa nacional de pobreza en 2023 (Benson, 2024).

Para los propósitos de este trabajo, se plantea la siguiente pregunta de investigación: ¿Cuáles son los impactos y la persistencia del cambio climático, la productividad del sector agrícola y los factores externos sobre la inflación de alimentos y bebidas en Estados Unidos?

Con base en esta pregunta de investigación, se plantea la siguiente hipótesis de investigación: el cambio climático, la productividad del sector agrícola y los factores externos ejercen efectos heterogéneos sobre la inflación de alimentos y bebidas en Estados Unidos, tanto en magnitud como en persistencia, esperándose que los factores externos generen los impactos más intensos y duraderos, mientras que la productividad agrícola contribuya a mitigar las presiones inflacionarias.

Con el fin de contrastar esta hipótesis, se plantea como objetivo evaluar los impactos y la persistencia del cambio climático, la productividad del sector agrícola y los factores externos sobre la inflación de alimentos y bebidas en Estados Unidos.

Aunque existe consenso en diversos estudios en que los eventos climáticos extremos reducen la producción agrícola en el corto plazo y provocan un aumento en la inflación de alimentos, especialmente en países en desarrollo (Ullah et al., 2019; Matsa y Dzawanda, 2019; Holleman et al., 2020; Bedasa y Bedemo, 2023), otros estudios presentan una visión diferente en el contexto de los países desarrollados.

Investigaciones como las de Sheng et al. (2015), Alston et al. (2009) y Fuglie y Heisey (2007) muestran que, durante el siglo XX, la oferta de alimentos en estas economías, y particularmente en Estados Unidos, creció a una tasa que superó la demanda. Este fenómeno se atribuye a mejoras significativas en la productividad agrícola, impulsadas por la inversión en investigación, desarrollo e innovación tecnológica. Esta evidencia resalta la importancia de analizar con mayor profundidad las interacciones entre el cambio climático, la productividad agrícola y los factores externos, así como su impacto conjunto sobre la inflación de alimentos en economías desarrolladas.

Para Estados Unidos, el efecto del cambio climático sobre la producción agrícola no es claro, y en la literatura se evidencian dos efectos: 1) el impacto negativo del cambio climático extremo sobre la productividad agrícola en el corto plazo (Ortiz-Bobea et al., 2018; Wheeler y Braun, 2013; Walthall et al., 2012; Wang et al., 2015), y 2) la mejora en la productividad del sector, debido a la I+D enfocada en cultivos más resilientes a cambios climáticos extremos (Sheng et al., 2015; Alston, 2010; Huffman y Evenson, 2006; Plastina y Fulginiti, 2012; Fuglie y Heisey, 2007).

Actualmente, la investigación agrícola en Estados Unidos se centra en desarrollar cultivos más resistentes a la sequía, a los vientos fuertes y con menores requerimientos de agua, con el fin de amortiguar los efectos de corto plazo del cambio climático sobre la productividad total de los factores (McFetridge, 2024).

Desde una perspectiva macroeconómica, Kotz et al. (2023) proporcionan evidencia global de que el aumento de las temperaturas promedio genera presiones inflacionarias no lineales y persistentes que duran hasta doce meses tanto en países de altos como de bajos ingresos. Bajo escenarios sin adaptación sin precedentes, proyectan aumentos sustanciales tanto en la inflación general como en la de alimentos, destacando al cambio climático como una posible amenaza para la estabilidad de precios.

Complementando esta visión, Mitra et al. (2025) enfatizan que el cambio climático afecta la inflación a través de múltiples canales, incluyendo choques físicos de oferta, pérdidas de productividad, mecanismos de transmisión monetaria y políticas de mitigación, lo que complica los dilemas de los bancos centrales.

Al mismo tiempo, Gammans (2025) encuentra evidencia limitada de que el cambio climático observado haya sido un impulsor principal de los recientes aumentos en los precios de los alimentos. Sin embargo, el estudio subraya que los impactos climáticos siguen siendo profundos a nivel de finca y representan riesgos significativos de largo plazo, sugiriendo que la adaptación y las mejoras en productividad pueden compensar parcialmente los efectos inflacionarios agregados en economías desarrolladas.

Por otra parte, Chand (2010) encuentra que la inflación de alimentos está asociada, entre otros factores, a factores externos como el comercio global y los precios internacionales, y se

acentúa por problemas relacionados con la interrupción de la cadena internacional de suministro como consecuencia, por ejemplo, de la epidemia de Covid-19 y del conflicto armado Rusia-Ucrania de 2022.

Marín et al. (2025) examinan la interconectividad dinámica entre las principales materias primas agrícolas y los principales indicadores de incertidumbre —incluyendo incertidumbre de política climática, incertidumbre de política económica global, riesgo geopolítico, volatilidad financiera, volatilidad del precio del petróleo y el dólar estadounidense— utilizando un marco TVP-VAR. Sus resultados muestran que la incertidumbre macrofinanciera externa domina consistentemente los efectos de contagio internos de las materias primas, especialmente durante períodos de tensión geopolítica o financiera, subrayando la importancia de políticas macrofinancieras y climáticas coordinadas.

De manera similar, Mehibel et al. (2025) demuestran que el riesgo geopolítico amplifica significativamente las presiones inflacionarias y debilita la seguridad alimentaria global una vez que se supera un umbral crítico, principalmente a través de aumentos abruptos en los precios de fertilizantes, alimentos y energía.

Majahana et al. (2025), utilizando evidencia bibliométrica, documentan un creciente enfoque de investigación global en adaptación y gobernanza del cambio climático, al tiempo que identifican brechas persistentes en los marcos de evaluación de riesgos y en la capacidad institucional, particularmente en regiones en desarrollo. Sus hallazgos resaltan la necesidad de integrar el conocimiento científico con consideraciones socioeconómicas para diseñar estrategias de adaptación equitativas y resilientes.

Si bien la literatura sobre cambio climático, productividad, precios internacionales de materias primas y agricultura es abundante, no se identificaron en la revisión realizada estudios que cuantifiquen conjuntamente el efecto del cambio climático, la productividad total de los factores, las cadenas de suministro y los precios internacionales de materias primas sobre la inflación de alimentos y bebidas. Este trabajo se centra en analizar estos impactos en un país desarrollado como Estados Unidos, utilizando como referencia el período 1992.01–2024.05. Hasta donde alcanza el conocimiento de los autores, este es uno de los primeros estudios que integra estas dimensiones dentro de un marco empírico unificado que combina modelos factoriales cuantílicos con una estructura FAVAR, lo que permite capturar tanto los efectos de contagio macrofinancieros como las dinámicas impulsadas por el clima.

La importancia de esta investigación radica en que se centra en los impactos sobre una variable de política relevante como la inflación de alimentos, la cual está vinculada con problemáticas actuales como el cambio climático, la productividad y los factores externos, dado que los impactos sobre los sistemas alimentarios pueden afectar la seguridad alimentaria de la población a nivel mundial. Por lo tanto, este trabajo contribuye a una mayor comprensión de una variable de política pública como la inflación de alimentos en Estados Unidos.

Este documento, además de esta introducción, presenta la siguiente estructura. La Sección 2 (Métodos) presenta la descripción de los datos utilizados, la metodología desarrollada en esta investigación y la modelación. La Sección 3 presenta los resultados. La sección 4 presenta las pruebas de robustez. La sección 5 presentan las principales conclusiones.

Métodos

Descripción de los datos


Esta sección describe los datos utilizados en esta investigación. Para estimar, mediante el modelo factorial cuantílico, el primer factor de los percentiles 90 y 50 de los índices de precios de materias primas alimentarias, y el primer factor del percentil 50 de las series mensuales de variables macroeconómicas y financieras en Estados Unidos, se emplean dos bases de datos.

La primera base está conformada por 24 series mensuales de índices precios internacionales de materias primas alimentarias, obtenidas de la base de datos de precios de materias primas primarias proporcionada por el Fondo Monetario Internacional (FMI). La segunda comprende 28 series mensuales de indicadores macroeconómicos y financieros de Estados Unidos extraídas de la base de datos proporcionada por el Banco de la Reserva Federal de St. Louis, denominada FRED-MD y desarrollada por McCracken y Ng (2016). El período para ambas bases de datos abarca desde enero de 1992.01 hasta 2024.05.

La Figura 2.1 presenta algunas de las principales series mensuales de índices de precios internacionales de materias primas en sus diferentes categorías de alimentos y bebidas: aceites, carnes y cereales. Puede observarse un patrón de comovimiento entre las series correspondientes a las categorías de aceites y cereales. Según Poncela, Senra y Sierra (2014), este comovimiento puede atribuirse a la financiarización en el mercado de materias primas.

Asimismo, en las distintas categorías de materias primas se observan los mayores incrementos alrededor de 2008, asociados con la crisis financiera internacional, debido a la crisis financiera global, y durante el período 2020-2021, relacionados con la pandemia de COVID-19, la crisis de contenedores y el conflicto entre Rusia y Ucrania.

Figura 0.1 Índices de precios internacionales de materias primas alimenticias en Estados Unidos, 1992.01-2024.05.



Fuente: Cálculos propios a partir la base de datos del FMI

La Figura 2.2 presenta algunas de las variables utilizadas para medir el desempeño económico de Estados Unidos. Se tuvieron en cuenta indicadores macroeconómicos relacionados con el ingreso de los hogares, la producción nacional, diferentes tipos de consumo y variables del mercado laboral y financiero de Estados Unidos.


En cuanto a las variables asociadas al ingreso personal real (Figura 2.2a), puede observarse un impacto positivo durante el período del COVID-19, posiblemente explicado por los subsidios gubernamentales a los hogares, junto con mayores beneficios por desempleo y una tasa de ahorro más alta debido al confinamiento de los hogares. Sin embargo, el ingreso personal real antes de transferencias presenta una caída significativa, quizás debido a la disminución de la actividad


económica durante ese período, como puede observarse en las variables relacionadas con la producción (Figura 2.2b). En el período posterior al COVID-19, las dos series de ingreso retornan a la senda de crecimiento de largo plazo.

Para el resto de las variables relacionadas con el empleo y los diferentes tipos de consumo, puede observarse el impacto de las crisis económicas de 2008 y 2020. No obstante, en el período posterior, los índices aumentan y luego se estabilizan, como se observa en las Figuras 2.2c y 2.2d.

En cuanto a las variables financieras, las tasas de letras y bonos del Tesoro disminuyen en diferentes períodos de crisis, como en 2008 y 2020, representando las políticas contracíclicas de la Reserva Federal de Estados Unidos (Figura 2.2e).

Figura 0.2 Variables macroeconómicas y financieras de los ingresos en Estados Unidos, 1992:01-2024:05





Fuente: Cálculos propios basados en la base de datos proporcionada por el Banco de la Reserva Federal de San Luis.

Adicionalmente, se consideró un conjunto de variables observables que teóricamente podrían explicar la inflación de alimentos y bebidas en Estados Unidos para el período 1992.01–2024.05. Estas variables fueron: la inflación de alimentos y bebidas de Estados Unidos proporcionada por la U.S. Bureau of Labor Statistics (2024); el Índice de la Cadena Global de Suministro (Global Supply Chain Pressure Index, GSCPI) elaborado por la Reserva Federal de Nueva York (Benigno et al., 2022), que es una medida parsimoniosa de las presiones en las cadenas

globales de suministro utilizada para evaluar la importancia de las restricciones de oferta sobre los resultados económicos; la serie de Productividad Total de los Factores (PTF) del sector agrícola de los Estados Unidos, proporcionada por USDA-ERS (2025), que cubre el periodo 1948-2021.

Asimismo, se incorporaron los componentes del índice Climático de Actuarios (Actuaries Climate Index, ACI), desarrollado por asociaciones actuariales en Canadá y Estados Unidos, los cuales son: Frecuencia estandarizada de altas temperaturas en Estados Unidos (T90USA), Frecuencia estandarizada de bajas temperaturas en Estados Unidos (T10USA), Precipitación estandarizada en Estados Unidos (PRECIUSA), Días secos consecutivos estandarizados en Estados Unidos (CDDUSA), Velocidad promedio estandarizada del viento en Estados Unidos (WP90USA) y Nivel del mar estandarizado en Estados Unidos (SEAUSA).

El ACI puede interpretarse como un indicador compuesto de variabilidad climática y riesgos relacionados con el clima, análogo en estructura al Índice de Precios al Consumidor (IPC), pero enfocado en condiciones ambientales en lugar de precios.


Dado que la serie de Productividad Total de los Factores (PTF) se encuentra únicamente en frecuencia anual, se procedió a su desagregación mensual utilizando el paquete EViews 12. Para ello, se eligió una asignación proporcional no lineal para cada mes basada en ponderaciones mensuales derivadas de los ciclos de los principales cultivos del sector agrícola de Estados Unidos: (siembra, crecimiento y cosecha).

Esta estrategia busca representar de manera más realista la estacionalidad de la actividad agrícola y, por tanto, la evolución intraanual de la productividad.

Antes de la desagregación mensual, la serie anual de PTF fue extendida. Dado que la información disponible llegaba hasta 2021, los años 2022, 2023 y el primer semestre del 2024 se

proyectaron mediante el método de suavizamiento exponencial de Holt-Winters sin componente estacional. Esta especificación se seleccionó porque la serie no presentaba un patrón estacional claro, pero sí mostraba una tendencia bien definida. La Figura 2.3 muestra la Productividad Total de los Factores anual, evidenciando una tendencia sostenida al alza durante el período 1948–2021.

Figura 0.3 Productividad total de los factores en Estados Unidos (1992-2021)



Antes de la estimación del modelo factorial cuantílico, todas las series fueron desestacionalizadas. En el caso de las series de precios internacionales de materias primas alimentarias, se aplicó la prueba de Dickey-Fuller Aumentada para determinar la transformación apropiada de cada variable y asignar el correspondiente código de transformación que permitiera obtener series aproximadamente estacionarias.

Para las series macroeconómicas y financieras de la base FRED-MD, se utilizaron los códigos de transformación suministrados por dicha base de datos (McCracken y Ng, 2016). Posteriormente, siguiendo el procedimiento propuesto por Chen et al. (2021), las funciones auxiliares desarrolladas por dichos autores aplicaron automáticamente los códigos de transformación definidos para cada serie.

Finalmente, las series transformadas fueron estandarizadas restando su media y dividiendo por su desviación estándar antes de estimar los factores cuantílicos.

Metodología y modelación

Esta sección presenta la metodología utilizada en este trabajo, que incluye el modelo factorial cuantílico desarrollado por Chen et al. (2021) y el modelo FAVAR (modelo VAR aumentado con factores), desarrollado por Bernanke et al. (2005). El primer modelo se utiliza para encontrar el primer factor del percentil 90 y del percentil 50 del índice de precios internacionales de materias primas alimentarias, y el primer factor del percentil 50 de las series mensuales de variables macroeconómicas y financieras de Estados Unidos, mientras que el segundo modelo se utiliza para modelar la relación entre las variables.

Como innovación, ambas metodologías se combinan en este trabajo, ya que, así como el estimador de componentes principales de factores y cargas desarrollado por Bai y Ng (2002) es consistente, el estimador de factores y cargas cuantílicos de Chen et al. (2021) también es

consistente. Por lo tanto, se extiende la propuesta de Bernanke et al. (2005), que se basa en factores comunes para la media, hacia factores comunes por cuantiles.

Modelo Factorial Cuantílico

El modelo factorial cuantílico puede considerarse una generalización de los modelos factoriales dinámicos, en la medida en que permiten, al igual que estos últimos, describir las fluctuaciones de un gran número de series mediante la combinación lineal de un pequeño número de factores no observables o latentes comunes al conjunto de series y un término idiosincrático específico de cada serie que no es explicado por el componente común.

La diferencia y principal fortaleza del modelo factorial cuantílico con respecto al modelo dinámico radica en que permite identificar los factores que explican el comportamiento de las distribuciones de las series observables vinculadas al fenómeno, en este caso, la inflación de alimentos y bebidas; no solo en la media, sino también en cualquier parte de la distribución, como las colas superiores o inferiores. En consecuencia, tanto las cargas como los factores dependen de los cuantiles.

En este trabajo, el modelo factorial cuantílico (QFM) propuesto por Chen et al. (2021) fue aplicado para obtener los factores no observables incorporados en el VAR. La estructura general de este modelo es la siguiente:

Supongamos que la variable observada X_{it} with $i = 1, 2, \dots, N$ y $t = 1, 2, \dots, T$ es generada por un componente común más uno idiosincrático. Para caracterizar la distribución de X_{it} , se tendrá un componente común diferente para cada cuantil de la distribución.

$$\lambda'_i(\tau)f_t(\tau) \text{ for } \tau \in (0,1)$$

donde los factores comunes $f_t(\tau)$ son vectores de variables aleatorias no observables de dimensión $r(\tau) \times 1$, $\lambda'_i(\tau)$ es un vector de cargas no aleatorias de dimensión $1 \times r(\tau)$ with $r(\tau) \ll N$. El QFM así definido permite que los factores, las cargas y el número de factores dependan de los cuantiles.

El modelo completo puede escribirse como:

$$X_{it} = \lambda'_i(\tau)f_t(\tau) + U_{it}(\tau) \quad (1)$$

donde el error idiosincrático dependiente del cuantil $U_{it}(\tau)$ satisface las siguientes restricciones:

$$P[U_{it}(\tau) \leq 0 | f_t(\tau)] = \tau \text{ y } Q_{U_{it}}[\tau | f_t(\tau)] = 0,$$

donde $U_{it}(\tau)$ es la perturbación aleatoria correspondiente al cuantil τ condicionado a $f_t(\tau)$.

El estimador (AFQ) de los factores y cargas, asumiendo que el número de factores es conocido, se define como:

$$\hat{\theta} = (\hat{\lambda}'_1, \dots, \hat{\lambda}'_N, \hat{f}'_1, \dots, \hat{f}'_T)' = \underset{\theta \in \Theta^r}{\operatorname{argmin}} \mathbb{M}_{NT}(\theta)$$

$$\text{donde } \mathbb{M}_{NT}(\theta) = \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T \rho_\tau(X_{it} - \lambda'_i f_t)$$

y $\rho_\tau(u) = (\tau - \mathbf{1}\{u \leq 0\})u$ es la función de verificación. Tanto las cargas como los factores estimados dependen de los cuantiles.

El estimador de factores y cargas comunes cuantílicos es consistente cuando tanto la dimensión temporal T como el tamaño de la sección transversal N tienden a infinito.

Resolver el problema de minimización anterior no produce una forma analítica cerrada. Por esta razón, los autores desarrollaron un algoritmo computacional al que denominan regresión cuantílica iterativa (IQR).

Dado que el estimador de factores y cargas comunes cuantílicas supone un número conocido de factores, los autores proponen dos métodos para estimar el número correcto de factores comunes en cada cuantil. El primero selecciona el número de factores minimizando rangos, mientras que el segundo utiliza criterios de información (IC), similares a los de Bai y Ng (2002). Ambos métodos producen estimadores consistentes. Para una descripción más detallada de los métodos, véase Chen et al. (2021).

Modelo FAVAR

Tomando como punto de partida el modelo FAVAR desarrollado por Bernanke et al. (2005), se presenta un nuevo modelo autorregresivo vectorial aumentado con factores (FAVAR), en el cual los factores han sido obtenidos mediante un modelo factorial cuantílico. Sea Y_t un vector de dimensión $M \times 1$ de variables observables (inflación mensual de alimentos y bebidas, Índice de Presión de la Cadena Global de suministro (GSCPI), el componente climático y productividad total de los factores (PTF)).

Para incluir factores no observables, considerése un vector F_t de dimensión $K \times 1$. Así, la dinámica conjunta de (F_t, Y_t) está dada por la siguiente ecuación:

$$\begin{bmatrix} F_t \\ Y_t \end{bmatrix} = \Phi(L) \begin{bmatrix} F_{t-1} \\ Y_{t-1} \end{bmatrix} + v_t \quad (2)$$

donde $\Phi(L)$ es una matriz de dimensión $(K+M) \times (K+M)$ de polinomios en el operador de rezago y el término de error v_t es ruido blanco multivariado, es decir, el vector $(K + M)$ $v_t \sim (0, Q)$.

El modelo FAVAR incluye los primeros factores de los percentiles 50 y 90 de los índices de precios internacionales de materias primas alimentarias (en adelante denominados *Prextermedios* y *Prexteraltos*, respectivamente). Adicionalmente, se incluye el primer factor del percentil 50 de las series mensuales de indicadores macroeconómicos y financieros de Estados Unidos, al cual denominamos *USIncofinan*. Junto con estos factores, el modelo incorpora un conjunto de variables observables teóricamente relacionadas con la inflación de alimentos y bebidas en Estados Unidos durante el período analizado. Como se discutió en la sección previa, estas variables observables incluyen la Inflación Mensual Nacional de Alimentos (*FoodInfla*), el componente del Índice Climático Actuarial nacional (ACI) (en adelante denominado *ACIUSA*), la Productividad Total de los Factores (PTF), y el Global Supply Chain Pressure Index (*GSCPI*)

$$\begin{bmatrix} F_t \\ Y_t \end{bmatrix} = \begin{bmatrix} \text{Prexteraltos}_t \\ \text{Prextermedios}_t \\ \text{USIncofinan}_t \\ \text{FoodInfla}_t \\ \text{ACIUSA}_t \\ \text{PTF}_t \\ \text{GSCPI}_t \end{bmatrix} = \Phi(L) \begin{bmatrix} \text{Prexteralto}_{t-1} \\ \text{Prextermedios}_{t-1} \\ \text{USIncofinan}_{t-1} \\ \text{Foodinfla}_{t-1} \\ \text{ACIUSA}_{t-1} \\ \text{PTF}_{t-1} \\ \text{GSCPI}_{t-1} \end{bmatrix} + v_t \quad (3)$$

donde $\Phi(L)$ y v_t han sido previamente definidos.

Resultados

Esta sección presenta y analiza los principales resultados del estudio. Inicialmente, se describen los componentes del Índice Climático Actuarial (ACI) y se presentan sus principales estadísticas descriptivas. A continuación, se analizan las correlaciones entre los componentes del índice climático y la Productividad Total de los Factores, así como las estadísticas descriptivas de

las demás variables incorporadas en el modelo FAVAR. Finalmente, se estudian las funciones de impulso-respuesta de la inflación de alimentos y bebidas ante choques en los componentes climáticos, la productividad y los factores externos.

La Figura 2.4 muestra los diferentes componentes del Índice Climático Actuarial de Estados Unidos y Canadá. Las seis variables climáticas utilizadas en este estudio reflejan diferentes tipos de eventos extremos. Estas variables miden cuánto se desvían fenómenos como olas de calor, olas de frío, aumento del nivel del mar, lluvias intensas, vientos fuertes y sequías prolongadas del promedio histórico (1961–1990). Cada variable se expresa en desviaciones estándar respecto a ese promedio, lo que permite identificar si un mes determinado experimentó condiciones climáticas más extremas de lo habitual. Todos los componentes, excepto la velocidad del viento, muestran una tendencia al alza, la cual es más pronunciada en los siguientes componentes: nivel del mar y frecuencias de altas y bajas temperaturas. Para una descripción más detallada de estas variables, véase el Anexo 1.1.

Figura 0.4 Comportamiento de cada uno de los componentes como anomalía estandarizada del Índice Climático Actuarial (ACI) para Estados Unidos 1992:01–2024:05.




Tabla 2.1 Estadísticas descriptivas de los componentes del Índice Climático de Actuarios (ACI) para Estados Unidos.

Estadística	T90USA	T10USA	PRECIUSA	CDDUSA	WP90USA	SEAUSA
Media	0.775	0.607	0.450	-0.100	-0.263	1.728
Desviación Estándar	0.444	0.253	0.227	0.644	0.295	0.870
Mínimo	0.000	0.030	-0.02	-1.370	-0.820	0.170
Máximo	1.65	1.080	1.050	1.150	0.250	3.630
Orden de Integración	I(1)	I(1)	I(1)	I(1)	I(1)	I(1)

Fuente: Cálculos propios basados en datos proporcionados por la ACI para EE. UU

La Tabla 2.1 presenta las estadísticas descriptivas de los componentes del Índice Climático de Actuarios (ACI) para Estados Unidos. Cada componente se expresa como el número de desviaciones estándar respecto al período de referencia 1961–1990, por lo que valores positivos indican condiciones climáticas más extremas que el promedio histórico. El componente T90USA registra un valor promedio de 0.775 desviaciones estándar, con un máximo de 1.65 y un mínimo de 0.00.

La Figura 2.4a muestra una tendencia creciente en T90USA, lo que indica que la frecuencia de días con temperaturas superiores al percentil 90 del período de referencia ha aumentado durante la muestra analizada. Este comportamiento es consistente con la evidencia que documenta una mayor ocurrencia de eventos de calor extremo asociada al cambio climático.

Asimismo, la Tabla 2.1 muestra que todos los componentes del ACI presentan un orden de integración I(1), indicando que son series no estacionarias en niveles. En consecuencia, antes de su incorporación al modelo FAVAR se aplicaron las transformaciones correspondientes para obtener series estacionarias.

Tabla 2.2 Correlaciones entre los componentes estandarizados del ACI y la productividad

	T90USA	T10USA	PRECIUSA	CDDUSA	WP90USA	SEAUSA	PRODUCTIVIDAD TOTAL DE FACTORES
T90USA	1						
T10USA	0.893	1					
PRECIUSA	0.530	0.375	1				
CDDUSA	0.195	0.493	-0.467	1			
WP90USA	0.893	-0.798	-0.452	-0.179	1		
SEAUSA	0.842	0.763	0.664	0.023	-0.856	1	
PRODUCTIVIDAD TOTAL DE FACTORES	0.813	0.810	0.367	0.346	-0.901	0.876	1

Fuente: Cálculos propios con base en datos proporcionados por el ACI para EE.UU.

La Tabla 2.2 presenta las correlaciones entre los componentes del Índice Climático de Actuarios (ACI) y la Productividad Total de los Factores (PTF). Se observa que T90USA presenta una correlación positiva relativamente alta con la PTF (0.813). Este resultado refleja que ambas series exhiben una tendencia creciente durante el período analizado. Mientras la frecuencia de episodios de altas temperaturas ha aumentado respecto al período de referencia 1961–1990, la productividad agrícola también ha mostrado una trayectoria ascendente, impulsada principalmente por la inversión en investigación, desarrollo e innovación tecnológica en el sector agrícola de Estados Unidos (USDA-ERS, 2024).

De manera similar, los componentes T10USA y SEAUSA también presentan correlaciones positivas elevadas con la PTF, mientras que WP90USA exhibe una correlación negativa alta (-0.901). En términos generales, estas correlaciones reflejan la evolución conjunta de las series durante el período de estudio y constituyen un análisis descriptivo previo a la estimación econométrica, sin implicar necesariamente relaciones causales entre las variables.

Table 2.3 Estadísticas descriptivas de las variables del modelo FAVAR

Variable	Descripción	Orden de integración	media	Desviación Estándar	Mínimo	Máximo
----------	-------------	-------------------------	-------	------------------------	--------	--------

Prextermidios	Primer factor cuantílico (P50) de índices precios internacionales de materias primas alimentarias	I(0)	0.011	1.0541	-6.039	2.844
Prexteraltos	Primer factor cuantílico (P90) de índices precios internacionales de materias primas alimentarias	I(0)	0.891	0.454	-0.258	2.661
USIncofinan	Primer factor cuantílico (P50) de indicadores macroeconómicos y financieros de EE.UU	I(0)	0.005	1.001	-14.781	5.780
FoodInfla	Inflación mensual de alimentos y bebidas	I(0)	0.22	0.233	-0.375	1.290
PTF	Productividad Total de Factores	I(0)	0.000	0.002	-0.006	0.005
GSCPI	Índice de presión de la Cadena Global de Suministro	I(0)	0.007	1.005	-1.56	4.380

Fuente: Cálculos propios

La **Tabla 2.3** presenta las estadísticas descriptivas de las variables incorporadas en el modelo FAVAR. Se observa que todas las variables son estacionarias, con orden de integración I(0), condición necesaria para la estimación del modelo.

Los factores cuantílicos asociados a los precios internacionales de materias primas alimentarias presentan comportamientos diferenciados. El factor **Prextermidios**, correspondiente al percentil 50, tiene una desviación estándar de 1.054, mientras que el factor **Prexteraltos**, correspondiente al percentil 90, presenta una desviación estándar de 0.454. Este resultado indica que el factor común asociado a los episodios extremos de aumentos en los precios internacionales

exhibe una menor variabilidad que el factor asociado a la mediana de la distribución, resultado consistente con el encontrado en el primer artículo de esta investigación.


El factor **USIncofinan** registra la mayor amplitud de variación entre todas las variables, con valores comprendidos entre -14.781 y 5.780. Este comportamiento refleja la presencia de episodios macroeconómicos y financieros de elevada intensidad durante el período analizado, incluyendo las recesiones de 2001, la crisis financiera internacional de 2008 y la crisis derivada de la pandemia del COVID-19.

La inflación mensual de alimentos y bebidas (**FoodInfla**) presenta una media de 0.22% mensual y una desviación estándar de 0.233, lo que evidencia una dinámica relativamente estable durante la mayor parte del período de estudio, aunque con episodios de incrementos importantes asociados a perturbaciones externas.

Por su parte, la Productividad Total de los Factores (PTF) presenta una variabilidad reducida, consistente con el comportamiento gradual que caracteriza la evolución de la productividad agrícola, la cual responde principalmente a procesos acumulativos de innovación tecnológica, inversión en investigación y mejoras en la eficiencia productiva.

Finalmente, el **Índice de Presión de la Cadena Global de Suministro (GSCPI)** presenta una desviación estándar cercana a uno y un máximo de 4.38, reflejando los episodios excepcionales de tensión registrados durante la pandemia y las posteriores disrupciones logísticas internacionales.

Figura 0.5 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA).



El Panel 2.5a muestra cómo un choque en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA) disminuye la inflación de alimentos y bebidas en los primeros 7 meses, antes de que el efecto desaparezca. Este resultado puede explicarse de tres maneras: la primera es que un aumento en las temperaturas no es necesariamente perjudicial, ya que algunos cultivos incrementan su productividad y otros no se ven significativamente afectados, dado que las semillas producidas mediante investigación y desarrollo tecnológico han permitido cultivos más resistentes a la sequía, a los vientos fuertes y con un requerimiento mínimo de agua

(McFetridge, 2024). La segunda es que un aumento en las altas temperaturas puede reducir la dinámica de la demanda y, por lo tanto, disminuir el consumo (Chidiac et al., 2022). La tercera es la interacción entre variables climáticas; por ejemplo, una semana calurosa con suficiente humedad acelera el crecimiento del maíz (Shirley et al., 2020).

El Panel 2.5b muestra que un choque en la productividad total de los factores solo reduce ligeramente la inflación de alimentos y bebidas durante los tres períodos siguientes, antes de que su efecto desaparezca. Este impacto leve puede explicarse porque la productividad total de los factores es una variable de naturaleza estructural, cuyos cambios ocurren gradualmente mediante procesos de innovación tecnológica, inversión y mejoras en eficiencia, a diferencia de variables como los precios internacionales o las condiciones climáticas, que presentan una mayor variabilidad en el corto plazo.

Adicionalmente, la serie de productividad total de los factores fue calculada con frecuencia anual y posteriormente desagregada a frecuencia mensual para su incorporación al modelo, proceso que pudo atenuar parcialmente la intensidad de sus variaciones. Aun así, los resultados muestran que las mejoras en la productividad contribuyen a reducir la inflación de alimentos y bebidas, aunque con una magnitud relativamente pequeña.

El Panel 2.5f muestra el impacto de un choque en las cadenas de suministro sobre la inflación de alimentos y bebidas en Estados Unidos. Como puede observarse, el impacto es creciente y sostenido, explicado por factores como la pandemia de COVID-19, que provocó la crisis de contenedores. La falta de contenedores interrumpió la cadena de suministro, ya que muchos insumos o materias primas no llegaron a tiempo, lo que en ocasiones condujo a la especulación. Asimismo, el inicio de la guerra entre Rusia y Ucrania provocó una escasez de

insumos para la mayoría de los países, ya que la cadena de suministro a través del Mar Negro también se vio interrumpida, reduciendo las exportaciones de estos países afectados por el conflicto. Los hallazgos son consistentes con los de Abbai et al. (2022), quienes destacan las interrupciones en las cadenas de suministro como un impulsor muy importante de la inflación en general y de la inflación de alimentos y bebidas en particular en Estados Unidos. Cabe señalar aquí que, aunque este trabajo no mide el impacto que el cambio climático extremo puede tener sobre la interrupción de las cadenas de suministro, puede afectarlas principalmente en relación con daños a carreteras o autopistas.

El Panel 2.5c muestra el efecto de un choque en el factor Prexteraltos, que captura los riesgos de mayores presiones al alza que se acentúan cuando los índices de precios internacionales de materias primas se encuentran en su parte superior. Como puede observarse, la inflación en el sector de alimentos y bebidas aumenta ligeramente desde el período 4 hasta el 12 y luego se desvanece. Esto es contrario a lo que ocurre cuando el choque se produce en el factor Prextermedios, que captura la media en los índices de precios internacionales de materias primas, donde la inflación aumenta de manera sostenida desde el período 4 hasta el período 20 (véase el Panel 2.5d). Este resultado puede justificarse porque un choque en las partes superiores de las distribuciones de los índices internacionales de precios tiende a retornar a sus valores medios a medida que los agentes económicos buscan formas de adaptarse a las nuevas condiciones, mientras que los choques en la parte mediana de las distribuciones de estos índices tienden a ser persistentes.

El Panel 2.5e muestra que un choque en el primer percentil 50 de las distribuciones de las variables macroeconómicas y financieras de Estados Unidos (USIncofinan) afecta significativamente la inflación de alimentos y bebidas en Estados Unidos, disminuyéndola en los

primeros 5 meses antes de desvanecerse. Finalmente, el Panel 2.5g muestra que un choque positivo en la inflación de alimentos conduce a un aumento estadísticamente significativo y persistente en su propia dinámica durante los horizontes iniciales, lo que indica un fuerte grado de inercia inflacionaria. Sin embargo, la magnitud de la respuesta se estabiliza gradualmente y disminuye en horizontes más largos, lo que sugiere que los choques en la inflación de alimentos presentan persistencia de corto a mediano plazo, pero no generan efectos permanentes.

Figura 0.6 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de bajas temperaturas (DT10USA).




Figura 0.7 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de la precipitación estandarizada (DPRECIUSA).




Figura 0.8 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de los días secos consecutivos estandarizados (DCDDUSA).




Figura 0.9 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de la velocidad del viento estandarizada (DWP90).





Figura 0.10 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación del nivel del mar estandarizado (DSEAUSA).



Un análisis de las funciones de impulso-respuesta en las Figuras 2.6 a 2.10 muestra que un choque en las variables comunes consideradas en la especificación 5 tiene un efecto similar sobre la inflación de alimentos y bebidas en Estados Unidos al exhibido por las propias funciones de impulso-respuesta (véase la Figura 2.5), demostrando así un comportamiento consistente a través de las diferentes especificaciones. Esto implica que las variables climáticas introducidas en cada modelo considerado no determinan la dinámica de estas variables comunes. Al analizar el efecto de un choque en: la variación en la frecuencia estandarizada de bajas temperaturas en Estados Unidos (DT10USA), la variación estandarizada de la precipitación para Estados Unidos (DPRECIUSA), la variación estandarizada de la velocidad del viento para Estados Unidos (DWP90USA), la variación estandarizada del nivel del mar para Estados Unidos (DSEAUSA) y

la variación estandarizada de los días secos consecutivos para Estados Unidos (DCDDUSA), se observa que no existe un efecto estadísticamente significativo sobre la inflación de alimentos y bebidas (véanse las Figuras 2.6a, 2.7a, 2.8a, 2.9a y 2.10a). Estos resultados sugieren que, de manera aislada, estas variables no presentan una influencia fuerte o sistemática sobre la dinámica de la inflación. Por ejemplo, aunque la precipitación generalmente se asocia con mejores rendimientos de los cultivos, su efecto puede verse contrarrestado por interacciones adversas con otros factores de estrés climático (por ejemplo, días secos o viento). De manera similar, el nivel del mar y la velocidad del viento, aunque relevantes en el contexto de eventos climáticos extremos, no parecen tener un impacto regular o directo sobre las fluctuaciones de corto plazo en los precios de los alimentos.

En conjunto, estos hallazgos subrayan que no todas las variables climáticas afectan la inflación de alimentos por igual y que los efectos de los choques climáticos son complejos y potencialmente moderados por la adaptación tecnológica, el tipo de cultivo o las interacciones entre variables.

Con el fin de evaluar la importancia de cada variable en la explicación de la inflación de alimentos en Estados Unidos, el modelo se estimó considerando únicamente dos componentes climáticos: la variación estandarizada en la frecuencia de temperaturas extremadamente altas (DT90USA) y la variación estandarizada en días secos consecutivos (DCDDUSA). Las funciones de impulso-respuesta se calcularon utilizando una identificación ortogonal basada en la descomposición de Cholesky. Este enfoque permite analizar la descomposición de la varianza del error de pronóstico. Las variables se ordenan desde la más exógena hasta la más endógena de la siguiente manera: componente climático, productividad total de los factores, el primer factor del

percentil 90 de los índices de precios internacionales de materias primas, el primer factor del percentil mediano de los índices de precios internacionales de materias primas, el primer factor del percentil mediano de la actividad económica y financiera de Estados Unidos, el Índice de Presión de la Cadena Global de Suministro y la inflación de alimentos y bebidas. Los resultados muestran que cuando se utilizan variaciones estandarizadas en temperaturas extremadamente altas (DT90USA) como variable climática, la inflación de alimentos está en gran medida explicada por sus propios choques (82,6%), lo que refleja una fuerte inercia de corto plazo. Sin embargo, esta contribución disminuye de manera sostenida hasta alrededor de 41,8% después de 12 meses y hasta casi 35% en un horizonte de 20 meses. Durante el mismo período, el poder explicativo de factores externos y estructurales aumenta sustancialmente. En particular, las presiones de los precios internacionales de materias primas, la actividad económica y financiera interna, las disrupciones en las cadenas de suministro, la productividad total de los factores y los extremos climáticos explican conjuntamente casi el 58% de la variabilidad de la inflación de alimentos después de un año y aproximadamente el 65% en el horizonte de mediano plazo. Entre estos determinantes, las condiciones macrofinancieras y los precios internacionales de materias primas emergen como los contribuyentes dominantes, mientras que los extremos climáticos exhiben un efecto menor pero persistente, reforzando la idea de que los choques climáticos actúan principalmente a través de canales indirectos, como pérdidas de productividad y disrupciones del lado de la oferta, más que como una fuerza inflacionaria directa. Estos resultados son consistentes con Marin et al. (2025), quienes documentan que la dinámica de los precios agrícolas está impulsada principalmente por choques macrofinancieros externos, y con Mitra et al. (2025), quienes enfatizan que los riesgos

climáticos afectan la inflación en gran medida a través de mecanismos de transmisión del sector real y de la cadena de suministro.

Como prueba de robustez, reemplazamos las temperaturas extremas por la variación estandarizada de los días secos consecutivos (DCCDUSA) como variable climática. La descomposición de la varianza permanece cualitativamente sin cambios, confirmando la estabilidad del mecanismo de transmisión. La inflación de alimentos continúa estando en gran medida impulsada por su propia inercia en el corto plazo, mientras que los precios internacionales de materias primas, las condiciones económico-financieras, las presiones en la cadena de suministro y la productividad ganan relevancia en horizontes de mediano plazo. La contribución de los choques climáticos aumenta gradualmente con el tiempo, alcanzando aproximadamente entre 3% y 4% en horizontes más largos, lo cual es ligeramente inferior a lo observado para las temperaturas extremas. En general, estos resultados refuerzan la robustez de los resultados obtenidos.

Robustez de los resultados

Para evaluar la robustez de los resultados presentados en la sección anterior, se realizaron varios análisis de robustez complementarios. Estos incluyen: (i) esquemas alternativos de identificación del modelo VAR, (ii) estimación para el período previo a la pandemia, y (iii) la inclusión de variables adicionales económicamente relevantes.

Funciones de impulso-respuesta bajo identificación Cholesky

Como ejercicio de robustez, todas las funciones de impulso-respuesta fueron reestimadas utilizando una identificación ortogonal basada en la descomposición de Cholesky. En este estudio, solo se reportan dos de estas funciones, correspondientes a variaciones en la frecuencia estandarizada de altas temperaturas (DT90USA) y días secos consecutivos (DCCDUSA).

Los resultados confirman los hallazgos obtenidos a partir de las funciones de impulso-respuesta generalizadas. En particular, los choques climáticos extremos, la productividad total de los factores y los determinantes externos continúan generando respuestas inflacionarias con el mismo signo y en horizontes similares. Las diferencias observadas están principalmente relacionadas con la magnitud de las respuestas, lo cual es consistente con los supuestos alternativos de identificación y no altera la interpretación económica de los resultados (véanse las Figuras 2.11 y 2.12).

Figura 0.11 Respuestas acumuladas Cholesky de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA).





Figura 0.12 Respuestas acumulativas de Cholesky de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de días secos consecutivos estandarizados (DCDDUSA).



Modelacion Prepandemia

En esta subsección, se realiza un análisis por submuestra restringiendo el período de estimación hasta diciembre de 2019, con el fin de excluir los efectos excepcionales asociados con la pandemia de COVID-19. Los resultados, al considerar la variación estandarizada en la frecuencia de temperaturas extremadamente altas (DT90), muestran que el efecto del Índice de Presión de la Cadena Global de Suministro (GSCPI) desaparece. Esto implica que el modelo captura adecuadamente los choques inesperados y sus efectos sobre la inflación de alimentos y bebidas, particularmente aquellos asociados con el COVID-19. Sin embargo, los efectos de las otras variables del modelo son similares a los obtenidos utilizando el período muestral completo, excepto por el factor asociado con la actividad económica, cuyo efecto sobre la inflación de

alimentos y bebidas también desaparece (véase la Figura 2.13). Se observa un patrón similar cuando se introduce la variación estandarizada de los días secos consecutivos como componente climático. No obstante, en esta especificación, el efecto propio de la inflación sobre la inflación de alimentos y bebidas se vuelve estadísticamente insignificante después del período 15, indicando un debilitamiento de la persistencia inflacionaria en horizontes más largos (véase la Figura 2.14).

Figura 0.13 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA). Periodo prepandemia.





Figura 0.14 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de los días secos consecutivos estandarizados (DCDDUSA). Período prepandémico.



Modelación con variables adicionales

Esta subsección amplía el modelo base incorporando la actividad económica global, la tasa de interés real y los precios de la energía con el fin de evaluar posibles sesgos por variables omitidas y fortalecer el marco empírico desde una perspectiva de política económica. Estas variables fueron incorporadas al modelo FAVAR utilizando la misma estructura de rezagos seleccionada para el modelo base, la cual fue determinada mediante pruebas de autocorrelación serial de los residuos (LM test), permitiendo capturar la dinámica temporal común de todas las variables endógenas.

Los indicadores climáticos considerados siguen siendo la variación estandarizada de las temperaturas extremadamente altas (DT90USA) y la variación estandarizada de los días secos

consecutivos (DCCDUSA). Los resultados muestran que la actividad económica global ajustada estacionalmente y la variación de los precios de la energía afectan la inflación de alimentos y bebidas con rezago, transmitiéndose los precios de la energía con mayor rapidez.

En contraste, la tasa de interés real no exhibe un efecto directo significativo sobre la inflación de alimentos. Es importante destacar que los patrones de las funciones de impulso-respuesta del modelo central permanecen en gran medida sin cambios tras incluir estas variables adicionales, lo que sugiere que los principales hallazgos son robustos y no están impulsados por la dinámica de la demanda global ni por los precios de la energía (véanse Figuras 2.15 – 2.20).

Figura 0.15 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA), incluyendo la actividad económica global.




Figura 0.16 Respuestas acumulativas de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de días secos consecutivos estandarizados (DCDDUSA), incluyendo la actividad económica mundial.




Figura 0.17 Respuestas acumulativas de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA), incluyendo la tasa de interés real.




Figura 0.18 Respuestas acumulativas de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de los días secos consecutivos estandarizados (DCDDUSA), incluyendo la tasa de interés real.




Figura 0.19 Respuestas acumulativas de la inflación de alimentos y bebidas a perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA) y el índice de precios de combustible y energía.





Figura 0.20 Respuestas acumulativas de la inflación de alimentos y bebidas a las perturbaciones en las variables del modelo, especialmente en la variación de los días secos consecutivos estandarizados (DCDDUSA) y el índice de precios de combustibles y energía.



Modelos regionales


Dado que la variable dependiente corresponde a la inflación nacional de alimentos y bebidas, el análisis principal se realizó utilizando indicadores climáticos agregados para Estados Unidos, manteniendo así la consistencia entre la escala geográfica de las variables explicativas y la variable de interés. No obstante, se reconoce que los impactos climáticos presentan una importante heterogeneidad regional. Por esta razón, como análisis complementario, se estimó un modelo para la región del Medio Oeste, principal zona agrícola del país, con el fin de evaluar la sensibilidad de los resultados frente a una especificación regional.

Para capturar la heterogeneidad regional, se asume que los choques externos afectan simultáneamente tanto al agregado nacional como a las regiones, y que la productividad total de

los factores a nivel nacional —impulsada por la inversión en investigación y desarrollo— se transmite a las economías regionales. Bajo este marco, se estimó un modelo para la región del Medio Oeste, dado su papel como el principal centro de producción agrícola en Estados Unidos, concentrando una parte significativa de la producción de maíz, soya, trigo, ganado y lácteos, todos los cuales tienen un peso notable en el índice de precios al consumidor.

La variable climática considerada es la variación estandarizada de la frecuencia de altas temperaturas en esa región. Los resultados muestran que el efecto de corto plazo asociado con el componente climático desaparece, mientras que el impacto del factor de cola superior de los precios internacionales de materias primas es casi inmediato, y el efecto de la inflación sobre su propia dinámica es mucho más lento. A pesar de estas diferencias, las funciones de impulso-respuesta a nivel regional son cualitativamente similares a las del nivel nacional (véase la Figura 2.21).

Figura 0.21 Respuestas acumuladas de la inflación de alimentos y bebidas ante perturbaciones en las variables del modelo, especialmente en la variación de la frecuencia estandarizada de altas temperaturas (DT90USA) para la región del Medio Oeste.



Conclusiones

La evidencia indica que la variabilidad climática, más que el cambio climático de largo plazo, no desempeña un papel importante en la explicación de la inflación de alimentos y bebidas en Estados Unidos durante el período analizado. La investigación y el desarrollo tecnológico en el sector agrícola han mitigado los impactos del cambio climático, principalmente mediante el desarrollo de semillas resistentes a altas y bajas temperaturas frecuentes y el diseño de sistemas de riego inteligentes para días secos.

Estos resultados coinciden o están en línea con diversos estudios que muestran que la investigación y el desarrollo tecnológico es una de las herramientas que los países deben utilizar para mitigar los efectos del cambio climático, especialmente en el sector agrícola. Cuando un país

adopta agricultura de secano, está más expuesto a los impactos del cambio climático, lo cual generalmente es el caso en los países de ingreso medio.

Aunque la I+D mitiga los efectos del cambio climático, es importante considerar la velocidad a la cual los agricultores se adaptan a estos desarrollos tecnológicos en las distintas regiones del país. Un retraso significativo en esta adopción y la falta de incentivos para incorporar estos avances pueden afectar considerablemente la oferta de alimentos frente a choques climáticos, impactando de manera importante la inflación de alimentos y bebidas y, en consecuencia, el acceso a estos productos por parte de los segmentos de menores ingresos de la población.

Por otro lado, factores externos como las cadenas globales de suministro son uno de los principales determinantes del aumento de la inflación de alimentos y bebidas en Estados Unidos. La disrupción de estas cadenas impide que los alimentos o las materias primas lleguen a los consumidores o productores, generando escasez y, en consecuencia, un incremento sostenido de los precios tanto de los alimentos como de las materias primas.

Finalmente, las variaciones en los precios internacionales de las materias primas, medidas a través de las fluctuaciones en la mediana y en la cola superior de las distribuciones de los índices internacionales de precios de materias primas, tienen un impacto significativo en la inflación de alimentos y bebidas en Estados Unidos.

Se espera que estos resultados contribuyan a mejorar la comprensión de la inflación de alimentos y bebidas en Estados Unidos y orienten a los responsables de política relacionados con el sector agrícola en ese país.

Implicaciones de política

Dado que la investigación, el desarrollo y la innovación tecnológica son instrumentos clave para mitigar los impactos del cambio climático en el sector agrícola y los riesgos asociados para la seguridad alimentaria, este estudio aboga por un aumento en la inversión en I+D, particularmente en agricultura, incorporando avances recientes en inteligencia artificial. Además, es esencial diseñar e implementar políticas efectivas de transferencia y adopción tecnológica, tanto entre las regiones de Estados Unidos como en países que enfrentan restricciones técnicas y financieras que limitan su capacidad para llevar a cabo este tipo de investigación. Este enfoque fortalecería la resiliencia de los sistemas alimentarios y ayudaría a garantizar el acceso a los alimentos para las poblaciones más vulnerables.

Limitaciones y futuras líneas de investigación

Una de las principales limitaciones de este estudio es que los datos de Productividad Total de los Factores (PTF) solo están disponibles con frecuencia anual, lo que requirió la aplicación de un procedimiento de desagregación temporal para alinearlos con la frecuencia mensual de las demás variables. Aunque este enfoque garantiza consistencia temporal dentro del modelo, el proceso de desagregación puede introducir errores de medición y suavizar la dinámica subyacente de la productividad, lo que potencialmente conduce a una subestimación del verdadero impacto de la PTF sobre la inflación de alimentos y bebidas.

Como líneas futuras de investigación, se propone extender el marco empírico desarrollado en este estudio mediante el empleo de metodologías econométricas alternativas, incluyendo VAR bayesianos (BVAR), VAR con parámetros que varían en el tiempo (TVP-VAR) y modelos de panel espacial. Estas extensiones permitirían evaluar la robustez de los principales hallazgos bajo diferentes esquemas de identificación y estimación, al tiempo que capturarían posibles no linealidades, cambios estructurales e interdependencias espaciales entre regiones. Específicamente, los modelos BVAR podrían ayudar a aliviar problemas de sobreparametrización en sistemas de alta dimensión; los modelos TVP-VAR permitirían analizar la evolución temporal de los efectos dinámicos del clima sobre la inflación de alimentos y la productividad; y los enfoques de panel espacial facilitarían el examen de efectos de derrame regional derivados de choques climáticos y de precios.

Referencias

- Abbai, B., Akinci, O., Benigno, G., di Giovanni, J., Groen, J. J., Heymann, R. C., ... & Noble, A. I. (2022). *The global supply side of inflationary pressures* (No. 20220128). *Federal Reserve Bank of New York*.
- Alston, J. M. (2010). “*The Benefits from Agricultural Research and Development, Innovation, and Productivity Growth*”, *OECD Food, Agriculture and Fisheries Papers*, No. 31.
- Alston, J.M., J.M. Beddow, and P.G. Pardey (2009). *Mendel versus Malthus: Research,*

Productivity, and Food Prices in the Long Run (InSTePP Working Paper), St Paul, University of Minnesota).

Bai, J., & Ng, S. (2002). Determining the number of factors in approximate factor models. *Econometrica*, 70(1), 191-221

Bedasa, Y., & Bedemo, A. (2023). The effect of climate change on food insecurity in the Horn of Africa. *GeoJournal*, 88(2), 1829-1839.

Benigno, G., di Giovanni, J., Groen, J. J. J., & Noble, A. I. (2022). *The GSCPI: A new barometer of global supply chain pressures* (Staff Report No. 1017). Federal Reserve Bank of New York.

Benson, C. (2024). *Poverty in states and metropolitan areas: 2023* (American Community Survey Briefs, ACSBR-022). U.S. Census Bureau.

<https://www.census.gov/library/publications/2024/acs/acsbr-022.html>

Bernanke, B. S., Boivin, J., & Elias, P. (2005). Measuring the effects of monetary policy: a factor-augmented vector autoregressive (FAVAR) approach. *The Quarterly Journal of Economics*, 120(1), 387-422.

Chand, R. (2010). Understanding the nature and causes of food inflation. *Economic and Political Weekly*, 10-13.

Chen, L., Dolado, J. J., & Gonzalo, J. (2021). Quantile factor models. *Econometrica*, 89(2), 875-910.

Chidiac, S. E., Yao, L., & Liu, P. (2022). Climate change effects on heating and cooling demands of buildings in Canada. *CivilEng*, 3(2), 277-295.

Fugli Fuglie, K. O., & Heisey, P. W. (2007). *Economic returns to public agricultural research* (Economic Brief No. 10). United States Department of Agriculture, Economic Research Service.

Gammans, M., & Schaefer, K. A. (2025). Is Climate Change a Driver of Food Price Inflation?. *Choices*, 40(3), 1-7.

Kotz, M., Kuik, F., Lis, E., & Nickel, C. (2023). The impact of global warming on inflation: averages, seasonality and extremes.

Majahana, J. M., Kalumba, A. M., Zhou, L., Mazinyo, S. P., & Afuye, G. A. (2025). Global trend analysis of climate change adaptation policy and governance in the water sector. *Discover Sustainability*, 6(1), 1-15.

Marín-Rodríguez, N. J., Gonzalez-Ruiz, J. D., & Botero, S. (2025). Connectedness of Agricultural Commodities Under Climate Stress: Evidence from a TVP-VAR Approach. *Sci*, 7(3), 123.

Matsa, M., & Dzawanda, B. (2019). Beitbridge minority farmer communities and climate change: prospects for sustainability. In *Climate change and agriculture*. IntechOpen.

McCracken, M. W., & Ng, S. (2016). FRED-MD: A monthly database for macroeconomic research. *Journal of Business & Economic Statistics*, 34(4), 574-589

McFetridge, S. (2024). “Short corn” could replace the towering cornfields steamrolled by a changing climate. *Associated Press*.

<https://apnews.com/article/b5e580aee90ec4cbbabf7b8f6e9e62ea>

- Mehibel, S., Boudjana, R. H., Zambrano-Monserrate, M. A., Bouzid, A., & Lazereg, M. (2025). Food security, prices, and geopolitical risk: a dynamic panel threshold model. *Geopolit. Under Global.*, 6, 30-44.
- Mitra, P., Batini, N., Kahn, B., Lam, W. R., et al. (2025). *Integrating climate change into macroeconomic analysis: A review of impact channels, data, models, and scenarios*. International Monetary Fund.
- Ortiz-Bobea, A., Knippenberg, E., & Chambers, R. G. (2018). Growing climatic sensitivity of US agriculture linked to technological change and regional specialization. *Science advances*, 4(12), eaat4343.
- Plastina, A., & Fulginiti, L. (2012). Rates of return to public agricultural research in 48 US states. *Journal of Productivity Analysis*, 37(2), 95-113.
- Poncela, P., Senra, E., & Sierra, L. P. (2014). Common dynamics of nonenergy commodity prices and their relation to uncertainty. *Applied Economics*, 46(30), 3724-3735.
- Plastina, A., y Fulginiti, L. (2012). Tasas de rentabilidad de la investigación agrícola pública en 48 estados de EE. UU. *Journal of Productivity Analysis*, 37 (2), 95-113.
- Sheng, Y., Ball, E., & Nossal, K. (2015). Comparing agricultural total factor productivity between Australia, Canada, and the United States, 1961-2006. *Centre for the Study of Living Standards*.
- Ullah, A., Ahmad, I., Saeed, U., Ahmad, A., Mahmood, A., & Hoogenboom, G. (2019). Climate smart interventions of small-holder farming systems. *In Climate change and agriculture*. IntechOpen.
- USDA, ERS. (2025). *Agricultural productivity in the United States: Productivity growth estimates, 1948-2021*.

U.S. Bureau of Labor Statistics. (2024). *Consumer Price Index for all food and beverages*.

Walthall, C.L., J. Hatfield, P. Backlund, L. Lengnick, E. Marshall, M. Walsh, S. Adkins, M. Aillery, E.A. Ainsworth, C. Ammann, C.J. Anderson, I. Bartomeus, L.H. Baumgard, F. Booker, B. Bradley, D.M. Blumenthal, J. Bunce, K. Burkey, S.M. Dabney, J.A. Delgado, J. Dukes, A. Funk, K. Garrett, M. Glenn, D.A. Grantz, D. Goodrich, S. Hu, R.C. Izaurralde, R.A.C. Jones, S-H. Kim, A.D.B. Leaky, K. Lewers, T.L. Mader, A. McClung, J. Morgan, D.J. Muth, M. Nearing, D.M. Oosterhuis, D. Ort, C. Parmesan, W.T. Pettigrew, W. Polley, R. Rader, C. Rice, M. Rivington, E. Rosskopf, W.A. Salas, L.E. Sollenberger, R. Srygley, C. Stöckle, E.S. Takle, D. Timlin, J.W. White, R. Winfree, L. Wright-Morton, L.H. Ziska. (2012). *Climate Change and Agriculture in the United States: Effects and Adaptation*. USDA Technical Bulletin 1935. Washington, DC. 186 pages.

Wang, S. L., Heisey, P., Schimmelpfennig, D., & Ball, V. E. (2015). *Agricultural productivity growth in the United States: Measurement, trends, and drivers*. Economic Research Service, Paper No. Err-189, U.S. Department of Agriculture, Economic Research Service.

Wheeler, T., & Von Braun, J. (2013). Climate change impacts on global food security. *Science*, 341(6145), 508-513.

ANEXOS

Anexo 2.1.

Descripción de los componentes del índice climático actuarial para Estados Unidos

Código	Variable	Descripción
T90USA	Frecuencia estandarizada de altas temperaturas en EE. UU.	Mide el número de desviaciones estándar en que la frecuencia de días que superan el percentil 90 de altas temperaturas se desvía de la frecuencia promedio histórica de referencia para el período 1961 a 1990 en un mes determinado.
T10USA	Frecuencia estandarizada de bajas temperaturas en EE. UU.	Mide el número de desviaciones estándar en que la frecuencia de días por debajo del percentil 10 de bajas temperaturas se desvía en un mes determinado de la frecuencia promedio histórica de referencia para el período 1961 a 1990..
SEAUSA	Nivel del mar estandarizado en EE. UU.	Mide el número de desviaciones estándar de la diferencia entre el nivel del mar en un mes determinado y el nivel promedio histórico de referencia del período 1961 a 1990.
PRECIUSA	Precipitación estandarizada en EE. UU.	Mide el número de desviaciones estándar de la diferencia entre la precipitación mensual máxima en un periodo de cinco días en un mes determinado y la precipitación máxima promedio histórica del período de referencia 1961 a 1990.
WP90USA	Velocidad promedio del viento estandarizada en EE. UU.	Mide el número de desviaciones estándar de la diferencia entre la frecuencia de velocidades del viento por encima del percentil 90 en un mes determinado y la frecuencia de velocidades del viento por encima del percentil 90 del promedio histórico de referencia del período 1961 a 1990.
CDDUSA	Días secos consecutivos estandarizados en EE. UU.	Mide el número de desviaciones estándar de la diferencia entre el número máximo anual de días secos consecutivos en un mes determinado y el número máximo anual de días secos del período histórico de referencia 1961 a 1990.

CAPITULO 3. DESEMPEÑO PREDICTIVO DE MODELOS FACTORIALES Y REDES NEURONALES: UN ANÁLISIS COMPARATIVO DE LA INFLACIÓN DE ALIMENTOS Y BEBIDAS EN ESTADOS UNIDOS.

Resumen

Este estudio evalúa el desempeño predictivo de distintos modelos para la inflación mensual de alimentos y bebidas en Estados Unidos. Utilizando 203 observaciones mensuales y un esquema de evaluación fuera de muestra con ventanas móviles, se comparan en la muestra completa modelos econométricos —autorregresivo, factorial dinámico y factorial cuantílico— y dos arquitecturas de deep learning (NHITS y TiDE). El desempeño predictivo se evalúa mediante el error cuadrático medio (ECM), la raíz del error cuadrático medio (RMSE) y el test de Diebold–Mariano.

En la muestra completa, los modelos factoriales generan reducciones modestas del ECM respecto al modelo autorregresivo de referencia, aunque dichas mejoras no resultan estadísticamente significativas en el corto plazo ($h = 1$). En contraste, las arquitecturas de deep learning presentan un desempeño significativamente inferior, evidenciando que una mayor flexibilidad no lineal no se traduce necesariamente en mejores pronósticos a muy corto horizonte.

Adicionalmente, se analiza el comportamiento de los modelos econométricos bajo dos regímenes inflacionarios definidos por el percentil 75 de la distribución. Los resultados muestran una clara dependencia por régimen: en episodios de inflación baja, la dinámica autorregresiva captura adecuadamente la señal relevante, mientras que en episodios de alta inflación los modelos factoriales —particularmente el dinámico y el cuantílico— reducen de manera significativa el error de pronóstico. Estos hallazgos sugieren que la información contenida en la parte superior de la

distribución adquiere relevancia predictiva principalmente en contextos de mayores presiones inflacionarias

Introducción.

La elaboración de pronósticos fiables y precisos de la inflación es fundamental para los responsables de la política monetaria y fiscal, para los inversionistas que gestionan el riesgo de activos nominales y para trabajadores y empresas en los procesos de negociación salarial. En particular, el comportamiento de la inflación en alimentos y bebidas adquiere una relevancia especial desde la perspectiva de la política pública, dado que aumentos persistentes en estos precios afectan de manera desproporcionada a los hogares de menores ingresos y pueden comprometer su seguridad alimentaria. En contextos de inflación elevada de alimentos, las decisiones gubernamentales en materia de subsidios, transferencias o ajustes fiscales dependen críticamente de la capacidad de anticipar con precisión la dinámica de estos precios. La precisión y fiabilidad de los pronósticos de la inflación, en general, y de la inflación de alimentos y bebidas, en particular, resaltan la importancia de identificar aquellos métodos que, bajo un contexto específico, ofrecen mejores resultados predictivos.

En los últimos años, diversas investigaciones se han orientado al pronóstico de variables macroeconómicas como la inflación y a la evaluación comparativa de distintos enfoques metodológicos. Entre estos estudios destacan los de Stock y Watson (1999) quienes muestran que, aunque la curva de Phillips puede aportar información útil para predecir la inflación, basarse exclusivamente en ella e ignorar otras medidas de actividad económica limita el desempeño predictivo. Posteriormente, Stock y Watson (2002) demuestran que los métodos basados en

factores permiten obtener predicciones factibles asintóticamente eficientes en entornos con gran número de predictores. En esta línea, Artis et al. (2005) encuentran que los modelos factoriales dinámicos mejoran el error cuadrático medio de pronóstico frente a modelos estándar de series temporales para variables macroeconómicas de Estados Unidos y la Unión Europea.

De manera complementaria, Ciccarelli y Mojon (2010) evidencian que un modelo autorregresivo ampliado con factores globales supera sistemáticamente al AR puro, la caminata aleatoria y la curva de Phillips en distintos horizontes de pronóstico y para la mayoría de los países considerados.

La aplicación de modelos factoriales dinámicos al pronóstico de inflación en economías específicas también ha mostrado resultados favorables. Chen y Lin (2011) aplican un modelo factorial dinámico aproximado para pronosticar inflación en Taiwán utilizando ventanas móviles y encuentran un desempeño superior frente a modelos AR y VAR para distintos horizontes. Para la economía chilena, Aguirre y Cespedes (2011) muestran que la incorporación de factores mejora significativamente las proyecciones fuera de muestra de la inflación y fortalece el ajuste en modelos estructurales como la curva de Phillips. Más recientemente, Aysu y Bering (2024) desarrollan un modelo factorial dinámico para una economía pequeña y abierta y encuentran que supera a modelos ARIMA, a medidas basadas en encuestas y a modelos DSGE en la predicción de la inflación tanto dentro como fuera de muestra. Para Estados Unidos, Della Marra (2017) compara diferentes especificaciones factoriales dinámicas con un AR de orden cuatro y reporta que, en general, los modelos factoriales superan al AR, aunque el desempeño depende de la naturaleza de las variables consideradas.

Una extensión relevante de esta literatura incorpora enfoques cuantílicos dentro del marco factorial. Cheng et al. (2021) comparan un modelo factorial cuantílico con un modelo factorial dinámico y un AR como referencia, considerando el crecimiento del PIB y la inflación. Sus resultados indican que el desempeño para la inflación a un horizonte de un periodo no es necesariamente superior en la muestra completa, aunque se observan mejoras cuando la muestra se divide en periodos de crisis y recuperación. De manera más reciente, Nazlioglu et al. (2025) aplican un modelo factorial cuantílico para analizar la estructura de correlación de cuantiles de la inflación en una muestra global de 151 países entre 1970 y 2023, encontrando que los factores de cuantiles mejoran las predicciones de densidad tanto en economías desarrolladas como emergentes.

Paralelamente, ha emergido una línea de investigación que utiliza técnicas de aprendizaje automático y deep learning para el pronóstico de la inflación. Yang y Guo (2021) emplean redes neuronales recurrentes con unidad GRU para pronosticar la inflación en China y encuentran un desempeño significativamente superior frente a modelos AR y VAR. Para Colombia, Cárdenas et al. (2023) utilizan redes LSTM y reportan mejor capacidad predictiva que modelos ARIMA, especialmente en horizontes más largos y cuando se incorporan variables adicionales. En el caso de Estados Unidos, Paranhos (2025) aplica LSTM y encuentra que el modelo funciona mejor en horizontes largos y durante periodos de mayor incertidumbre macroeconómica.

Theoharidis et al. (2023) proponen un modelo híbrido basado en autoencoders variacionales y redes ConvLSTM que supera a modelos econométricos y de aprendizaje automático tradicionales en términos de consistencia fuera de muestra. De manera similar,

Abotaleb et al. (2025) muestran que redes neuronales convolucionales superan a modelos ARIMA y VAR en la captura de patrones no lineales de la inflación en Egipto, mientras que Nortey et al. (2025) encuentran que modelos de deep learning y machine learning superan a ARIMA y ETS para Estados Unidos.

Los estudios revisados se han concentrado en el pronóstico de la inflación agregada en Estados Unidos y en la comparación entre distintos métodos de predicción. Sin embargo, hasta donde sabemos, no existe un estudio que evalúe el desempeño predictivo de modelos autorregresivos, modelos factoriales (dinámicos y cuantílicos) y arquitecturas modernas de aprendizaje profundo como TiDE y NHITS en el caso específico de la inflación de alimentos y bebidas en Estados Unidos.

La pregunta que rige la presente investigación es: ¿Mejoran los modelos factoriales, particularmente aquellos que incorporan factores cuantílicos derivados de índices de precios de materias primas, la capacidad predictiva de la inflación de alimentos en comparación con modelos autorregresivos y técnicas de deep learning en la muestra completa, y frente a modelos autorregresivos bajo distintos regímenes inflacionarios?

A partir de la pregunta de investigación anterior, se plantea la siguiente hipótesis de investigación: los modelos factoriales, en particular aquellos que incorporan factores cuantílicos derivados de índices de precios internacionales de materias primas alimentarias, mejoran la capacidad predictiva de la inflación de alimentos y bebidas en Estados Unidos respecto a los modelos autorregresivos y a las arquitecturas de deep learning. Se espera, además, que dicha ventaja predictiva sea más pronunciada durante episodios de alta inflación, cuando la información

contenida en las colas superiores de la distribución adquiere mayor contenido informativo para el pronóstico.

Con el fin de contrastar esta hipótesis, se plantea como objetivo del artículo evaluar comparativamente el desempeño predictivo a un paso adelante de un modelo ARIMA, un modelo factorial dinámico, un modelo factorial cuantílico y dos arquitecturas modernas de redes neuronales, Interpolación Jerárquica Neuronal para Series Temporales NHITS y el Codificador Denso de Series Temporales TiDE, en el pronóstico de la inflación de alimentos y bebidas en Estados Unidos.

La muestra total abarca el período 1992.01–2024.05. La evaluación fuera de muestra se implementa mediante ventanas móviles con 180 observaciones de entrenamiento, generando 203 pronósticos recursivos a un paso adelante.

Adicionalmente, se analiza el desempeño bajo distintos regímenes inflacionarios, restringiendo en este caso la comparación a los modelos autorregresivos y factoriales debido a los requerimientos de tamaño muestral de las arquitecturas de redes neuronales.

Este artículo contribuye a la literatura de pronóstico de inflación al evaluar, en el contexto de la inflación de alimentos y bebidas en Estados Unidos, si factores cuantílicos extremos mejoran la precisión predictiva a un paso adelante frente a modelos autorregresivos y factoriales basados en la media condicional, así como frente a arquitecturas modernas de redes neuronales. Adicionalmente, examina si el desempeño relativo entre modelos autorregresivos y factoriales varía según el régimen inflacionario.

Este documento, además de esta introducción, presenta la siguiente estructura. La Sección 2 presenta la descripción de los datos utilizados. La Sección 3 presenta la metodología desarrollada en esta investigación, así como la modelación. La sección 4 presenta los principales resultados. La sección 5 presentan las principales conclusiones.

Descripción de datos.

La base de datos está compuesta por 24 series mensuales de índices internacionales de precios de materias primas alimentarias reportadas por el Fondo Monetario Internacional (FMI), correspondientes a diferentes categorías de cereales, aceites, carnes, bebidas y otros productos alimentarios. La relación completa de las materias primas utilizadas se presenta en el Anexo 3.1. El período muestral abarca desde enero de 1992 hasta mayo de 2024. Adicionalmente, se utiliza la serie mensual de inflación de alimentos y bebidas en Estados Unidos, obtenida de la *U.S. Bureau of Labor Statistics*, la cual constituye la variable objetivo del ejercicio de pronóstico.

Antes de estimar los modelos, todas las series fueron desestacionalizadas. Posteriormente, se aplicó la prueba de Dickey-Fuller Aumentada para determinar la transformación necesaria que permitiera obtener series aproximadamente estacionarias, asignando a cada variable el correspondiente código de transformación (*tcode*). Finalmente, las series transformadas fueron estandarizadas restando su media y dividiendo por su desviación estándar. Estas transformaciones garantizan que las variables utilizadas en la estimación de los factores cuantílicos y en la comparación entre los distintos modelos predictivos se encuentren en una escala homogénea.

Metodología y Modelación

Para la evaluación fuera de muestra se implementa un esquema de ventana móvil (rolling window) con tamaño fijo de 180 observaciones mensuales (equivalente a 15 años de información). El primer pronóstico se genera utilizando la muestra inicial y, posteriormente, la ventana de estimación se desplaza secuencialmente un período a la vez hasta marzo de 2024.

El desempeño predictivo se analiza en tres contextos: (i) la muestra completa de evaluación, (ii) períodos en los que la inflación de alimentos y bebidas se ubica por debajo del percentil 75 de su distribución fuera de muestra y (iii) períodos en los que supera dicho umbral, con el fin de evaluar posibles diferencias en la capacidad predictiva de los modelos bajo distintos regímenes inflacionarios.

En los subperíodos definidos por percentiles se comparan únicamente los modelos autorregresivo (AR) y factoriales (dinámico y cuantílico), dado que el tamaño muestral reducido podría afectar la estabilidad en la estimación de arquitecturas de aprendizaje profundo.

Las implementaciones computacionales de los modelos econométricos se realizaron en MATLAB, mientras que las arquitecturas de aprendizaje profundo (NHITS y TiDE) se implementaron en Python utilizando la librería NeuralForecast de Nixtla.

En lo que sigue, se presentan las estructuras formales de los modelos considerados en la investigación.

Modelo Autorregresivo AR(p)

El modelo autorregresivo de orden p se especifica como:

$$\pi_t = c + \sum_{i=1}^p \phi_i \pi_{t-i} + \varepsilon_t$$

Donde

π_t es la tasa de inflación de alimentos y bebidas en el periodo t

c es el término constante

ϕ_i son los coeficientes autorregresivos

ε_t es un término de error con propiedades de ruido blanco, tal que:

$$E(\varepsilon_t) = 0, \text{ Var}(\varepsilon_t) = \sigma^2, \text{ Cov}(\varepsilon_t, \varepsilon_{t-j}) = 0 \text{ para } j \neq 0$$

El modelo autorregresivo se utiliza como referencia (benchmark). Ya que explica la dinámica de la inflación de alimentos exclusivamente a partir de sus propios rezagos, capturando la persistencia temporal característica de las series macroeconómicas.

El orden del modelo se selecciona mediante el criterio de información Bayesiano (BIC), garantizando parsimonia y estabilidad en cada ventana de estimación.

Modelo Factorial Dinámico

Sea X_{it} con $i=1,2,\dots,N$ y $t=1,2,\dots,T$ una variable observada generada por un componente común y un componente idiosincrático:

$$X_{it} = \lambda_i' F_t + e_{it}$$

Donde

F_t es un vector $r \times 1$ de factores comunes latentes;

λ_i es el vector de cargas factoriales;

e_{it} es el componente idiosincrático.

Se asume que:

$$E(e_{it} | F_t) = 0,$$

por lo que el componente común condicional es: $E(X_{it} | F_t) = \lambda_i' F_t$

Este enfoque permite sintetizar la información contenida en un amplio conjunto de variables mediante un número reducido de factores comunes no observables. En esta investigación, los 24 índices internacionales de materias primas alimentarias se representan como combinaciones lineales de factores latentes y componentes idiosincráticos.

Los factores se estiman mediante componentes principales y posteriormente se incorporan en la ecuación de pronóstico de la inflación. Este método resulta particularmente adecuado en entornos de alta dimensionalidad, donde el uso directo de todas las variables podría generar problemas de sobreparametrización.

El número de factores retenidos se determinó mediante el criterio de información propuesto por Bai y Ng (2002). En cada ventana de estimación se seleccionó el número de factores que minimizó dicho criterio, garantizando una representación parsimoniosa de la información común contenida en las 24 series de índices de precios internacionales de materias primas alimentarias.

Modelo Factorial Cuantílico

El modelo factorial cuantílico extiende el enfoque tradicional al permitir que la relación entre factores y variables observadas dependa del cuantil $\tau \in (0,1)$. La especificación es:

$$X_{it} = \lambda'_i(\tau)F_t(\tau) + e_{it}(\tau)$$

Donde

$F_t(\tau)$ es un vector $r \times 1$ de factores comunes asociados al cuantil τ ;

$\lambda_i(\tau)$ son las cargas factoriales dependientes del cuantil;

$e_{it}(\tau)$ es el componente idiosincrático

Observe que tanto los factores como las cargas y el error idiosincrático dependen del cuantil

Se impone que el cuantil condicional del término idiosincrático satisfaga:

$$P[e_{it}(\tau) \leq 0 | F_t(\tau)] = \tau \text{ y } Q_{e_{it}}[\tau | F_t(\tau)] = 0,$$

lo que implica que el cuantil condicional de X_{it} está dado por:

$$Q_{X_{it}}(\tau | F_t(\tau)) = \lambda'_i(\tau) F_t(\tau)$$

A diferencia del modelo factorial dinámico, que caracteriza la media condicional, el MFQ modela directamente distintos segmentos de la distribución condicional. Esto permite capturar posibles asimetrías y dinámicas asociadas a episodios extremos, lo cual resulta particularmente relevante en contextos inflacionarios caracterizados por riesgos en las colas.

La estimación de los factores cuantílicos se realizó mediante el algoritmo de regresión cuantílica iterativa (Iterative Quantile Regression, IQR) propuesto por Cheng et al. (2021), el cual estima simultáneamente factores y cargas factoriales cuantílicas mediante un procedimiento iterativo de minimización de la función de pérdida cuantílica. El número de factores se determinó utilizando el criterio de información propuesto por dichos autores.

Codificador Denso de Series Temporales (TiDE)

TiDE (Time-series Dense Encoder), propuesto por Das et al. (2024), es una arquitectura de aprendizaje profundo diseñada para el pronóstico de series temporales. El modelo emplea capas densas que codifican valores históricos y posibles covariables, generando posteriormente las predicciones mediante un esquema de decodificación.

A diferencia de arquitecturas basadas en mecanismos de atención, TiDE utiliza una estructura más parsimoniosa y computacionalmente eficiente. En esta investigación, el modelo se implementó utilizando la librería NeuralForecast de Nixtla, conservando la arquitectura propuesta por Das et al. (2024). El entrenamiento se realizó bajo el esquema de ventanas móviles descrito

previamente y la optimización se efectuó mediante descenso por gradiente, minimizando el error cuadrático medio.

Interpolación Jerárquica Neural para Series Temporales (NHITS)

NHITS (Neural Hierarchical Interpolation for Time Series), introducido por Challu et al. (2022), es una arquitectura basada en bloques jerárquicos que operan a distintas escalas temporales. El modelo descompone la serie en componentes de diferentes frecuencias y genera predicciones parciales que se agregan para obtener el pronóstico final.

En esta investigación, NHITS se implementó utilizando la librería NeuralForecast, conservando la arquitectura jerárquica propuesta por Challu et al. (2022). El entrenamiento se realizó bajo el esquema de ventanas móviles descrito anteriormente, empleando el procedimiento estándar de optimización basado en descenso por gradiente.

Especificaciones de los modelos para el pronóstico

En la sección anterior se definieron las estructuras individuales de los modelos econométricos considerados en esta investigación. A continuación, se presentan las especificaciones de pronóstico siguiendo el enfoque propuesto por Cheng et al. (2021). Las especificaciones se construyen de manera anidada, partiendo de un modelo autorregresivo de referencia al cual se incorporan progresivamente factores dinámicos y factores cuantílicos asociados a la parte superior de la distribución.

Sea h el horizonte de pronóstico. Aunque las especificaciones se presentan en su forma general para un horizonte h , en esta investigación únicamente se considera el caso $h=1$, correspondiente a pronósticos a un paso adelante.

Modelo base (Benchmark): AR(p)

$$\pi_{t+h} = \alpha + \sum_{i=1}^p \phi_i \pi_{t-i} + \varepsilon_{t+h}$$

Este modelo supone que la dinámica propia de la inflación de alimentos y bebidas contiene toda la información relevante para su pronóstico, capturando únicamente la persistencia temporal de la serie.

Modelo AR+MFD

$$\pi_{t+h} = \alpha + \sum_{i=1}^p \phi_i \pi_{t-i} + \beta' F_t^{MFD} + \varepsilon_{t+h}$$

Esta especificación evalúa si la dinámica común en la media de los índices internacionales de materias primas alimentarias (capturada por los factores dinámicos) aporta información predictiva adicional más allá de la historia propia de la inflación.

Modelo AR+MFD+MFQ90

$$\pi_{t+h} = \alpha + \sum_{i=1}^p \phi_i \pi_{t-i} + \beta' F_t^{MFD} + \gamma' F_t^{Q90} + \varepsilon_{t+h}$$

Este modelo examina si la dinámica común en la parte alta de la distribución (percentil 90) contiene información incremental respecto a la media común y a la dinámica autorregresiva de la inflación.

Modelo AR + MFD + MFQ (99)

$$\pi_{t+h} = \alpha + \sum_{i=1}^p \phi_i \pi_{t-i} + \beta' F_t^{MFD} + \delta' F_t^{Q99} + \varepsilon_{t+h}$$

En esta especificación se evalúa si la dinámica común en la cola superior extrema (percentil 99) incorpora información predictiva adicional más allá de la media común y la historia propia de la inflación

Modelo completo: AR + MFD + MFQ (90) + MFQ (99)

$$\pi_{t+h} = \alpha + \sum_{i=1}^p \phi_i \pi_{t-i} + \beta' F_t^{MFD} + \gamma' F_t^{Q90} + \delta' F_t^{Q99} + \varepsilon_{t+h}$$

Este modelo permite evaluar si las dinámicas comunes en la parte alta y extrema de la distribución aportan información complementaria entre sí o si existe redundancia informativa entre los distintos segmentos de la cola superior.

Resultados

Esta sección presenta los resultados de la evaluación predictiva fuera de muestra de los modelos considerados para el pronóstico en tiempo real de la inflación mensual de alimentos y bebidas en Estados Unidos. La evaluación se realizó sobre una muestra de 203 observaciones mensuales, correspondiente al período comprendido entre mayo de 2007 y marzo de 2024, utilizando un esquema de ventana móvil con 180 observaciones de entrenamiento. Se comparan especificaciones autorregresivas (AR), modelos aumentados con factores dinámicos (MFD) y cuantílicos (MFQ), así como dos arquitecturas de aprendizaje profundo (TiDE y NHITS).

El desempeño predictivo se analiza a partir del Error Cuadrático Medio (ECM), su versión relativa respecto al modelo AR de referencia (ECMR), y el test de Diebold–Mariano. La Tabla 3.1

presenta los resultados de ECM y ECMR para la muestra completa de evaluación, mientras que la Tabla 3.2 reporta los estadísticos del test de Diebold–Mariano para la comparación formal de precisión predictiva entre modelos.

En el test de Diebold–Mariano, la hipótesis nula establece que el modelo autorregresivo (AR) y el modelo alternativo presentan igual capacidad predictiva, es decir, que no existen diferencias estadísticamente significativas en sus errores de pronóstico. Dado que el diferencial de pérdidas se define como la diferencia entre el error cuadrático del modelo AR y el del modelo alternativo, un estadístico positivo favorece al modelo alternativo, mientras que un estadístico negativo favorece al modelo AR.

Tabla 3.1 *Desempeño predictivo fuera de muestra: ECM y ECM relativo.*

Modelos Econométricos	ECM	ECMR
AR	0.0378	1.000
AR+MFD	0.0363	0.960
AR+MFD+MFQ(90)	0.0355	0.940
AR+MFD+MFQ(99)	0.0349	0.923
AR+MFD+MFQ(90)+MFQ(99)	0.0358	0.947
TiDE	0.0705	1.865
NHITS	0.0476	1.260

Nota: Esta tabla informa el error cuadrático medio (ECM) de siete métodos alternativos de pronóstico mensual para la tasa de inflación mensual de alimentos y bebidas de los Estados Unidos y su error cuadrático medio relativo (ECMR) comparado con el modelo de referencia AR. El pronóstico fuera de muestra se implementa utilizando ventanas móviles con 180 observaciones. El período de evaluación de pronóstico completo es desde mayo de 2007 hasta marzo de 2024

Como se observa en la Tabla 3.1, todas las extensiones factoriales presentan reducciones del ECM respecto al modelo AR de referencia. La incorporación de factores dinámicos reduce el ECM en aproximadamente 4%, mientras que la inclusión de factores cuantílicos genera mejoras adicionales, lo que está en línea con Ciccarelli y Mojon (2010).

El mejor desempeño cuantitativo corresponde al modelo AR+MFD+MFQ(99), con una reducción del ECM cercana al 8% frente al benchmark autorregresivo. Este resultado sugiere que la dinámica común en la cola superior extrema podría contener información predictiva adicional respecto a la dinámica promedio.

Un aspecto relevante es que la inclusión simultánea de MFQ(90) y MFQ(99) no genera mejoras adicionales, lo que indica que el percentil más extremo concentra la mayor parte del contenido informativo capturado por los factores cuantílicos. Ello es consistente con la idea de que los movimientos conjuntos más pronunciados de los precios internacionales pueden estar asociados a episodios de mayor tensión en los mercados de materias primas.

Por el contrario, las arquitecturas de aprendizaje profundo presentan errores de predicción sustancialmente mayores. TiDE y NHITS registran incrementos del ECM de 86% y 26%, respectivamente, frente al modelo AR, lo que indica un deterioro claro en términos de precisión predictiva a horizonte $h = 1$.

Tabla 3.2 *Test de Diebold–Mariano para la comparación de precisión predictiva (muestra completa)*

Modelos Econométricos	Estadíst. DM	Valor p	Significancia
AR + MFD	0.520	0.603	ns
AR+MFD+MFQ(90)	1.574	0.115	ns
AR+MFD+MFQ(99)	1.144	0.252	ns
AR+MFD+MFQ(90)+MFQ(99)	1.100	0.271	ns
TiDE	-4.679	0.000	s
NHITS	-1.962	0.049	s

ns= no significativo

s= significativo

Los resultados del test de Diebold–Mariano, reportados en la Tabla 3.2, confirman esta evidencia. Para los modelos factoriales, no es posible rechazar la hipótesis de igual precisión predictiva frente al modelo autorregresivo de referencia, lo que sugiere que las mejoras observadas en el ECM son cuantitativamente modestas y no estadísticamente robustas en la muestra completa como lo sugiere Cheng et al. (2021). En contraste, tanto TiDE como NHITS resultan estadísticamente inferiores al modelo AR, con estadísticos DM negativos y significativos al 1% y 5%, respectivamente.

En conjunto, la evidencia indica que, en el horizonte de muy corto plazo considerado ($h = 1$), la dinámica autorregresiva y la información contenida en factores estructurados capturan adecuadamente la mayor parte de la señal relevante. Las arquitecturas de aprendizaje profundo no solo no superan al benchmark, sino que presentan un desempeño significativamente inferior en términos estadísticos.

Estos resultados son coherentes con parte de la literatura reciente, Cárdenas et al. (2023) y Paranhos (2025) que documenta que las redes neuronales tienden a mostrar ventajas más claras en horizontes de predicción más largos, donde la acumulación de no linealidades y efectos dinámicos complejos puede volverse más relevante. En el horizonte inmediato analizado en este estudio, la fuerte persistencia inercial de la inflación de alimentos parece dominar la dinámica predictiva, favoreciendo especificaciones econométricas parsimoniosas.

Desempeño predictivo bajo distintos regímenes inflacionarios

Dado que en la muestra agregada no emergen diferencias estadísticamente significativas en la precisión predictiva, resulta relevante examinar si el desempeño relativo de los modelos varía según el entorno inflacionario. Es plausible que la información contenida en la parte superior de la distribución de precios internacionales adquiera mayor capacidad predictiva en contextos de inflación elevada, donde los choques extremos pueden tener una mayor propagación.

Con el fin de explorar esta posible heterogeneidad, se analizan por separado los episodios de inflación moderada y los periodos de inflación alta, definidos en función de la distribución empírica de la serie. Este ejercicio permite evaluar si las ganancias asociadas a los factores cuantílicos se concentran en contextos de mayor presión inflacionaria.

Tabla 3.3 *Desempeño predictivo por régimen inflacionario: ECM y ECM relativo*

Modelo	ECM Baja	ECMR Baja	ECM Alta	ECMR Alta
AR Berchmark	0.0221	1.000	0.0847	1.000
AR+MFD	0.0242	1.095	0.0721	0.851
AR+MFD+MFQ(90)	0.0217	0.981	0.0769	0.907
AR+MFD+MFQ(99)	0.0225	1.018	0.0720	0.850
AR+MFD+MFQ(90)+MFQ(99)	0.0227	1.027	0.0745	0.879

Nota: Esta tabla informa el error cuadrático medio (ECM) de cinco métodos alternativos de pronóstico mensual para la tasa de inflación mensual de alimentos y bebidas de los Estados Unidos y su error cuadrático medio relativo (ECMR) comparado con el modelo de referencia AR. El pronóstico fuera de muestra se implementa utilizando ventanas móviles con 180 observaciones. La evaluación de pronóstico se realiza para inflaciones por debajo del percentil 75 (baja) y por encima del percentil 75 (alta)

La Tabla 3.3 presenta la evaluación de desempeño predictivo diferenciando entre episodios de inflación baja (por debajo del percentil 75) y alta (por encima de dicho umbral). Los resultados evidencian un patrón claramente dependiente del régimen.

En el régimen de inflación baja, el modelo autorregresivo de referencia muestra un desempeño altamente competitivo. Las extensiones factoriales no generan mejoras sustanciales y,

en algunos casos, incluso deterioran marginalmente el ECM. Las reducciones observadas al incorporar el factor cuantílico asociado al percentil 90 son pequeñas ($ECMR = 0.981$), lo que sugiere que, en contextos de estabilidad inflacionaria, la dinámica inercial domina el proceso predictivo y la información contenida en la parte extrema de la distribución tiene un papel limitado.

En contraste, en el régimen de inflación alta se observa una mejora clara y sistemática al incorporar factores dinámicos y cuantílicos. El modelo $AR+MFD+MFQ(99)$ reduce el ECM en aproximadamente 15% respecto al benchmark, mientras que las demás especificaciones factoriales también superan consistentemente al modelo autorregresivo. Estos resultados indican que, durante episodios de mayor presión inflacionaria, la información contenida en los movimientos conjuntos extremos de los precios internacionales adquiere relevancia predictiva.

En conjunto, la evidencia sugiere que la contribución de los factores cuantílicos no es uniforme a lo largo del ciclo inflacionario, sino que se intensifica en entornos de inflación elevada, donde los choques externos y las dinámicas no lineales parecen desempeñar un papel más relevante.

Tabla 3. 4 *Test de Diebold-Mariano: comparación de precisión predictiva en régimen de inflación baja*

Modelos Econométricos	Estadíst. DM	Valor p	Significancia
AR + MFD	-0.6232	0.5332	ns
AR+MFD+MFQ(90)	0.3623	0.7171	ns
AR+MFD+MFQ(99)	-0.2234	0.8232	ns
AR+MFD+MFQ(90)+MFQ(99)	-0.4724	0.6366	ns

ns= no significativo

Tabla 3.5 *Test de Diebold-Mariano: comparación de precisión predictiva en régimen de inflación alta.*

Modelos Econométricos	Estadíst. DM	Valor p	Significancia
AR + MFD	2.1590	0.0308	s
AR+MFD+MFQ(90)	1.6903	0.091	s
AR+MFD+MFQ(99)	1.5369	0.1243	ns
AR+MFD+MFQ(90)+MFQ(99)	1.6543	0.0981	s

ns= no significativo

s= significativo

La evidencia del test de Diebold–Mariano confirma que el desempeño relativo de los modelos depende del régimen inflacionario. Como se muestra en la tabla 3.4, en el régimen de inflación baja, ninguno de los modelos factoriales presenta diferencias estadísticamente significativas frente al benchmark autorregresivo. Los estadísticos DM son pequeños en magnitud y no permiten rechazar la hipótesis de igual precisión predictiva, lo que sugiere que, en contextos de estabilidad inflacionaria, la dinámica inercial domina el proceso y la información contenida en las colas de la distribución no aporta mejoras sistemáticas.

En contraste, como se muestra en la tabla 3.5, en el régimen de inflación alta, los estadísticos DM son positivos para todas las especificaciones factoriales, lo que indica una reducción del error respecto al modelo AR. En particular, el modelo que incorpora factores dinámicos (AR+MFD) muestra mejoras estadísticamente significativas al 5%, mientras que algunas especificaciones que incluyen factores cuantílicos resultan significativas al 10%. Estos resultados sugieren que, durante episodios de mayor presión inflacionaria, la información

contenida en los movimientos conjuntos de los precios internacionales adquiere relevancia predictiva

En conjunto, la evidencia indica que la utilidad de la información proveniente de las colas superiores de la distribución no es uniforme a lo largo del ciclo inflacionario, sino que se concentra en contextos de inflación elevada, donde los choques externos y las dinámicas no lineales parecen desempeñar un papel más relevante.

Conclusiones

La predicción de la inflación de alimentos constituye un ejercicio particularmente desafiante, dada la coexistencia de persistencia inercial, choques externos y posibles no linealidades asociadas a episodios de tensión en los mercados internacionales. En este contexto, la elección del modelo y su grado de complejidad no pueden evaluarse de manera aislada, sino en función del horizonte de predicción y del régimen inflacionario predominante.

Este estudio comparó el desempeño predictivo de modelos autorregresivos, extensiones factoriales dinámicas y cuantílicas, y arquitecturas de aprendizaje profundo para la inflación mensual de alimentos y bebidas en Estados Unidos, utilizando un esquema de evaluación fuera de muestra con ventanas móviles y horizonte de muy corto plazo ($h = 1$).

En la muestra completa, los modelos factoriales generan reducciones cuantitativas del error cuadrático medio respecto al benchmark autorregresivo, aunque dichas mejoras no resultan estadísticamente significativas según el test de Diebold–Mariano. En contraste, las arquitecturas de deep learning (TiDE y NHITS) presentan un desempeño significativamente inferior,

evidenciando que una mayor flexibilidad no lineal no se traduce necesariamente en mejores pronósticos en horizontes inmediatos. Este resultado sugiere que, cuando la dinámica está dominada por fuerte persistencia, especificaciones parsimoniosas pueden capturar adecuadamente la señal relevante.

Al introducir heterogeneidad por régimen inflacionario, los resultados revelan una clara dependencia contextual. En episodios de inflación baja, ninguno de los modelos factoriales logra mejoras estadísticamente significativas frente al autorregresivo, lo que indica que la dinámica inercial domina el proceso predictivo en entornos de estabilidad. Sin embargo, en episodios de inflación alta, los modelos factoriales —particularmente aquellos que incorporan factores dinámicos y cuantílicos— reducen de manera significativa el error de pronóstico. La información contenida en la parte superior de la distribución de precios internacionales adquiere relevancia precisamente cuando las presiones inflacionarias son más intensas.

En conjunto, la evidencia indica que la utilidad predictiva de la información extrema es régimen-dependiente y que la complejidad del modelo debe estar alineada con el entorno macroeconómico y el horizonte de pronóstico. La no linealidad relevante no se manifiesta de forma permanente, sino que emerge bajo condiciones de estrés inflacionario. Estos hallazgos aportan evidencia empírica sobre la interacción entre extremos, regímenes y desempeño predictivo, y sugieren que, en el corto plazo, la parsimonia estructurada puede ser más efectiva que la flexibilidad no restringida de modelos altamente complejos.

Referencias

Abotaleb, M., El-kenawy, E. S. M., & Dhoska, K. (2025). Deep learning-based time series forecasting: A convolutional neural network approach for predicting inflation trends. *EDRAAK*, 2025, 19-28.

Aguirre, A., & Céspedes, L. F. (2004). Uso de análisis factorial dinámico para proyecciones macroeconómicas. *Documentos de Trabajo (Banco Central de Chile)*, (274), 1.

Aysun, U., & Wright, C. (2024). A two-step dynamic factor modelling approach for forecasting inflation in small open economies. *Emerging Markets Review*, 62, 101188.

Artis, M. J., Banerjee, A., & Marcellino, M. (2005). Factor forecasts for the UK. *Journal of forecasting*, 24(4), 279-298. Bräuning, F., & Koopman, S. J. (2014). Forecasting macroeconomic variables using collapsed dynamic factor analysis. *International Journal of Forecasting*, 30(3), 572-584.

Cárdenas-Cárdenas, J. A., Cristiano-Botia, D. J., & Martínez-Cortés, N. (2023). *Colombian inflation forecast using long short-term memory approach* (No. 1241). Banco de la República de Colombia.

Challu, C., Olivares, K. G., Oreshkin, B. N., Ramirez, F. G., Canseco, M. M., & Dubrawski, A. (2023, June). Nhits: Neural hierarchical interpolation for time series forecasting. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 37, No. 6, pp. 6989-6997).

Chen, C. C., & Lin, H. W. (2011). The advantages of dynamic factor models as techniques for forecasting: evidence from taiwanese macroeconomic data. *International Journal of Economics and Finance*, 3(5), 208-215.

Chen, L., Dolado, J. J., & Gonzalo, J. (2021). Quantile factor models. *Econometrica*, 89(2), 875-910.

Ciccarelli, M., & Mojon, B. (2010). Global inflation. *The Review of Economics and Statistics*, 92(3), 524-535.

Das, A., Kong, W., Leach, A., Mathur, S., Sen, R., & Yu, R. (2023). Long-term forecasting with tide: Time-series dense encoder. *arXiv preprint arXiv:2304.08424*.

Della Marra, F. (2017). A forecasting performance comparison of dynamic factor models based on static and dynamic methods. *Communications in Applied and Industrial Mathematics*, 8(1), 43-66.

Maragkos, N., & Refanidis, I. (2025). A comparative evaluation of time-series forecasting models for energy datasets. *Computers*, 14(7), 246.

Nazlioglu, S., Gurel, S. P., Gunes, S., Akin, T., Karul, C., & Kar, M. (2025). Inflation co-movement: new insights from quantile factor model. *Empirical Economics*, 69(1), 431-464.

Nortey, E. N., Agyemang, E. F., Sakyi-Yeboah, E., Ampomah, O. A., & Agyekum, L. (2025). AI meets economics: Can deep learning surpass machine learning and traditional statistical models in inflation time series forecasting?. *Data Science in Finance and Economics*.

Paranhos, L. (2025). Predicting inflation with recurrent neural networks. *International Journal of Forecasting*.

Šestanović, T., & Arnerić, J. (2021). Can recurrent neural networks predict inflation in euro zone as good as professional forecasters?. *Mathematics*, 9(19), 2486.

Theoharidis, A. F., Guillén, D. A., & Lopes, H. (2023). Deep learning models for inflation forecasting. *Applied Stochastic Models in Business and Industry*, 39(3), 447-470.

Stock, J. H., & Watson, M. W. (1999). Forecasting inflation. *Journal of monetary economics*, 44(2), 293-335.

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

Yang, C., & Guo, S. (2021). Inflation prediction method based on deep learning. *Computational Intelligence and Neuroscience*, 2021(1), 1071145.

Anexo 3.1

Clasificación de alimentos por categoría (Adaptado de FAO)

Categoría	Subcategoría
Cereales	Cebada; Maíz; Arroz; Trigo y Sorgo
Carnes	Carne de res; Cordero; Cerdo; Aves y Camarón
Aceites	Aceite de Colza; Aceite de Oliva; Aceite de Palma; Aceite de Soya y Aceite de Girasol
Granos tostados secos	Café suave, Café robusto, cacao, maní
Sugar=azúcar	Azúcar
Legumes = legumbres	Soybean= Soya y Beans=fríjoles
Flours= harinas	Soybean meal= harina de soya y fish meal= harina de pescado

Fuente: Materias primas obtenidas del Fondo Monetario Internacional y adaptadas a las categorías de la FAO

CONCLUSIONES GENERALES, IMPLICACIONES PARA LA POLÍTICA ECONÓMICA Y LIMITACIONES

La presente tesis doctoral por compendio de artículos analiza la inflación de alimentos y bebidas en Estados Unidos desde dos dimensiones complementarias: (i) la identificación de sus principales determinantes mediante un modelo VAR ampliado con factores extraídos de un modelo factorial cuantílico, y (ii) la evaluación del desempeño predictivo de distintos enfoques econométricos y de aprendizaje profundo.

En conjunto, los resultados permiten establecer conclusiones sólidas y coherentes con los objetivos planteados.

En relación con los determinantes, la evidencia muestra de manera robusta que los factores externos —particularmente las presiones en las cadenas de suministro globales y los precios internacionales de las materias primas alimentarias— constituyen el principal motor de la inflación de alimentos y bebidas en Estados Unidos.

Los episodios asociados a la pandemia de COVID-19 y al conflicto entre Rusia y Ucrania evidencian que los choques globales generan efectos significativos y persistentes sobre los precios. Asimismo, se demuestra que las fluctuaciones en la cola superior de la distribución de los precios internacionales, asociadas a escenarios de estrés inflacionario, tienen un efecto estadísticamente significativo, lo que resalta la necesidad de incorporar medidas que capturen dinámicas extremas.

En cuanto a la dimensión climática y productiva, los resultados indican que la variabilidad climática no presenta efectos significativos sobre la inflación de alimentos en el período analizado, lo cual puede explicarse por los avances en investigación, desarrollo e innovación en el sector agrícola.

Por su parte, la productividad total de los factores agrícolas contribuye de manera moderada a mitigar las presiones inflacionarias. No obstante, estos resultados también ponen de manifiesto que la efectividad de estos mecanismos depende de la velocidad de adopción tecnológica, lo que constituye un elemento clave en la resiliencia del sector agrícola.

Desde la perspectiva predictiva, la evidencia muestra que el desempeño de los modelos es dependiente del régimen inflacionario. En contextos de inflación baja, los modelos autorregresivos capturan adecuadamente la dinámica de la serie.

En contraste, en episodios de inflación alta, los modelos factoriales que incorporan factores cuantílicos mejoran significativamente la precisión de los pronósticos. Por su parte, las arquitecturas de aprendizaje profundo, como TiDE y NHITS, no presentan ventajas en horizontes de muy corto plazo, lo que indica que una mayor complejidad no garantiza mejoras en el desempeño predictivo en este contexto.

La tesis contribuye al ODS 2: Hambre Cero, al aportar evidencia sobre los factores que determinan la inflación de alimentos, elemento clave para la accesibilidad y asequibilidad de los alimentos, y al ODS 13: Acción por el Clima, al incorporar la variabilidad climática y el papel de la innovación tecnológica como mecanismos de adaptación en el sector agrícola.

Estos aportes son relevantes para el diseño de políticas orientadas a fortalecer la seguridad alimentaria y la resiliencia frente a choques globales.

Esta investigación realiza cuatro contribuciones principales.

En primer lugar, aporta evidencia empírica robusta sobre la dominancia de los factores externos en la inflación de alimentos y bebidas en Estados Unidos, reforzando la idea de que este fenómeno tiene una naturaleza predominantemente global.

En segundo lugar, introduce una contribución metodológica relevante mediante la implementación de un modelo VAR ampliado con factores cuantílicos, lo que permite capturar dinámicas comunes en los extremos de la distribución de los precios internacionales, superando una limitación importante de los modelos factoriales tradicionales centrados en la media.

En tercer lugar, integra en un mismo marco empírico la dimensión climática y productiva, ampliando el análisis de los determinantes de la inflación de alimentos y aportando evidencia sobre el papel de la innovación tecnológica en la mitigación de choques.

En cuarto lugar, realiza una contribución en el ámbito predictivo, al comparar de manera sistemática modelos econométricos y arquitecturas de aprendizaje profundo (TiDE y NHITS), evidenciando que su desempeño depende del régimen inflacionario.

En cuanto a su alcance, la tesis proporciona un enfoque integral que combina el análisis estructural de los determinantes con la evaluación predictiva, ofreciendo resultados relevantes tanto para la literatura académica como para la formulación de política económica.

Desde la perspectiva de la de política económica, la evidencia obtenida sugiere que las estrategias orientadas a contener la inflación de alimentos deben considerar de manera explícita la influencia de los factores externos sobre la dinámica de los precios.

En particular, las disrupciones en las cadenas globales de suministro y los movimientos extremos en los precios internacionales de las materias primas alimentarias constituyen fuentes relevantes de presión inflacionaria, por lo que su monitoreo sistemático puede fortalecer la

capacidad de anticipación y respuesta de las autoridades económicas frente a episodios de alta inflación.

Asimismo, los resultados resaltan la importancia de fortalecer las políticas de investigación, desarrollo e innovación en el sector agrícola como mecanismos para mejorar la productividad e incrementar la resiliencia del sistema alimentario frente a choques externos y climáticos.

Finalmente, la evidencia derivada del análisis predictivo sugiere que la incorporación de información asociada a factores cuantílicos y variables externas puede contribuir a la identificación temprana de presiones inflacionarias, proporcionando elementos adicionales para apoyar la formulación de políticas económicas.

A pesar de sus aportes, la investigación presenta algunas limitaciones.

En primer lugar, la disponibilidad de información sobre la Productividad Total de los Factores (PTF) únicamente en frecuencia anual requirió la aplicación de técnicas de desagregación temporal. Para ello se utilizó el procedimiento de Chow-Lin (1971), el cual permite distribuir series de baja frecuencia en una frecuencia mayor mediante el uso de una serie auxiliar correlacionada con la variable de interés.

En esta investigación, la serie auxiliar utilizada fue el índice climático mensual ACIUSA, dada su relación conceptual y estadística con la productividad agrícola. Este procedimiento permitió obtener una aproximación mensual consistente con la información disponible.

No obstante, la desagregación temporal podría suavizar parcialmente la volatilidad inherente de la productividad y, en consecuencia, atenuar la magnitud de sus efectos de corto plazo sobre la inflación de alimentos y bebidas. Esta limitación debe tenerse en cuenta al interpretar los resultados asociados a la Productividad Total de los Factores.

En segundo lugar, el análisis se centra en Estados Unidos, lo que limita la generalización de los resultados a economías con diferentes estructuras productivas y niveles de desarrollo.

En tercer lugar, la evaluación predictiva se realiza en horizontes de muy corto plazo, por lo que no se analizan en profundidad horizontes más largos.

Finalmente, las variables climáticas utilizadas pueden no capturar completamente la heterogeneidad regional ni la complejidad del fenómeno climático.

DIFUSIÓN DE RESULTADOS

Papers

Girón-Cruz, L.E. and Sierra-Suárez, L.P. (2026). Los efectos de la variabilidad climática, la productividad total de los factores agrícolas y los determinantes externos sobre la inflación de alimentos y bebidas en los estados unidos. *Discover Food* (2026) 6:167
<https://doi.org/10.1007/s44187-026-00919->

Estancia Doctoral

Universidad del Valle, Escuela de Estadística (Cali, valle, Colombia)

Profesor: Omar Alexander Ríos Saavedra

Periodo: 25 de Agosto al 25 de Noviembre de 2025

Congresos/Seminarios

Seminario de investigación.

Universidad del Valle

Escuela de Estadística (Cali)

Título: "Comparación de tres métodos de pronósticos: Método factorial cuántico, métodos ARIMA y Redes neuronales de corto y largo plazo"

Octubre 7 de 2025

8°. Coloquio Nacional de Estudiantes Doctorales en Economía, organizado por la Red Colombiana de Doctorados en Economía, con el apoyo del Banco de la República.

8 de octubre en la Universidad Libre de Pereira