

Tipo de documento: Tesis de Grado



Departamento de Economía. Licenciatura en Economía
Impacto de eventos climáticos extremos en los mercados de futuros de maíz y soja: un análisis de retornos anormales

Autoría: Asteggiano, Saul Luca; Di Cocco, Isabella; Panichelli, Catalina; Stanislasky, Ilan

Año: 2024

¿Cómo citar este trabajo?

Asteggiano, S., et al. (2024). "*Impacto de eventos climáticos extremos en los mercados de futuros de maíz y soja: un análisis de retornos anormales*". [Tesis de grado. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella.

<https://repositorio.utdt.edu/handle/20.500.13098/13113>

El presente documento se encuentra alojado en el Repositorio Digital de la Universidad Torcuato Di Tella bajo una licencia Creative Commons Atribución/Reconocimiento - No comercial - Compartir igual 4.0 internacional

Dirección: <https://repositorio.utdt.edu>

**IMPACTO DE EVENTOS CLIMÁTICOS EXTREMOS
EN LOS MERCADOS DE FUTUROS DE MAÍZ Y SOJA:
UN ANÁLISIS DE RETORNOS ANORMALES**

ASTEGGIANO SAUL LUCA, DI COCCO ISABELLA, PANICHELLI CATALINA,
STANISLAVSKY ILAN

Tutora: CORNEJO, MAGDALENA

*Universidad Torcuato Di Tella
Departamento de Economía
Licenciatura en Economía*

Agosto 2024

ÍNDICE

1. Introducción	4
2. Revisión de literatura	5
3. Marco teórico	7
4. Metodología	10
4.1. Descripción de eventos climáticos extremos	10
4.2. Cálculo de retornos anormales	10
4.3. Cálculo de retornos anormales acumulados.	13
5. Modelo	13
5.1. Consistencia de los errores estándar	15
5.2. Test de significancia para los AR_{ct}	18
6. Datos	19
7. Resultados	23
7.1. Inundaciones	24
7.2. Sequías	26
7.3. Contrafactuales	29
8. Conclusiones	32
Apendice A: Tablas	35
Estimaciones por efectos fijos	35
Referencias	38

RESUMEN. Este estudio busca evaluar si existen retornos anormales en los precios futuros de maíz y soja en respuesta a eventos climáticos extremos. Se concentra en la variación diaria de los precios futuros de estas commodities durante su temporada de crecimiento. Utilizando datos de precios futuros del Chicago Mercantile Exchange y registros de eventos climáticos extremos de EM-DAT, se analizó el impacto de sequías e inundaciones en las principales zonas agrícolas de Estados Unidos, Argentina y Brasil.

El análisis se basa en el método de Estudio de Eventos para identificar y medir los retornos anormales durante y después de la ocurrencia de los eventos climáticos extremos. Además, se exploró cuánto tiempo persisten estos efectos y cómo varían según el tipo de evento. Se incluyeron variables de control como el S&P 500, las tasas de interés Norteamericana y el Baltic Dry Index para ajustar los resultados.

Los resultados preliminares muestran que los mercados de commodities reaccionan significativamente a los eventos climáticos extremos, aunque la magnitud y la duración del impacto varían según el tipo de evento. Este estudio contribuye a una mejor comprensión de cómo los desastres naturales afectan los mercados agrícolas y ofrece información valiosa para inversores y productores agrícolas que buscan mitigar el riesgo climático.

ABSTRACT. This study aims to evaluate whether there are abnormal returns in the futures prices of corn and soybeans in response to extreme weather events. It focuses on the daily variation of the futures prices of these commodities during their growing season. Using futures price data from the Chicago Mercantile Exchange and records of extreme weather events from EM-DAT, the impact of droughts and floods in the main agricultural areas of the United States, Argentina, and Brazil was analyzed.

The analysis is based on the Event Study method to identify and measure abnormal returns during and after the occurrence of extreme weather events. Additionally, it explored how long these effects persist and how they vary according to the type of event. Control variables such as the S&P 500, U.S. interest rates, and the Baltic Dry Index were included to adjust the results.

Preliminary results show that commodity markets react significantly to extreme weather events, although the magnitude and duration of the impact vary depending on the type of event. This study contributes to a better understanding of how natural disasters affect agricultural markets and offers valuable information for investors and agricultural producers seeking to mitigate climate risk in their investments.

1. INTRODUCCIÓN

Los mercados de commodities agrícolas son especialmente vulnerables a las condiciones climáticas. Eventos extremos como sequías e inundaciones pueden afectar considerablemente la oferta y demanda de productos agrícolas, en particular del maíz y la soja, influyendo en sus precios futuros. La frecuencia y severidad de estos eventos han aumentado con el cambio climático, planteando un desafío continuo para productores, inversores y responsables de políticas que buscan mantener la estabilidad y previsibilidad de estos mercados.

A lo largo de las últimas décadas, ha crecido el interés por entender cómo los desastres naturales impactan los mercados de commodities. Investigaciones previas han demostrado que estos eventos pueden provocar fluctuaciones significativas en los precios de los productos agrícolas, afectando tanto a los productores locales como a los mercados globales. Sin embargo, sigue siendo crucial entender con mayor precisión cómo y cuándo estos eventos influyen en los precios futuros de commodities específicos como el maíz y la soja.

En este contexto, esta tesis tiene como objetivo principal evaluar la existencia de retornos anormales en los precios futuros de maíz y soja ante la presencia de eventos climáticos extremos. Se centró el análisis en la variación diaria de los precios futuros durante el período de crecimiento de los commodities en las principales zonas agrícolas. Para el hemisferio Norte, se consideró el Medio Oeste de Estados Unidos en los meses productivos de Junio, Julio y Agosto. Para el hemisferio Sur, se consideró la Pampa Húmeda en Argentina, y el Centro-Oeste (Mato Grosso, Mato Grosso do Sul y Goiás) y algunas zonas del Sur (Rio Grande do Sul, Paraná y Minas Gerais) para Brasil. Para este último, se tomó como meses productivos a Enero, Febrero y Marzo. Utilizando el método de Estudio de Eventos, se investigó cómo estos eventos afectan los precios y si los mercados reaccionan de manera eficiente o presentan sesgos sistemáticos en términos de sobre-reacción o sub-reacción.

Para llevar a cabo este análisis, se utilizaron datos de precios futuros del Chicago Mercantile Exchange (CME) y registros de eventos climáticos extremos provenientes de la base de datos EM-DAT. Además, se consideraron las tres variables de control mencionadas anteriormente para ajustar y validar nuestros resultados.

Los resultados de esta investigación pueden contribuir a una mejor comprensión de la dinámica de los mercados de commodities agrícolas en respuesta a eventos

climáticos extremos y ayudar a diseñar estrategias más efectivas para enfrentar estos desafíos.

La tesis se estructura de la siguiente manera. La sección 2 detalla la metodología de estudio de eventos, mientras las secciones 3 y 4 presentan los datos utilizados y los resultados obtenidos, respectivamente. Por último, la sección 5 analiza las implicancias de estos hallazgos en el contexto de los mercados de commodities bajo el impacto de los desastres naturales.

2. REVISIÓN DE LITERATURA

Revisando la literatura existente, se observa cómo se documentan las respuestas del mercado financiero a determinadas políticas climáticas, como la IRA (Ley de Reducción de la Inflación de 2022), proporcionando una nueva perspectiva financiera sobre la acción política climática. Por ejemplo, en el estudio de [Bauer et al. \[2023\]](#), se utiliza el método de Estudio de Eventos para analizar los movimientos de los precios de las acciones tras eventos de noticias clave que llevaron a la aprobación de la IRA. Este estudio concluye que los precios de los activos financieros tuvieron reacciones sustanciales y rápidas ante las noticias sobre políticas climáticas. A pesar de que el enfoque de considerar las noticias como eventos resulta interesante, dado que nuestros eventos son desastres climáticos extremos sorpresivos y no anticipados, se ha decidido tomar el propio desastre como evento, en lugar de la noticia que lo precede.

En el estudio de [Guo et al. \[2023\]](#), se investiga cómo las percepciones de riesgo climático afectan a los precios de productos agrícolas a través de la construcción de tres índices de percepción de riesgo climático: un índice de incertidumbre de políticas climáticas, un índice de riesgo físico climático y un índice de preocupación climática. Los autores encontraron que las respuestas de los precios de productos agrícolas a las percepciones de riesgo climático son más pronunciadas a corto plazo que a largo plazo. Este estudio es particularmente relevante para nuestra investigación, ya que demuestra que las percepciones del riesgo climático se han convertido en un factor significativo en los cambios de precios de productos agrícolas, proporcionando un marco útil para analizar cómo los eventos climáticos extremos afectan a los mercados agrícolas.

En esta línea, el presente trabajo considera el estudio de [Demirer and Kutan \[2010\]](#), donde se analizan los mercados spot y futuros para determinar si estos eventos tienen un impacto a corto o largo plazo en el mercado del petróleo crudo. Una

vez más, se utilizó el estudio de eventos como metodología para examinar los rendimientos anormales en los mercados spot y de futuros del petróleo crudo alrededor de las fechas de las conferencias de la OPEP y los anuncios de la SPR entre 1983 y 2008. Los autores llegan a la conclusión de que los anuncios de recorte de producción de la OPEP tienen un impacto significativo, especialmente a corto plazo, a diferencia de los anuncios relacionados con la SPR donde el mercado responde eficientemente a ellos en el largo plazo. Este trabajo nos resulta relevante, ya que al igual que en nuestro caso, mide el impacto en los precios de los contratos futuros.

Sin embargo, el estudio realizado por [Schmidbauer and Rösch \[2012\]](#), es de mayor relevancia para nuestra investigación ya que analiza el impacto de los anuncios de la OPEP en las expectativas y la volatilidad de los cambios diarios en el precio del petróleo. En su análisis, se utilizan tres dummies (para recortar, aumentar y mantener la producción), las cuales indican el día de un anuncio de la OPEP y reflejan un patrón del impacto en la expectativa de rendimiento y volatilidad. Los autores encuentran evidencia de que el efecto posterior al anuncio es negativo en el caso de una decisión de recorte de producción y positivo en caso de una decisión de mantenerla. Además, observan un efecto positivo en la volatilidad en los eventos previos al anuncio, siendo este efecto más pronunciado en el caso de una decisión de recorte. Para la presente investigación también se utilizan dummies, aunque para indicar los días en los que ocurre un evento extremo, usando los retornos diarios para medir su impacto.

En el estudio de [Hong et al. \[2023\]](#), se investiga si los mercados captan eficientemente los riesgos que el cambio climático genera, con un enfoque particular en las sequías, consideradas como los desastres naturales más dañinos para los cultivos y para los rendimientos de las empresas alimentarias. Utilizando el Índice de Severidad de Sequía de Palmer (PDSI) para medir la duración de las sequías prolongadas en un país, los autores demuestran que estas sequías pronostican tanto disminuciones en los ratios de rentabilidad como rendimientos negativos para las empresas alimentarias de dicho país. Los hallazgos de este estudio respaldan las preocupaciones regulatorias sobre la ineficiencia del mercado frente a los riesgos climáticos y sugieren la necesidad de una mayor divulgación. Este estudio es particularmente relevante para nuestra investigación, ya que las sequías son eventos climáticos extremos de mayor duración, lo que permite observar los impactos prolongados en los mercados agrícolas y financieros, aunque también requieren de un análisis específico en comparación al resto de los eventos.

Volviendo a nuestra investigación, se encuentra una significativa complementariedad con el estudio de [Shen et al. \[2023\]](#), que examina el impacto de 2404 eventos climáticos extremos a nivel global en los retornos anormales del gas natural entre 1997 y 2021. Este trabajo utiliza el método de Estudio de Eventos con diferentes ventanas temporales y modelos de retorno, asegurando la fiabilidad de los resultados con pruebas de robustez. Este análisis revela que aproximadamente un 25 % de estos eventos afectan significativamente los retornos anormales, alcanzando los retornos acumulativos su punto máximo en el octavo día posterior al evento. Además, se observa que las tormentas ejercen la influencia más fuerte, las temperaturas extremas generan el impacto más duradero, los incendios forestales desencadenan respuestas tempranas y las inundaciones de alto daño producen las mayores variaciones en tendencias. Geográficamente, la respuesta de los retornos anormales acumulados es más rápida en América, más fuerte en Europa y más moderada en Asia, con un mayor impacto en los principales países productores de gas.

En nuestra investigación, se adopta una metodología similar al emplear dummies para eventos climáticos extremos y utilizar tanto el modelo CAPM como el GARCH para estimar los retornos esperados. Al igual que [Shen et al. \[2023\]](#), se aplican ventanas de evento de diferentes tamaños para evaluar la persistencia y magnitud de los efectos. Nuestra investigación se diferencia en que se centra en los precios futuros de maíz y soja en lugar del gas natural y utilizando datos específicos de las principales regiones agrícolas en Estados Unidos, Argentina y Brasil.

3. MARCO TEÓRICO

Existe amplia literatura que relaciona las condiciones climáticas con el rendimiento de distintos cultivos agrícolas. [Schlenker and Roberts \[2009a\]](#) se basan en datos de EE.UU. entre 1950 y 2005 para probar que el rendimiento del maíz y de la soja tienen una respuesta en forma de U invertida a la lluvia durante el período de crecimiento de la planta entre mayo y agosto. La lluvia es beneficiosa para los cultivos hasta cierto umbral. A partir de ahí, los cultivos se resienten. A su vez, el rendimiento de los cultivos aumenta ligeramente en función de la temperatura hasta cerca de los 30 grados centígrados, y disminuye bruscamente tras la exposición a temperaturas superiores a ese umbral. Usando datos de Estados Unidos entre 1977 y 2007, [Miao et al. \[2016\]](#) encuentran que el rendimiento del maíz y la soja tiene una respuesta en forma de U invertida a la lluvia mensual durante junio, julio y agosto. También observan que los rendimientos del maíz y la soja están relacionados positivamente

con los GDD (*Growing Degree Days*, por sus siglas en inglés) y negativamente con los EDD (*Extreme Degree Days*, por sus siglas en inglés).

En trabajos anteriores, [Tamura et al. \[2008\]](#) utilizó datos entre 1960 y 2006 para Indiana, Illinois y Iowa, para encontrar una relación de U invertida entre los rendimientos de maíz y soja en el Midwest de EE.UU. y la lluvia en cada uno de los meses de junio, julio y agosto. Estos trabajos constatan que los rendimientos del maíz y de la soja aumentan en general hasta una proximidad de 6 pulgadas (1.524 décimas de mm) de lluvia mensual estival y tienden a disminuir para precipitaciones más abundantes. [Schlenker and Roberts \[2009a\]](#) informa que la relación no lineal entre rendimiento y temperatura entre 1950 y 1977 fue la misma que entre 1978 y 2005. Estos trabajos no se pronuncian sobre la estabilidad de la relación entre lluvia y rendimiento a lo largo del tiempo.

En este trabajo exploramos el efecto de los eventos extremos climáticos sobre la dinámica de los precios de los cultivos. Los agricultores en las principales áreas productivas en Estados Unidos, Argentina y Brasil cultivan soja y maíz y venden su producción en un mercado competitivo.

Nos centraremos en las variaciones de los precios de estos cultivos durante la temporada de crecimiento del cultivo (junio, julio y agosto para Estados Unidos y enero, febrero y marzo para Argentina y Brasil) luego de que las semillas se hayan plantado en $t = 0$. Esto nos permite suponer que las variaciones de la producción en el momento de la cosecha T al final del verano se deben a la variabilidad del rendimiento causada por las perturbaciones climáticas y no a las decisiones de siembra del productor. La producción regional se cosecha en T y se añade a las existencias, normalmente pequeñas, para obtener una oferta regional final Q_T medida en toneladas métricas.

La oferta total esperada en T , condicionada a la información disponible para los participantes en la Bolsa Mercantil de Chicago durante el verano de cultivo en el momento $t \leq T$ es

$$E_t[Q_T]. \tag{3.1}$$

La incertidumbre sobre la oferta al momento de la cosecha es función de rendimiento por unidad de tierra, que depende de la tecnología elegida antes del período de crecimiento de la planta y de las condiciones climáticas. En ausencia de riego significativo, lo cual es el caso de la mayor parte del maíz y de la soja en las zonas

productivas consideradas en este trabajo, la entrada de agua procede exclusivamente de las lluvias.

Sean W_t^j variables dicotómicas que identifican la presencia de un evento climático extremo (i.e. inundación o sequía) en el día t del verano y para la región i . Sean Y_T y A_T el rendimiento final y la superficie cosechada, respectivamente. Se postula que,

$$Y_T^i = f\left(\sum_{t=1}^T W_t^i\right) \quad (3.2)$$

Las expectativas del mercado sobre la producción final se van actualizando durante el transcurso del verano¹, bajo el supuesto de que el clima es predecible en forma confiable a partir de los pronósticos climáticos de muy corto plazo. Por lo tanto, los cambios en la producción final esperada que ocurren durante el verano ($t = 1, \dots, T$) dependen exclusivamente de medidas climáticas que son reveladas en forma contemporánea, o con una antelación de pocos días (no más de una semana). Sea E_j la esperanza condicional basada en la información disponible al comienzo del período t . Tomando esperanzas condicionales a (3.2) se llega a

$$E_{t+1}[Y_T^i] - E_t[Y_T^i] = f(\hat{W}_t^i - EW), \quad (3.3)$$

donde \hat{W}_t^i son medidas de eventos extremos climáticos y EW es la esperanza incondicional de los shocks climáticos para el período t . Las condiciones climáticas asociadas a períodos antes de t ya son conocidas por el mercado o tienen la misma esperanza condicional que las observadas entre los períodos t y $t + 1$. Por lo tanto, el cambio en la producción esperada en el período t está impulsado exclusivamente por los shocks climáticos en t .

Sea P_t^T el precio observable en $t \leq T$ asociado a un contrato de futuros de la Bolsa Mercantil de Chicago que vence en T . Usando un modelo estándar de oferta y demanda en T , con elasticidades constantes y multiplicador β , la variación en el precio debido a un shock exógeno en la oferta es

$$\frac{P_{t+1}^T - P_t^T}{P_t^T} \approx \beta \omega_T^i (W_T^i - EW), \quad (3.4)$$

es una medida de la importancia de la producción en la región i en el mercado global de maíz o soja (antes de ser multiplicado por las variaciones locales del rendimiento).

¹Junio a Septiembre en el hemisferio norte; y Diciembre a Febrero hemisferio sur.

Los precios de los cultivos también se ven influenciados por la demanda global y otras variables financieras que se tienen en cuenta en la estimación empírica del modelo mediante el uso de controles adecuados.

La estrategia empírica utilizada para estimar el modelo de la ecuación (3.4) se desarrolla en la sección de metodología.

4. METODOLOGÍA

El método de Estudio de Eventos es una herramienta esencial en la investigación económica para analizar cómo los eventos afectan los precios del mercado. Este enfoque se basa en comparar el rendimiento real de estos contratos durante el período del evento con el rendimiento esperado. La diferencia entre estos dos valores se denomina rendimiento anormal (AR). Si el AR durante el período del evento es significativamente distinto de cero, podemos inferir que el evento climático ha tenido un impacto considerable en los precios de los contratos futuros. Si no, se concluye que el evento no ha afectado significativamente al mercado.

4.1. Descripción de eventos climáticos extremos. Se optó por centrar la selección de dos eventos climáticos extremos, sequías e inundaciones, que hayan ocurrido en Argentina y Brasil, representando el hemisferio sur, así como en los Estados Unidos, representando el hemisferio norte. Al considerar el periodo entre 2004 y 2023, se identificaron un total de 12 inundaciones y 4 sequías entre Argentina y Brasil, con una duración media de 12 y 201 días relativamente. Para Estados Unidos, por otro lado, se identificaron un total de 7 inundaciones y una sequía, con una duración media de 10 y 213 días relativamente. En casos donde el mercado no estaba abierto el día en que ocurrió el evento, la fecha del evento se fijó en el primer día hábil después de su ocurrencia Pandey. [2021]. En cuanto a la selección de ventanas de eventos, se utilizó una ventana de 30 días para ambos eventos.

4.2. Cálculo de retornos anormales. Como se menciona anteriormente, el AR es la diferencia entre el retorno real y el retorno esperado para el período del evento, que se calcula como:

$$AR_{ct} = Ret_t - E(Ret_t), \quad (4.1)$$

donde AR_{ct} es el retorno anormal en el tiempo t . El subíndice c denota los eventos climáticos extremos mencionados anteriormente. Ret_t es el retorno de los contratos futuros en el tiempo t , y $E(Ret_t)$ es el retorno de los contratos futuros, suponiendo que el evento no ocurre.

En este estudio se emplearán tres modelos distintos para estimar el retorno esperado: se aplicará el CAPM, el CMR y el modelo GARCH.

4.2.1. *CAPM*. El Modelo de Mercado toma la forma del CAPM estándar, pero utiliza el índice de commodities como proxy para el retorno del mercado. Para estimar este modelo, se aplicó la siguiente regresión:

$$R_{ct} = \alpha_c + \beta_c R_{mt} + \varepsilon_{ct}, \quad (4.2)$$

donde R_{ct} es el retorno del commodity c en el día t , α_c es la constante, β_c es el coeficiente del índice de los commodities, R_{mt} es el retorno del índice de commodities en el día t y ε_{ct} es el término del error.

Se estimó el retorno normal en una ventana de estimación y predicción de 30 días al rededor del evento. Aquí, R_{mt} representa el retorno del *Bloomberg Commodity Index* en el día t . El *Bloomberg Commodity Index* es un punto de referencia altamente líquido y diversificado para el mercado de commodities, compuesto por 19 commodities físicas, y se utiliza en el modelo como un proxy para el rendimiento del mercado de commodities.

Suponiendo que el error ε_{ct} tiene un valor esperado de cero, se puede afirmar que este error es en realidad el rendimiento anormal en el momento del evento en las proximidades del evento c , denotado como

$$AR1_{ct} = \varepsilon_{ct}. \quad (4.3)$$

De esta forma se define

$$AR1_{ct} = \beta_0 + \sum_i \beta_i Disaster_c + controles \quad (4.4)$$

una primer aproximación de el retorno anormal estimado en una ventana de $t \in [-30, +30]$ días al rededor del evento. Donde el término $Disaster_c$ toma un valor no nulo mientras ocurre el evento c en el momento t .

4.2.2. *CMR*. El modelo de Retornos Condicionales (CMR) es una extensión del CAPM. En el presente caso, se añade *relevancy* como proxy adicional. La regresión se formula de la siguiente manera:

$$R_{ct} = \alpha_c + \beta_{c1} R_{mt} + \beta_{c2} relevancy_t + \varepsilon_{ct}, \quad (4.5)$$

donde R_{ct} es el retorno del commodity c en el día t , α_c es la constante, β_{c1} es el coeficiente del índice de los commodities, β_{c2} es el coeficiente de la variable *relevancy*,

R_{mt} es el retorno del índice de commodities en el día t , $relevancy_t$ es la variable de relevancia en el día t y ε_{ct} es el término del error.

Se estima el retorno normal en una ventana de $t \in [-30, +30]$ días, utilizando tanto el *Bloomberg Commodity Index* como la variable de relevancia como proxies.

Suponiendo que el error ε_{ct} tiene un valor esperado de cero, se puede decir que es de hecho el rendimiento anormal en el tiempo del evento en las proximidades del evento c , denotado como

$$AR2_{ct} = \varepsilon_{ct}. \quad (4.6)$$

Se estima el retorno anormal en una ventana de $t \in [-30, +30]$ días al rededor del evento c . Luego entonces

$$AR2_{ct} = \beta_0 + \sum_i \beta_i Disaster_c + \text{controles}, \quad (4.7)$$

el segundo modelo a estimar en una ventana de $t \in [-30, +30]$. Donde nuevamente término $Disaster_c$ toma un valor no nulo mientras ocurre el evento c .

4.2.3. *GARCH*. El modelo GARCH es comúnmente utilizado para modelar la volatilidad en series temporales. En el contexto de nuestra investigación, nos permite capturar de manera sistemática y cuantitativa el impacto de los eventos climáticos extremos en los precios de los futuros de los commodities. Se utiliza este modelo para calcular los retornos anormales, se puede capturar la volatilidad condicional de los retornos de los commodities.

Se define t como el índice de los días en el tiempo del evento, con $t = 0$ como la fecha del evento, R el retorno diario y c el índice del evento con $c = 1, 2, \dots, N$.

Luego, reescribiendo el modelo como $R_{ct} = \mu + \varepsilon_{ct}$ donde R_{ct} es el retorno del commodity c en el tiempo t , μ es la media del retorno y ε_{ct} es el término del error, el cual sigue una distribución normal con media cero y varianza condicional.

La varianza condicional σ_t^2 se modela como

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2, \quad (4.8)$$

donde α_0 es una constante, α_i son los coeficiente de los términos de error al cuadrado retrasados y β_j son los coeficientes de los términos de varianza condicional retrasados.

Para estimar los parámetros μ , α_i y β_j , de cada commodity, se utilizan los datos históricos de precios. Para esto se requiere aplicar un modelo *GARCH*(q, p) sobre los retornos R_{ct} .

Luego, se definen los retornos anormales como la diferencia entre el retorno observado y el retorno esperado:

$$AR_{3ct} = R_{ct} - E(R_t|\Omega_{t-1}), \quad (4.9)$$

donde AR_{3ct} es el retorno anormal del commodity c en el momento t , R_{ct} es el retorno observado del commodity c en el momento t , y la esperanza se define como el retorno esperado basado en la información disponible hasta el momento $t - 1$.

4.3. Cálculo de retornos anormales acumulados. Se definen los rendimientos anormales promedio diarios como

$$\overline{AR}_t = \frac{\sum_{c=1}^n AR_{ct}}{n} \quad (4.10)$$

donde n es el número de eventos para los cuales existen observaciones para un tipo dado de evento. Se utilizan para calcular los rendimientos anormales acumulados promedio como la suma de los rendimientos anormales promedio desde el día i hasta el día especificado T utilizando la siguiente fórmula

$$CAR_T = \sum_{t=i}^T \overline{AR}_t \quad (4.11)$$

5. MODELO

Para abordar el análisis de los datos transversales y evaluar la dependencia entre los retornos anormales de los futuros de maíz y soja en respuesta a eventos climáticos extremos, se desarrolla una metodología detallada y estructurada. Los datos transversales nos permiten observar distintos contratos de futuros de maíz y soja de distintas zonas (Estados Unidos y Sudamérica) en un mismo punto del tiempo, capturando así una instantánea de las observaciones en diferentes contratos y regiones. Este tipo de análisis es relevante para ver cómo los precios de estos contratos responden a eventos climáticos específicos en distintos momentos y lugares.

La presencia de efectos fijos no observados, como características únicas de cada país o condiciones del mercado que persisten a lo largo del tiempo, puede influir tanto en los retornos anormales como en los regresores, generando sesgos en las estimaciones por MCO. Suponga el modelo inicial definido por

$$AR_{jit} = \beta_0 + \beta X_t + u_{it} \quad (5.1)$$

Donde AR_{it} representa el retorno anormal estimado por el modelo j para el país i en el momento t , y X_t la matriz de variables explicativas compuesta por, una

variable dummy *relevancy* que toma valor 1 en el momento que ocurre el evento, y una matriz Z de controles.

Si se regresara utilizando *OLS* el modelo propuesto podríamos no estar capturando diferencias fijas entre los países y commodities, ya que se estaría asumiendo que todas las unidades son idénticas entre sí. Para corregir estos problemas y mitigar el sesgo en las estimaciones del efecto del shock climático extremo sobre el retorno de los commodities se propone un modelo de regresión Modelo de Efectos Fijos.

Para asegurar la adecuación del modelo de datos de panel, primero se verifica la presencia de efectos fijos utilizando la prueba de LM - time effects [Breusch and Pagan \[1980\]](#). Esta prueba evalúa si hay variación sistemática en los efectos individuales (país y commodity) o temporales, lo cual es crucial para determinar si un modelo de efectos fijos es más apropiado que uno de efectos aleatorios o comunes. La hipótesis nula (H_0) del test de Breusch-Pagan es que no hay efectos individuales ni temporales:

$$H_0 : \sigma_\mu^2 = 0 \text{ y } \sigma_\lambda^2 = 0 \quad (5.2)$$

Donde σ_μ es la varianza de los efectos individuales no observados (μ_i) y σ_λ es la varianza de los efectos temporales no observados (λ_t). Si el resultado de la prueba indica significancia estadística, se rechaza H_0 y se concluye que es adecuado utilizar un modelo de efectos fijos. Esto nos permite capturar las características específicas de cada contrato de futuros que pueden influir en los retornos, como las condiciones del mercado en el momento de emisión del contrato o factores estructurales de las áreas agrícolas específicas.

Luego, considerando el AR_{jit} , se utiliza variables dummy para considerar el efecto individual (país) y commodity. Efectos temporales pueden ser fácilmente considerados si se introduce variables categórica o dummy de tiempo, una para cada año. Incluir efectos fijos de unidad en una regresión lineal es idéntico a eliminar promedios temporales específicos de la unidad y aplicar mínimos cuadrados ordinarios agrupados a los datos transformados. Luego, incluir efectos fijos temporales elimina cambios seculares en el entorno económico que tienen el mismo efecto en todas las unidades [Wooldridge \[2021\]](#). De esta forma el modelo de Efectos Fijos estará definido por el modelo lineal para cada país en cada momento

$$AR_{it} = \alpha_0 + \beta X_{ic} + \gamma Z + u_{it} \quad (5.3)$$

Donde $u_{it} = \mu_{it} + \lambda_t + \epsilon_{it}$. Luego se incorporan variables binarias por país y commodity. Y se busca estimar β el coeficiente de la variable dummy X_{ic} la que indica la

ocurrencia del evento c y país i , y Z la matriz de controles. En términos matriciales,

$$Y = X\beta + D\mu + \gamma Z + u \quad (5.4)$$

Reescribiendo esto,

$$AR = \dot{X}\beta + D\mu + \gamma Z + u \quad \text{donde} \quad \dot{X} \equiv \begin{bmatrix} X & D & Z \end{bmatrix}, \quad \delta \equiv \begin{bmatrix} \beta' & \mu' & \gamma' \end{bmatrix}' \quad (5.5)$$

El estimador de efectos fijos es:

$$\hat{\delta}_{EF} = \begin{pmatrix} \hat{\beta}_{EF} \\ \hat{\mu}_{EF} \\ \hat{\gamma}_{EF} \end{pmatrix} = \left(\dot{X}'\dot{X} \right)^{-1} \dot{X}'AR \quad (5.6)$$

Lo cual a fines interpretativos por el teorema de Frisch–Waugh–Lovell,

$$\hat{\beta} = \left(X^* X^* \right)^{-1} X^* AR^* \quad (5.7)$$

donde $X^* \equiv M_D X$ y $AR^* \equiv M_D Y \cdot M_D = I - D(D'D)^{-1}D'$ es la matriz que ajusta errores de regresión para X y Y en D , lo cual implica que la estimación de efectos fijos *twoways* es equivalente a restar las medias individuales

$$X_{it}^* = X_{it} - \bar{X}_i$$

Notar que podría haberse escrito al estimador como $\hat{\beta} = (X^* X^*)^{-1} X^* AR$ por idempotencia de la matriz M_D .

Finalmente construcción, $\hat{\beta}_{FE}$ es insesgado, independientemente de si X está correlacionado con D .

De esta forma se ha controlado por los efectos fijos de características específicas de cada contrato de futuros que no varían en el tiempo pero pueden influir en la estimación del impacto del evento en los retornos, como las condiciones del mercado en el momento de emisión del contrato o factores estructurales de las áreas agrícolas específicas. Al utilizar este enfoque, se han eliminado estos efectos fijos, permitiendo una estimación más precisa del impacto de los eventos climáticos extremos.

5.1. Consistencia de los errores estándar. Una vez que se ha establecido la adecuación de un modelo de efectos fijos, el siguiente paso es verificar la presencia de heterocedasticidad en los errores del modelo. Detectar y corregir la heterocedasticidad es crucial para asegurar que los errores estándar sean precisos y que las inferencias estadísticas sean válidas. La heterocedasticidad ocurre cuando la varianza de los errores no es constante a lo largo de las observaciones, lo que puede distorsionar las estimaciones de los coeficientes y afectar las pruebas de hipótesis.

La hipótesis nula (H_0) de la prueba de Breusch-Pagan (1979) para homocedasticidad postula que los errores tienen varianzas constantes, es decir $\sigma_i = \sigma_o$. Si se supone que la varianzas del error σ_i^2 de la regresión del modelo está modelada de la siguiente manera

$$\sigma_i^2 = f(\alpha_0 + \alpha_1 z_{1i} + \dots + \alpha_m z_{mi}) \quad (5.8)$$

lo cual implica que σ_i^2 es una función de las variables z , que en este caso son las explicativas del modelo. Específicamente, se considera el caso donde: siguiente manera

$$\sigma_i^2 = \alpha_0 + \alpha_1 z_{1i} + \dots + \alpha_m z_{mi} \quad (5.9)$$

esto indica que σ_i^2 sigue una relación lineal con respecto a las variables z . Si $\alpha_1 = \alpha_2 = \dots = \alpha_m = 0$, entonces $\sigma_i^2 = \sigma_o^2$, que es una constante. Formalmente², la estadística LM Breusch and Pagan [1980] dada por

$$LM = T \sum_{i=1}^{N-1} \sum_{j=i+1}^N \hat{\rho}_{ij}^2 \quad (5.10)$$

donde $\hat{\rho}_{ij}$ es la estimación muestral de la correlación pareada de los residuos

$$\hat{\rho}_{ij} = \frac{\sum_{t=1}^T \hat{u}_{it} \hat{u}_{jt}}{\left(\sum_{t=1}^T \tilde{u}_{it}^2\right)^{1/2} \left(\sum_{t=1}^T \tilde{u}_{jt}^2\right)^{1/2}} \quad (5.11)$$

y \hat{u}_{it} es la estimación de u_{it} en la regresión de efectos fijos.

Por otro lado, se evalúa si existen correlaciones sistemáticas entre los errores idiosincráticos a lo largo del tiempo para cada entidad en el panel a partir del test Breusch-Godfrey/Wooldridge (Godfrey [1978] & Breusch [1978]) para la correlación serial en modelos de panel. Si este test rechaza la hipótesis nula de ausencia de correlación serial, indica que hay evidencia de que los errores no son independientes entre períodos de tiempo consecutivos dentro de cada entidad. Este test, evalúa para, supóngase, $Y_t = X_t \beta + u_t$, si el término de error u_t sigue el esquema autorregresivo de orden p , AR(p), dado por

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_p u_{t-p} + \varepsilon_t, \quad (5.12)$$

donde ε_t es un término de error de ruido blanco que cumple con todas las suposiciones clásicas. Entonces, la hipótesis nula, H_0 , a probar es:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_p = 0, \quad (5.13)$$

lo que implica que no hay correlación serial entre $u_t, u_{t-1}, \dots, u_{t-p}$ de ningún orden.

²Véase "Testing for cross-sectional dependence in panel-data models", Hoyos. [2006] (2006)

A fines del presente trabajo, todas las hipótesis nulas de los estadísticos previos han sido rechazadas a un nivel de significancia del 1 %, argumentando la presencia de efectos fijos individuales y temporales para el uso de efectos fijos a partir de el test de multiplicadores de Lagrange. Luego el test de Breusch-Pagan para evaluar la heterocedasticidad en datos de panel rechaza la hipótesis nula de homocedasticidad de los errores. Además el test de Breusch-Godfrey/Wooldridge para evaluar la presencia de correlación serial en los errores idiosincráticos en modelos panel rechaza la hipótesis nula de ausencia de correlación serial. Estas pruebas justifican la estimación de los errores estándar a partir de las siguientes estimaciones bajo dos escenarios de heterocedasticidad, correlación serial y (*Caso1*) *crosssectional dependence* cuya estimación es tomada de [John C. Driscoll \[1998\]](#) o (*Caso2*) sin *crosssectional dependence* cuya estimación es tomada de [Arellano \[1987\]](#).

Luego para detectar la existencia de dependencia transversal en los datos, se utiliza la prueba de Pesaran's CD [Pesaran \[2004\]](#). Ésta evalúa si las fluctuaciones en un contrato están correlacionadas con las fluctuaciones en otros contratos, lo cual es crucial para determinar la independencia de los retornos en diferentes contratos y países. La hipótesis nula (H_0) de la prueba de Pesaran asume que no hay dependencia transversal. Si el p -value de esta prueba resulta significativo ($p < 0,05$, se rechaza H_0 y se concluye que hay dependencia transversal. La fórmula de la prueba de Pesaran se expresa como:

$$CD = \frac{\sqrt{2T}}{\sqrt{2T(T-1)}} \sum_{i=1}^{T-1} \sum_{j=i+1}^T \hat{\rho}_{ij} \quad (5.14)$$

[Pesaran \[2004\]](#) han demostrado que bajo la hipótesis nula de ausencia de dependencia transversal $CD \xrightarrow{d} N(0, 1)$ a medida que $N \rightarrow \infty$ y T suficientemente grande aunque experimentos de Monte Carlo propuestos por [John C. Driscoll \[1998\]](#) demuestran que las propiedades en muestra finita de este estimador son bastante buenas y superiores a las de otras técnicas comúnmente utilizadas.

En caso de encontrar dependencia transversal significativa al 5 % a partir de Pesaran's CD, se emplea el método de Driscoll-Kraay [John C. Driscoll \[1998\]](#) para ajustar los errores estándar en nuestras regresiones. Este método es robusto ante heterocedasticidad, autocorrelación y dependencia transversal. La metodología de Driscoll-Kraay se basa en corregir los errores estándar de los coeficientes estimados en presencia de estas condiciones adversas. Si se rechaza la hipótesis nula H_0 de ausencia de dependencia transversal en los errores, se ajustan los errores estándar utilizando la metodología de Driscoll-Kraay para corregir cualquier dependencia

transversal que pueda existir en los datos. Para más detalles sobre la estimación de la varianza S^2 véase [John C. Driscoll \[1998\]](#).

Si la prueba de Pesaran no indica una dependencia transversal significativa, se utiliza el método de Arellano [Arellano \[1987\]](#), el cual proporciona una matriz de covarianza consistente con la heterocedasticidad diseñada específicamente para modelos de datos de panel. Ofrece errores estándar robustos que tienen en cuenta la heterocedasticidad y la posible correlación serial. Este estimador viene dado por³

$$\hat{S}_0 \equiv \left(\frac{1}{N} \sum_{i=1}^N \tilde{x}_i \tilde{x}_i' \right)^{-1} \left(\frac{1}{N} \sum_{i=1}^N \tilde{x}_i' \tilde{u}_i \bar{u}_i \tilde{x}_i \right) \left(\frac{1}{N} \sum_{i=1}^N \tilde{x}_i \tilde{x}_i' \right)^{-1}, \quad (5.15)$$

donde

$$\hat{u}_i \equiv \tilde{y}_i - \tilde{x}_i \hat{\beta}_{FE}. \quad (5.16)$$

siendo $\hat{\mu}$ los residuos de la regresión de efectos fijos y $\tilde{y}_i = My_i$, $\tilde{x}_i = Mx_i$ para $M_{T \times T} = I_T - \frac{1}{T} 1_T 1_T'$.

5.2. Test de significancia para los AR_{ct} . En este estudio, se utilizaron dos pruebas de significatividad para evaluar la magnitud e impacto de los eventos climáticos extremos en los retornos anormales (AR) de los commodities.

La primera prueba de significatividad se realiza para un período de tiempo desde la ocurrencia de un evento hasta el momento en que el CAR (retorno anormal acumulado) alcanza su pico. En este periodo, se prueba si el valor medio de los ARs es significativamente diferente de cero para determinar el porcentaje de eventos climáticos que tienen un impacto significativo en los precios de los commodities después de la ocurrencia del evento.

El estadístico t para esta prueba se calcula de la siguiente manera:

$$t_1 = \frac{\beta - 0}{\sqrt{S^2}} \quad (5.17)$$

donde β es el retorno anormal explicado por el evento en el día t , y T es el periodo desde el evento climático y $\sqrt{S^2}$ es una estimación consistente de el error estándar.

La segunda prueba de significatividad se realiza para todos los eventos de un tipo específico. En esta prueba, se demuestra si el valor medio de los CARs de los eventos es significativamente diferente de cero para evaluar la magnitud y significatividad de los CARs causados por un tipo específico de evento en diferentes momentos después del evento.

El estadístico t para esta prueba se calcula de la siguiente manera:

³Véase Robust Standard Error Estimation in Fixed Effects Panel Models”, ?

$$t_2 = \frac{CAR_{eT}}{\sqrt{\text{var}(CAR_{eT})}}$$


donde CAR_{eT} es el retorno anormal acumulado del evento e durante el período T , y $\text{var}(CAR_{eT})$ es la varianza de los $CARs$.

Estas pruebas nos permiten evaluar de manera sistemática la significatividad de los impactos de eventos climáticos extremos en los precios de los commodities, proporcionando una base sólida para nuestras conclusiones.

6. DATOS

En términos de precios, se usaron los precios de contratos futuros de soja y maíz, que fueron descargados del *Chicago Mercantile Exchange* entre los años 2004 y 2023. En la fig. 1 se observa el comportamiento de los precios.

FIGURA 1. Precio Contrato Futuro USA y América del Sur



El período de muestra también se estableció desde 2004 hasta 2023. Se centró el análisis en los meses de crecimiento de los commodities en las principales zonas agrícolas. Para el hemisferio Norte, se consideró el Medio Oeste de Estados Unidos en los meses productivos de Junio, Julio y Agosto. Para el hemisferio Sur, se consideró la Pampa Húmeda en Argentina, y el Centro-Oeste (Mato Grosso, Mato Grosso do Sul y Goiás) y algunas zonas del Sur (Rio Grande do Sul, Paraná y Minas Gerais) para Brasil. Para este último, se tomó como meses productivos a Enero, Febrero y Marzo. La table 1 presenta un breve analisis descriptivo de los datos para los distintos periodos del contrato.

En América del Sur, los retornos de la soja tienen un promedio de 0.017% y un error estándar de 0.02%, con valores extremos que varían entre -22.84% y 9.17%, indicando una mayor variabilidad en comparación con Estados Unidos. Los retornos del maíz en América del Sur son aún más bajos, con un promedio de 0.011% y un error estándar de 0.03%, y un rango de -25.34% a 19.24%, lo que sugiere una considerable volatilidad en los retornos. En Estados Unidos, los retornos de la soja y maíz presentan una menor variabilidad durante el periodo, aunque una mayor media en los retornos. Se observa una alta correlación entre los precios de los futuros de soja y maíz, tanto en Estados Unidos como en América del Sur, debido a tendencias compartidas del mercado.

CUADRO 1. Análisis Descriptivo Series de Contratos Futuros para USA y S.A.

Estados Unidos				
Variable	Media	Desv. Est.	Min	Max
Precio Soja	375.56	1.25	200.00	620.58
Precio Maíz	168.62	0.65	85.60	339.84
Retorno Soja	0.022 %	0.019 %	-11.98 %	6.85 %
Retorno Maíz	0.028 %	0.024 %	-12.59 %	17.61 %
América del Sur				
Variable	Media	Desv. Est.	Min	Max
Precio Soy	368.72	1.20	183.98	575.18
Precio Maíz	166.03	0.57	86.21	331.85
Retorno Soja	0.017 %	0.021 %	-22.84 %	9.17 %
Retorno Maíz	0.011 %	0.026 %	-25.34 %	19.24 %

4879 observaciones. Serie desde 01-01-2004 hasta 31-05-2023.

Respecto a los eventos climáticos extremos, los datos utilizados en este estudio fueron extraídos del EM-DAT, una fuente ampliamente utilizada para caracterizar eventos climáticos extremos en todo el mundo, informando sobre sus ubicaciones, daños y duraciones (Pagnottoni et al., 2022).

De acuerdo al Departamento de Agricultura de los Estados Unidos (USDA)⁴, la producción norteamericana de soja y maíz representa el 29% y 31% de la producción mundial, respectivamente. Su ciclo de cosecha ocurre durante los meses de mayor temperatura del año, según la Oficina Nacional de Administración Oceánica

⁴Foreign Agricultural Service. U.S. Department of Agriculture - USDA. Update 07/2024

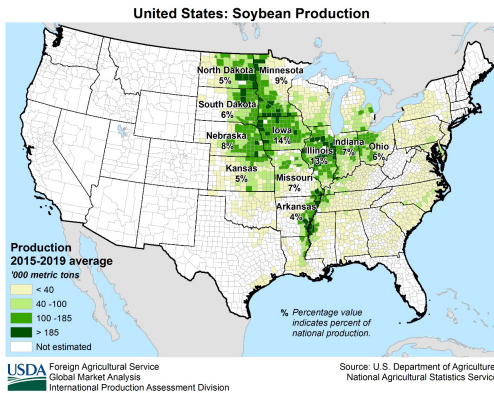


FIGURA 2. Zonas productivas en USA para soja

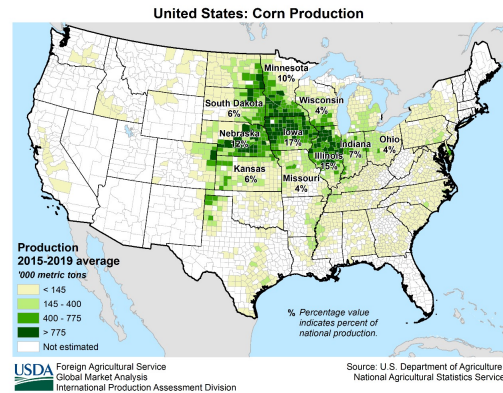


FIGURA 3. Zonas productivas en USA para maíz

y Atmosférica⁵ con precipitaciones de 270-500mm en las zonas productoras de soja y 400-700 mm para el maíz.

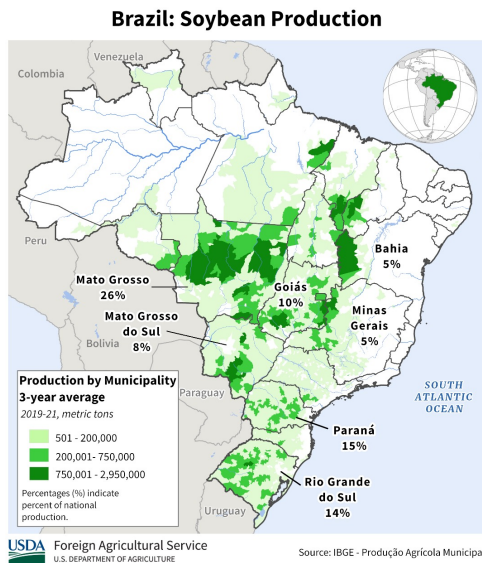


FIGURA 4. Zonas productivas en Brasil para soja

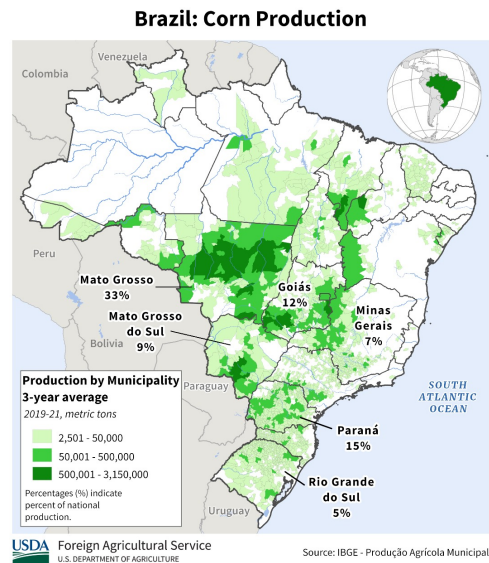


FIGURA 5. Zonas productivas en Brasil para maíz

Según el mismo organismo la producción sudamericana de soja y maíz está dominada por Brasil y Argentina. En conjunto, Brasil contribuye con el 40% de la producción mundial de soja y el 10% de la de maíz, mientras que Argentina aporta el 12% y el 4%, respectivamente.

⁵NOAA/CPC. National Oceanic and Atmospheric Administration.

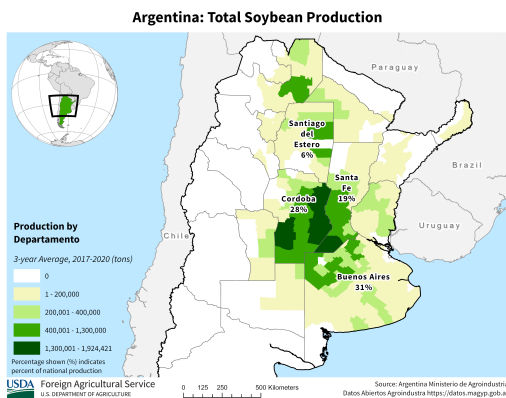


FIGURA 6. Zonas productivas en Argentina para soja




FIGURA 7. Zonas productivas en Argentina para maíz

El ciclo de cosecha en estas regiones está influenciado por las temperaturas promedio durante los meses productivos. En Argentina, las temperaturas varían entre 20°C y 35°C, alcanzando sus máximos en esos meses. En Brasil, las temperaturas son más constantes, entre 22°C y 33°C. Las precipitaciones en las zonas productoras de maíz en Brasil oscilan entre 580 mm y 1200 mm, mientras que para la soja están entre 600 mm y 1200 mm. En Argentina, las acumulaciones de precipitación para ambos cultivos varían entre 330 mm y 680 mm.

El número total de eventos fue de 24, incluyendo 5 sequías y 19 inundaciones. El número, el daño promedio y la duración de cada tipo de evento en cada región se muestran en el siguiente cuadro:

CUADRO 2. Características de los eventos

País	Tipo de evento	No. de eventos	Duración promedio (días)	Daño promedio (miles de USD)	Afectados promedio
América Latina	Sequía	4	201	\$3.531.648	-
	Inundación	12	12	\$130.099	50.575
Estados Unidos	Sequía	1	213	\$25.493.258	-
	Inundación	7	10	\$4.717.624	1.847.411

Como se muestra en la tabla, en términos del número de eventos climáticos extremos, América del Sur y Estados Unidos tuvieron distintos tipos de eventos. En América del Sur, las inundaciones fueron más frecuentes, con un total de 12 eventos,

mientras que las sequías fueron menos frecuentes, con solo 4 eventos. En Estados Unidos, se registraron 7 inundaciones y 1 sequía.

En cuanto a la duración de los eventos, las sequías en América del Sur y Estados Unidos tuvieron una duración promedio considerablemente alta, con 201 y 213 días, respectivamente. Las inundaciones, por otro lado, tuvieron una duración promedio mucho más corta, con 12 días en América del Sur y 10 días en Estados Unidos.

En términos de daño promedio, las sequías en Estados Unidos causaron el mayor daño, con un promedio de \$25.493.258. Las sequías en América del Sur también causaron daños significativos, con un promedio de \$3.531.648. Las inundaciones en Estados Unidos también causaron un daño considerable, con un promedio de \$4.717.624, mientras que en América del Sur el daño promedio fue de \$130.099.

En cuanto al número de personas afectadas, las inundaciones en Estados Unidos tuvieron un impacto significativo, afectando en promedio a 1.847.411 personas. En América del Sur, las inundaciones afectaron a un promedio de 50.575 personas.

Es importante considerar que Estados Unidos tiene una población mayor que la de muchos países de América del Sur, lo que puede contribuir a que el número de personas afectadas y el daño promedio sean más altos. Esto sugiere que, aunque los eventos en Estados Unidos fueron menos frecuentes, tendieron a ser más severos en términos de duración y daño promedio, en parte debido a la mayor densidad de población y el mayor valor económico expuesto a los desastres.

7. RESULTADOS

Se muestran los *CARs* generados a partir de cada tipo de evento climático extremo y se consideran significativamente diferentes de cero según la ecuación (4.11). Las figuras fig. 8 - fig. 13 ilustran el comportamiento del *CAR* estimado para cada uno de los eventos a partir de las distintas metodologías empleadas. La trayectoria creciente generada por los eventos sugieren un comportamiento eficiente al incorporar la información sobre el precio del contrato. Los eventos climáticos extremos generaron *ARs* positivos en el día del evento para el caso de las inundaciones y algunos días después de la ocurrencia del evento para las sequías, donde se observan rendimientos acumulados positivos. Esta diferencia en la respuesta refleja la naturaleza de cada evento, considerando que las inundaciones tienen un impacto inmediato debido a la destrucción y daños causados, mientras que las sequías generan efectos más graduales al afectar la producción y disponibilidad de recursos a lo largo del tiempo.

Las table 3 a table 8 ilustran el resultado de las comparaciones del impacto de los 24 eventos considerados sobre cada uno de los *AR* estimados a partir de las


ecuaciones (4.1)–(4.9). La evaluación conjunta de ambas regiones controlando por efectos fijos a nivel país&commodity&tiempo en las tablas table 3 - table 4 y los resultados se mantienen robustos incluso cuando el conjunto de controles se eliminan de la especificación. Para el caso de las sequías muestra un efecto significativo para los primeros meses del evento. Sin embargo, teniendo en cuenta las heterogeneidades de los eventos, a si como su impacto progresivo sobre los cultivos si bien los resultados demuestran significatividad al 1 % solo para los primeros meses, los mismos no parecen capturar su efecto observado en las fig. 8 - fig. 13 y en las estimaciones de cada subregión de las table 5 -table 8. Esto puede deberse a la naturaleza gradual y acumulativa de los impactos de las sequías, que pueden reflejar un comportamiento menos eficiente en la medida que el impacto se prolonga por varios meses. Si considerando el efecto sobre las 2 regiones juntas de los eventos sobre las inundaciones (table 3), el modelo CMR captura una respuesta de signo positivo significativo al 5 %, aunque indicando un efecto poco conclusivo del impacto del evento relativo al análisis sobre cada región por separado (table 5-table 8) y a los otros dos modelos. Esto puede deberse al hecho de que controla por las características inobservables de cada país y commodity, el mercado parece anticipar el impacto de este tipo de evento considerando que los meses de cosecha están caracterizados por ser los meses de mayor grado de precipitaciones, de esta forma, si bien el efecto del impacto no es concluyente, los *CAR* estimados permiten capturar su relevancia.

7.1. Inundaciones. El análisis por región, ilustrado en la tablas table 6 para América del Sur y en la table 7 para Estados Unidos, para el primer caso, arroja un impacto significativo del evento sobre el retorno para los tres modelos (CAPM, CMR y GARCH) de aproximadamente 2 %. Esto implica que, en promedio, un día antes de una inundación, los retornos anormales (AR) aumentan en un 2.0 %. Por otra parte, para Estados Unidos, el coeficiente de los tres modelos es de aproximadamente 0.7 %. Los tres coeficientes para ambas regiones son significativos a un nivel del 1 %, lo cual sugiere que hay una relación estadísticamente significativa entre las inundaciones y los retornos anormales al día previo del evento y durante la duración del mismo.

Las fig. 8 a fig. 10 muestran una tendencia creciente en los retornos acumulados anormales después del evento de inundación, indicando que éstas tienen un impacto positivo en los retornos de maíz y soja a lo largo del tiempo. La serie de maíz (línea continua) muestra retornos anormales acumulados mayores en comparación con la serie de soja (línea punteada) en la mayoría de los puntos en el tiempo. Esto sugiere que las inundaciones pueden tener un impacto mayor en los retornos de


maíz en comparación con la soja. En los primeros días después del evento ($t = 0$ a $t = 5$), ambas series muestran incrementos rápidos en los retornos acumulados alcanzando un retorno acumulado promedio de alrededor de 1.5%. Posteriormente, el incremento se vuelve más gradual pero continuo hasta alrededor de $t = 15$. Esto sugiere una rápida respuesta del mercado, y la persistencia del incremento en los retornos acumulados podría indicar una reevaluación continua sobre el impacto a largo plazo de las inundaciones en la producción y disponibilidad de maíz y soja.

FIGURA 8. Inundaciones: Retorno Anormal CAPM Acumulado




Nota : Suma Acumulada del Promedio del Retorno Anormal de cada evento en cada momento t de la ventana ($t = 0$ inicio del evento)

FIGURA 9. Inundaciones: Retorno Anormal GARCH Acumulado



Nota : Suma Acumulada del Promedio del Retorno Anormal de cada evento en cada momento t de la ventana ($t = 0$ inicio del evento)

FIGURA 10. Inundaciones: Retorno Anormal CMR Acumulado



Nota : Suma Acumulada del Promedio del Retorno Anormal de cada evento en cada momento t de la ventana ($t = 0$ inicio del evento)

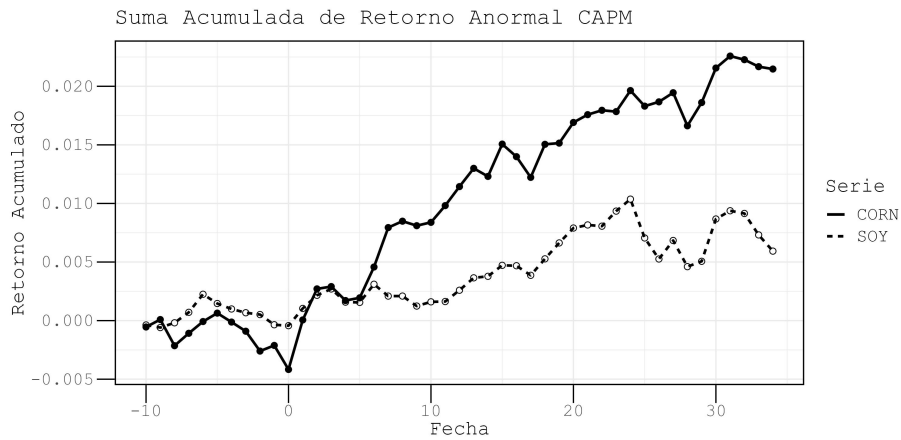
7.2. Sequías. En el análisis de los efectos de las sequías, los resultados obtenidos se presentan en el table 5 para Sudamérica y en el table 8 para Estados Unidos. Para Sudamérica, los coeficientes de la variable de relevancia para los tres modelos (CAPM, CMR y GARCH) son significativos al nivel del 1%, con valores de 0.006 para CAPM y GARCH, y 0.005 para CMR. Esto implica que, en promedio, nueve días antes de una sequía, los retornos anormales aumentan en un 0.6% y 0.5%, respectivamente, dependiendo del modelo utilizado. Para Estados Unidos, los coeficientes de la variable de relevancia para los tres modelos son uniformemente 0.002, sugiriendo que, en promedio, dos días antes de una sequía, los retornos anormales (AR) aumentan en un 0.2%. Este efecto es altamente significativo, a un nivel del 0.01, indicando una relación estadísticamente significativa entre las sequías y los retornos anormales.

Las fig. 11 a fig. 13 muestran una tendencia creciente en los retornos acumulados anormales después del evento de sequía, indicando que estas tienen un impacto positivo en los retornos de maíz y soja a lo largo del tiempo. La serie de maíz (línea continua) muestra retornos anormales acumulados mayores en comparación con la serie de soja (línea punteada) en la mayoría de los puntos en el tiempo. Esto sugiere que las sequías pueden tener un impacto mayor en los retornos de maíz en comparación con la soja. En los primeros días después del evento ($t = 0$ a $t = 10$), ambas series muestran incrementos graduales en los retornos acumulados, alcanzando un retorno acumulado promedio de alrededor de 1.0%. Posteriormente, el incremento se acelera y se vuelve más pronunciado, especialmente para el maíz, que alcanza un retorno acumulado de más del 2.5% hacia el final del período de observación ($t = 40$).

El maíz es más sensible a la sequía que la soja debido a diferencias en sus etapas de desarrollo y mecanismos de adaptación. La soja puede generar nuevas flores y vainas cuando las condiciones mejoran tras un estrés hídrico a corto plazo, mientras que el maíz carece de esta capacidad. En la soja, la pérdida de rendimiento por sequía es menos severa porque puede recuperar parte de su producción una vez que las condiciones mejoran, lo cual no ocurre en el caso del maíz.


Teniendo esto en consideración, es razonable lo que observamos en las fig. 8 a fig. 13: tanto en el caso de las inundaciones como para las sequías, se ve una mayor acumulación de los retornos anormales para el maíz. Esto se debe a que el cultivo que se ve más afectado, dependiendo del tipo de evento, experimenta una contracción de oferta mayor y, por ende, un mayor aumento de precios, generando que la acumulación de retornos anormales sea mayor en comparación con el otro cultivo.

FIGURA 11. Sequías: Retorno Anormal CAPM Acumulado




Nota : Suma Acumulada del Promedio del Retorno Anormal de cada evento en cada momento t de la ventana ($t = 0$ inicio del evento)

FIGURA 12. Sequías: Retorno Anormal GARCH Acumulado



Nota : Suma Acumulada del Promedio del Retorno Anormal de cada evento en cada momento t de la ventana ($t = 0$ inicio del evento)

FIGURA 13. Sequías: Retorno Anormal CMR Acumulado



Nota : Suma Acumulada del Promedio del Retorno Anormal de cada evento en cada momento t de la ventana ($t = 0$ inicio del evento)

7.3. Contrafactuales. Se define el Contrafactual del Retorno Anormal Acumulado (CCAR) se define como el retorno anormal estimado basado en tres modelos propuestos, bajo el supuesto de que el evento de desastre no hubiese ocurrido. Específicamente, se considera la predicción de los retornos anormales si las variables dummy correspondientes a sequías (*sequia*) e inundaciones (*inundacion*) fueran iguales a cero durante todo el período de duración del evento.

En línea con los resultados de [Schlenker and Roberts \[2009b\]](#) quienes estimaron la relación entre el clima y los rendimientos para los tres cultivos con el mayor valor de producción en los Estados Unidos (maíz, soja y algodón), nuestros hallazgos indican un mayor impacto de las sequías sobre el maíz y un impacto similar entre maíz y soja, aunque aún mayor para el maíz durante eventos extremos de inundaciones.

A partir de nuestro análisis de los retornos acumulados, así como del análisis de regresión de efectos fijos, que nos permitió controlar por diversas características de los cultivos y regiones, las figuras fig. 14 - fig. 19 muestran el Retorno Acumulado (CAR - línea negra) y el Contrafactual del CAR (CCAR - línea gris) donde para cada caso la línea sólida indica el cultivo Maíz y la línea punteada la Soja. Se denota $t = 0$ como el día que inicia el evento, teniendo en cuenta el rezago de las estimaciones en las tablas table 5 - table 8, es decir, para sequías 9 días de anticipación en América del Sur y 2 días para Estados Unidos, durante una ventana de -10 día antes del evento y 35 días posteriores; y 1 día de anticipación para ambas regiones en el caso de las inundaciones, durante una ventana de -1 día antes del evento y 20 días posteriores.

Como puede observarse, para el caso del Maíz, donde el efecto de los shocks son mayores, como a su vez, la diferencia entre el Contrafactual y el Retorno Anormal en el caso de las sequías, lo cual otorga mayor robustez al efecto del evento sobre el Maíz relativo a la soja. La soja, aunque también afectada durante periodos de sequías, presenta mecanismos de compensación que le permiten manejar mejor los periodos cortos de estrés hídrico. [Schlenker and Roberts \[2009b\]](#) encuentran que la temperatura crítica de umbral es de 29°C, mientras que para la soja es de 30°C. Esto se debe a que las etapas de desarrollo de la soja se solapan, proporcionando una mayor capacidad de compensación frente a periodos cortos de sequía. Sin embargo, durante periodos prolongados de sequía. A su vez, como es de esperarse, el efecto descompuesto, llámese neto del efecto del evento posee un comportamiento mucho mas eficiente, consistente con el comportamiento estocástico del retorno de los commodities.

Durante los períodos de sequía, el Contrafactual Cumulative Abnormal Returns (CCAR) exhibe un comportamiento inferior a cero, como se anticipa. Este fenómeno puede atribuirse a la capacidad de los modelos para capturar el efecto neto del evento

sobre el Retorno Anormal durante períodos de duración prolongada. Específicamente, dado que el Cumulative Abnormal Returns (CAR) se estima y promedia por separado para cada país utilizando las regresiones presentadas en las tablas table 5 a table 8, se observa que los interceptos varían en cada caso. Esta variación puede implicar la presencia de colinealidad durante períodos prolongados entre la variable dummy del evento y algunos de los controles, como el costo de transporte de commodities. No obstante, la colinealidad es menos probable debido a la naturaleza aleatoria tanto de los retornos como del shock externo. Estos factores pueden resultar en que el comportamiento del CCAR, especialmente para el caso del maíz en los modelos CAPM y GARCH (fig. 14 y fig. 15), no se aproxime al valor cero de manera tan precisa como se podría esperar.

FIGURA 14. Sequías: Contrafactual CAPM





FIGURA 15. Sequías: Contrafactual GARCH




Nota : CAR (línea negra) y CCAR (línea gris). (t=0 inicio del evento con rezago)

Por otro lado, como puede verse en las figuras fig. 17 a fig. 19 efecto sobre las inundaciones es similar para ambos cultivos, y apenas superior para el Maíz, Lo cual es consistente de acuerdo con el Instituto de Agricultura de la Universidad de Tennessee⁶, se observa que la soja presenta una mayor tolerancia a las inundaciones en

⁶Véase Jake McNeal (2023), Corn and Soybean Tolerance to Flooding and Submergence, UT AgResearch


FIGURA 16. Sequías: Contrafactual CMR



Nota : CAR (línea negra) y CCAR (línea gris). (t=0 inicio del evento con rezago)


comparación con el maíz. Específicamente, la soja puede sobrevivir bajo condiciones de inundación durante un período de hasta 48 horas sin experimentar impactos significativos en su rendimiento. En contraste, el maíz muestra una tolerancia limitada a las inundaciones, con una capacidad de supervivencia que oscila entre 2 y 4 días, dependiendo de la temperatura ambiente. Más allá de este período, el maíz enfrenta un riesgo potencial de disminución en su vitalidad y rendimiento, efecto que se refleja en el crecimiento acelerado del Retorno Anormal Acumulado (CAR) a partir del momento $t = 5$. Adicionalmente, el análisis del contrafactual estimado indica una eficiencia mejorada, en consonancia con la literatura existente. El comportamiento del CAR alrededor del valor cero respalda la hipótesis del retorno anormal estocástico cuando el evento de inundación no ocurre para los tres modelos considerados. Así, los modelos implementados capturan de manera más precisa el efecto descompuesto cuando se analiza el evento de inundación en una ventana temporal más reducida.

FIGURA 17. Inundaciones: Contrafactual CAPM




Nota : CAR (línea negra) y CCAR (línea gris). (t=0 inicio del evento con rezago)

FIGURA 18. Inundaciones: Contrafactual GARCH



Nota : CAR (línea negra) y CCAR (línea gris). (t=0 inicio del evento con rezago)

FIGURA 19. Inundaciones: Contrafactual CMR



Nota : CAR (línea negra) y CCAR (línea gris). (t=0 inicio del evento con rezago)

8. CONCLUSIONES

Este estudio se centró en evaluar cómo 24 eventos climáticos extremos, de sequías e inundaciones, han afectado los mercados de futuros de soja y maíz, explorando su prevalencia, variabilidad y los factores que impulsan estos impactos.

El análisis se centra en los tres principales productores y exportadores de estos cultivos en el mundo: Estados Unidos, Brasil y Argentina. El análisis se restringe a los eventos climáticos extremos que ocurrieron en las zonas productivas de estos países durante el período de crecimiento del cultivo, es decir, los meses de verano tanto del hemisferio norte como del hemisferio sur. Las zonas estudiadas representan en conjunto el 81 % y 45 % de la producción mundial de soja y maíz, respectivamente.

Los hallazgos empíricos indican que los eventos climáticos extremos han tenido un impacto generalizado en los mercados de commodities. La intensidad y las tendencias

de estos impactos varían según el tipo, la ubicación y el momento de los eventos, siendo impulsadas por factores fundamentales, especulativos, climáticos y atributos específicos de cada evento.

Los resultados de los modelos utilizados (CAPM, CAR y GARCH) muestran que los retornos anormales están positivamente correlacionados con eventos climáticos extremos, provocando una reducción en la oferta y, por consiguiente, un aumento en los precios. Entre los hallazgos destacados, se observa que las inundaciones y las sequías tienen un impacto mayor en los retornos acumulados anormales del maíz. Todos estos eventos han demostrado ser estadísticamente significativos, aunque el aumento en los precios varía según el tipo de commodity y el evento climático.

Los resultados de este estudio son consistentes con los hallazgos reportados por [Schlenker and Roberts \[2009b\]](#) y [McFadden et al. \[2022\]](#). En particular, [McFadden et al. \[2022\]](#) enfatizan que el maíz, un cultivo intensivo en agua con una notable importancia económica en EE. UU., enfrenta desafíos significativos en la gestión del riesgo asociado a las sequías. A corto plazo, los agricultores disponen de herramientas limitadas para mitigar estos riesgos, como la adopción de tecnologías de riego más eficientes, las cuales solo están disponibles para aquellos con suficiente acceso al recurso hídrico. Sin embargo, a largo plazo, la evidencia sugiere que factores como el aumento de las temperaturas y el riesgo de sequía, más que la exposición a sequías recientes, han impulsado una mayor adopción de variedades de maíz tolerantes a la sequía en 2016. Estos hallazgos corroboran la tendencia hacia la adaptación y mejora de las prácticas agrícolas frente a los desafíos climáticos, y subrayan la importancia de la innovación en la selección de cultivos para enfrentar condiciones extremas.

Este estudio proporciona información crucial para productores, inversores, reguladores de mercado y políticos, ayudándoles a comprender mejor las magnitudes, tendencias y factores que afectan los retornos ajustados al riesgo del maíz y la soja en respuesta a estos eventos climáticos extremos. En la actualidad, de acuerdo a [Yu and Babcock \[2010\]](#), las principales empresas de semillas están enfocando sus esfuerzos en desarrollar cultivos tolerantes a la sequía, concentrándose principalmente en la mejora del maíz. Los avances previos en el desarrollo de maíz biotecnológico han resultado en una mejora inesperada en la resistencia a la sequía de los híbridos de maíz. No obstante, esta tendencia no explica el incremento en la resistencia a la sequía de la soja, a menos que las variedades de soja resistentes a herbicidas sean intrínsecamente menos susceptibles a las condiciones de sequía.

Finalmente, los autores [Yu and Babcock \[2010\]](#) han demostrado que la tolerancia a la sequía de la soja mediante la regresión de los rendimientos a nivel de condado en función de un índice de sequía y el tiempo. Resulta alentador observar que [Yu](#)

[and Babcock \[2010\]](#) encontraron que las pérdidas de rendimiento del maíz debido a sequías de una severidad dada han disminuido con el tiempo. Este avance se atribuye en gran medida a los esfuerzos en el desarrollo de maíz biotecnológico, que ha mejorado la resistencia del maíz a las condiciones de sequía. Aunque de acuerdo a [Schlenker and Roberts \[2009b\]](#) las proyecciones de disminución de rendimientos podrían ser severas y superar las capacidades adaptativas actuales, sugiriendo que las adaptaciones históricas y las mejoras en las variedades no son suficientes para contrarrestar los efectos del calentamiento global.

APENDICE A: TABLAS

Estimaciones por efectos fijos.

CUADRO 3. Estimaciones por efectos fijos: por Día y País-Commodity. Resultados para sequías (rezago de 3 días)

Nro de meses	<i>Variable dependiente:</i>					
	CAPM		CMR		GARCH	
	1	2	1	2	1	2
	(1)	(2)	(3)	(4)	(5)	(6)
Sequía	0.002*** (0.001)	0.001*** (0.0001)	0.002*** (0.001)	0.001 (0.0002)	0.002*** (0.001)	0.001*** (0.0001)
Observaciones	3,366	3,366	3,366	3,366	3,366	3,366
R ²	0.001	0.0002	0.003	0.001	0.001	0.0002
F-stat	1.608	0.512	6.580**	1.485	1.612	0.507

Notas: SE de Discroll-Kraay se reportan entre paréntesis. *p<0.1; **p<0.05; ***p<0.01

CUADRO 4. Estimación de Efectos Fijos: Within Two-Ways por Date y Country-Commodity. Resultados para inundaciones (rezago de 1 día)

	<i>Variable dependiente:</i>		
	AR1 CAPM	AR2 CMR	AR3 GARCH
	(1)	(2)	(3)
Inundación	0.0001 (0.0004)	0.001** (0.0003)	0.0001 (0.0004)
Observations	3,144	3,144	3,144
R ²	0.00001	0.0002	0.00001
Adjusted R ²	-0.335	-0.335	-0.335
F Statistic (df = 1; 2354)	0.018	0.498	0.015

Note: *p<0.1; **p<0.05; ***p<0.01
Driscoll & Kraay SE para CMR y Heterocedasticidad y Correlación Serial para CAPM y GARCH (Arellano SE)

América del Sur.

CUADRO 5. Estimación de Efectos Fijos para South America: Within Two-Ways por Date y Commodity. Resultados para sequías (rezago de 9 días)

	<i>Variable dependiente:</i>		
	AR1 CAPM	AR2 CMR	AR3 GARCH
	(1)	(2)	(3)
Sequía	0.006*** (0.001)	0.005*** (0.002)	0.006*** (0.001)
Observations	1,646	1,646	1,646
R ²	0.001	0.001	0.001
Adjusted R ²	-1.002	-1.001	-1.002
F Statistic (df = 1; 821)	0.644	1.154	0.644

Note:

*p<0.1; **p<0.05; ***p<0.01

Heterocedasticidad y Correlación Serial para (Arellano SE) para all models

CUADRO 6. Estimación de Efectos Fijos para South America: Within Two-Ways por Date y Commodity. Resultados para inundaciones (rezago de 1 día)

	<i>Variable dependiente:</i>		
	AR1 CAPM	AR2 CMR	AR3 GARCH
	(1)	(2)	(3)
Inundación	0.020*** (0.001)	0.019*** (0.000)	0.020*** (0.001)
Observations	958	958	958
R ²	0.004	0.009	0.004
Adjusted R ²	-0.999	-0.988	-0.999
F Statistic (df = 1; 477)	1.849	4.326**	1.815

Note:

*p<0.1; **p<0.05; ***p<0.01

Driscoll & Kraay SE para CMR y Heterocedasticidad y Correlación Serial para CAPM y GARCH (Arellano SE)

Estados Unidos.

CUADRO 7. Estimación de Efectos Fijos para USA: Within Two-Ways por Date y Commodity. Resultados para inundaciones (rezago de 1 día)

	<i>Variable dependiente:</i>		
	AR1 CAPM	AR2 CMR	AR3 GARCH
	(1)	(2)	(3)
Inundación	0.007** (0.003)	0.007** (0.003)	0.007** (0.003)
Observations	356	356	356
R ²	0.016	0.019	0.016
Adjusted R ²	-0.984	-0.979	-0.984
F Statistic (df = 1; 176)	2.929*	3.347*	2.903*

Note: *p<0.1; **p<0.05; ***p<0.01
 Driscoll & Kraay SE para CMR y Heterocedasticidad y Correlación Serial
 para CAPM y GARCH (Arellano SE)

CUADRO 8. Estimación de Efectos Fijos para USA: Within Two-Ways por Date y Commodity. Resultados para sequías (rezago de dos días)

	<i>Variable dependiente:</i>		
	AR1 CAPM	AR2 CMR	AR3 GARCH
	(1)	(2)	(3)
Sequía	0.002*** (0.000)	0.002*** (0.000)	0.002*** (0.000)
Observations	362	362	362
R ²	0.001	0.001	0.001
Adjusted R ²	-1.015	-1.015	-1.015
F Statistic (df = 1; 179)	0.150	0.157	0.146

Note: *p<0.1; **p<0.05; ***p<0.01
 Driscoll & Kraay SE para all models

REFERENCIAS

- M. Arellano. Computing robust standard errors for within-groups estimators. *Oxford Bulletin of Economics Statistics*, pages–, 1987.
- M. Bauer, E. Offner, and G. D. Rudebusch. The effect of us climate policy on financial markets: An event study of the inflation reduction act. 2023.
- T. Breusch and A. Pagan. The lagrange multiplier test and its applications to model specification in econometrics. *Review of Economic Studies*, pages–, 1980.
- T. S. Breusch. Testing for autocorrelation in dynamic linear models. *Australian Economic Papers*, pages–, 1978.
- R. Demirer and A. M. Kutan. The behavior of crude oil spot and futures prices around opec and spr announcements: An event study perspective. *Energy Economics*, 32(6):1467–1476, 2010.
- L. G. Godfrey. Testing against general autoregressive and moving average error models when the regressors include lagged dependent variables. *JSTOR*, pages–, 1978.
- K. Guo, Y. Li, Y. Zhang, Q. Ji, and W. Zhao. How are climate risk shocks connected to agricultural markets? *Journal of Agricultural Economics*, 2023.
- H. Hong, F. W. Li, and J. u. Climate risks and market efficiency. *Review of Financial Studies*, 36(5):2090–2122, 2023.
- R. E. D. Hoyos. Testing for cross-sectional dependence in panel-data models. *The Stata Journal*, pages–, 2006.
- A. C. K. John C. Driscoll. Consistent covariance matrix estimation with spatially dependent panel data. *Review of Economic Studies*, pages–, 1998.
- J. R. McFadden, D. J. Smith, and S. Wallander. Weather, climate, and technology adoption: An application to drought-tolerant corn in the united states. *NATIONAL BUREAU OF ECONOMIC RESEARCH*, pages pp. 1310–1323, 2022.
- R. Miao, M. Khanna, and H. Huang. Responsiveness of crop yield and acreage to prices and climate. *American Journal of Agricultural Economics*, 98(1):191–211, 2016.
- D. K. Pandey. Event study on the reaction of the developed and emerging stock markets to the 2019-ncov outbreak. *IREF*, pages–, 2021.
- M. H. . Pesaran. General diagnostic tests for cross section dependence in panels. *University of Cambridge, Faculty of Economics*, pages–, 2004.
- W. Schlenker and M. Roberts. Nonlinear temperature effects indicate severe damages to u.s. crop yields under climate change. *Proceedings of the National Academy of Sciences*, 106(37):15594–15598, 2009a.

- W. Schlenker and M. J. Roberts. Nonlinear temperature effects indicate severe damages to u.s. crop yields under climate change. *PNAS*, pages–, 2009b.
- H. Schmidbauer and A. Rösch. Opec news announcements: Effects on oil price expectation and volatility. *Energy Economics*, 34(5):1656–1663, 2012.
- Y. Shen, i. Sun, Q. Ji, and D. Zhang. Climate events matter in the global natural gas market. *Energy Economics*, 125:106887, 2023.
- M. Tannura, S. Irwin, and D. Good. Weather, Technology, and Corn and Soybean Yields in the U.S. Corn Belt. *Marketing and Outlook Research Report 2008-01, Department of Agricultural and Consumer Economics, University of Illinois at Urbana-Champaign*, 2008.
- J. Wooldridge. Two-way fixed effects, the two-way Mundlak regression, and difference-in-differences estimators. *Michigan State University*, pages–, 2021.
- T. Yu and B. A. Babcock. Are u.s. corn and soybeans becoming more drought tolerant?. *American Journal of Agricultural Economics*, pages pp. 1310–1323, 2010.