

UNIVERSIDAD TORCUATO DI TELLA

Departamento de Economía

# **El Impacto del Clima sobre el Rendimiento del Maíz: un Análisis desde la Econometría Espacial**

Tesis para la Maestría en Econometría

Autora: Yasmin Buenos

Tutora: Magdalena Cornejo

Buenos Aires, Argentina

Junio 2025

# Índice general

|          |                                                                             |           |
|----------|-----------------------------------------------------------------------------|-----------|
| <b>1</b> | <b>Introducción</b>                                                         | <b>3</b>  |
| 1.1      | Planteamiento del Problema . . . . .                                        | 3         |
| 1.2      | Objetivo de la Investigación . . . . .                                      | 4         |
| 1.3      | Preguntas de Investigación . . . . .                                        | 4         |
| 1.4      | Importancia del Estudio . . . . .                                           | 4         |
| 1.5      | Estructura del Documento . . . . .                                          | 5         |
| <b>2</b> | <b>Revisión de la Literatura</b>                                            | <b>6</b>  |
| 2.1      | Determinantes del Rendimiento del Maíz . . . . .                            | 6         |
| 2.2      | Modelos Econométricos Aplicados a la Agricultura . . . . .                  | 7         |
| 2.3      | Dependencia Espacial en Datos Agrícolas . . . . .                           | 8         |
| 2.4      | Cambio Climático y Agricultura . . . . .                                    | 8         |
| <b>3</b> | <b>Datos</b>                                                                | <b>10</b> |
| 3.1      | Fuentes de Información . . . . .                                            | 10        |
| 3.2      | Agregación Espacial de los Datos Climáticos . . . . .                       | 11        |
| 3.3      | Variables Utilizadas . . . . .                                              | 11        |
| 3.4      | Imputación de Datos Faltantes . . . . .                                     | 12        |
| 3.5      | Análisis Exploratorio de los Datos . . . . .                                | 17        |
| <b>4</b> | <b>Metodología</b>                                                          | <b>19</b> |
| 4.1      | Modelos Econométricos . . . . .                                             | 19        |
| 4.1.1    | <i>Modelo Base: Regresión en Panel sin Componentes Espaciales</i> . . . . . | 19        |
| 4.1.2    | <i>Regresión en Panel Espacial (SAR)</i> . . . . .                          | 20        |
| 4.1.3    | <i>Regresión en Panel Espacial (SARAR)</i> . . . . .                        | 22        |

|                                                                            |           |
|----------------------------------------------------------------------------|-----------|
| <b>4.2 Estrategia de Estimación</b> . . . . .                              | <b>23</b> |
| <b>5 Resultados</b>                                                        | <b>25</b> |
| 5.1 Estimación del Efecto del Clima sobre el Rendimiento del Maíz . . . .  | 25        |
| 5.2 Evaluación Predictiva . . . . .                                        | 28        |
| 5.3 Análisis de Robustez . . . . .                                         | 28        |
| 5.4 Proyecciones a 2100 . . . . .                                          | 31        |
| 5.4.1 Escenario de Cambio Climático SSP2-4.5 . . . . .                     | 31        |
| 5.4.2 Proyecciones del Rendimiento del Maíz a 2100 . . . . .               | 33        |
| <b>6 Conclusiones y Discusión</b>                                          | <b>35</b> |
| 6.1 Principales Hallazgos . . . . .                                        | 35        |
| 6.2 Limitaciones del Estudio y Posibles Líneas de Investigación Futura . . | 36        |

# Capítulo 1

## Introducción

En este capítulo se plantea el problema de investigación que motiva el estudio, se establecen los objetivos generales y específicos, y se formulan las preguntas que guían el análisis. Además, se discute la importancia y relevancia del tema en el contexto actual, destacando su contribución potencial. Finalmente, se describe la estructura del documento.

### 1.1. Planteamiento del Problema

En las últimas décadas, el cambio climático ha provocado alteraciones significativas en las condiciones meteorológicas a escala global, impactando de manera particular sobre el sector agrícola. El maíz, cultivo esencial para la seguridad alimentaria y las cadenas agroindustriales de numerosos países, es especialmente sensible a factores climáticos como la temperatura y las precipitaciones. Las variaciones en estos determinantes pueden incidir directamente en su rendimiento, generando incertidumbre tanto para productores como para los responsables del diseño de políticas agroalimentarias.

En este contexto, resulta crucial comprender cómo las transformaciones climáticas están afectando los niveles de producción de maíz. Si bien existe una amplia literatura que documenta los efectos del clima sobre la agricultura a escala global, persiste un espacio relevante para profundizar en estudios a nivel subnacional y con desagregación temporal, que consideren no solo la evolución conjunta de variables climáticas y rendimientos históricos, sino también la presencia de posibles dependencias espaciales entre regiones geográficamente próximas. Estas interacciones podrían influir en los patrones observados de productividad agrícola y, por lo tanto, deben ser contempladas en el análisis econométrico.

## 1.2. Objetivo de la Investigación

El objetivo central de esta tesis es analizar el impacto del clima sobre el rendimiento del maíz en la región del *Midwest* de Estados Unidos, considerando explícitamente la existencia de dependencias espaciales. En particular, se busca estimar la relación entre variables climáticas (temperatura, precipitaciones, entre otras) y el rendimiento del cultivo, centrándonos en el rol que desempeñan las dependencias espaciales entre regiones vecinas en los rendimientos o en factores no observables. Se espera que la inclusión explícita de estas interacciones espaciales en los modelos econométricos mejore tanto la capacidad explicativa como predictiva del efecto del clima sobre la productividad agrícola.

## 1.3. Preguntas de Investigación

Esta tesis busca responder las siguientes preguntas:

- ¿Existen dependencias espaciales significativas en las regiones geográficamente cercanas del *Midwest*?
- ¿Cómo impactan las dependencias espaciales en la modelación del impacto de las variables climáticas sobre el rendimiento del maíz?
- Los modelos que tienen en cuenta dependencias espaciales, ¿mejoran su capacidad predictiva?

## 1.4. Importancia del Estudio

En 2023, según [Food and Agriculture Organization of the United Nations \[2024\]](#), el maíz registró la mayor producción (1.200 millones de toneladas) y el crecimiento más rápido desde 2010 (46 %), en comparación con los demás cereales principales (arroz, trigo, cebada y sorgo), ya que se utiliza ampliamente en distintos sectores además de la alimentación, como los biocombustibles o la alimentación animal. En 2023, la producción de maíz se recuperó de la caída observada en 2022, asociada a sequías generalizadas en Europa, y superó el nivel de 2021. Comprender de qué manera el clima afecta su rendimiento resulta fundamental para garantizar la seguridad alimentaria y diseñar estrategias de adaptación eficaces frente a escenarios de creciente variabilidad climática.

Sin embargo, los datos agrícolas y climáticos presentan, en general, una fuerte estructura espacial ya que factores como las características del suelo, el clima y cuestiones geográficas suelen presentar patrones de dependencia entre regiones colindantes. En la práctica, los

modelos econométricos tradicionales más difundidos en la literatura —basados en datos de panel— tienden a omitir esta dimensión espacial, lo que puede limitar la validez de las inferencias obtenidas. Frente a la evidencia de autocorrelación espacial en los residuos, una solución habitual ha sido el uso de errores estándar robustos a la dependencia cruzada, como los propuestos por Driscoll y Kraay. Sin embargo, esta estrategia no modela explícitamente la estructura de interacción espacial.

A diferencia de ese enfoque, esta tesis propone incorporar dicha dependencia de manera explícita mediante el uso de modelos de econometría espacial. El objetivo es evaluar en qué medida esta estrategia mejora la capacidad explicativa y predictiva de las variables climáticas sobre el rendimiento del maíz, contribuyendo así a una caracterización más precisa de los efectos del clima sobre la producción agrícola.

## 1.5. Estructura del Documento

Esta tesis se organiza en seis capítulos. Tras la introducción, el Capítulo 2 ofrece una revisión de la literatura vinculada al cambio climático, la productividad agrícola y la incorporación de estructuras espaciales en el análisis econométrico de datos agrícolas. El Capítulo 3 presenta las fuentes de información, las variables consideradas, el método de agregación espacial y el tratamiento de los valores faltantes. A continuación, el Capítulo 4 describe en detalle la estrategia metodológica adoptada, incluyendo los modelos econométricos utilizados. El Capítulo 5 presenta los resultados empíricos obtenidos a partir de los datos observados y extiende el análisis a escenarios futuros mediante proyecciones climáticas del IPCC para estimar sus posibles impactos sobre el rendimiento del maíz. Finalmente, el Capítulo 6 resume los principales hallazgos del estudio, sus limitaciones y sugiere posibles líneas de investigación futura.

# Capítulo 2

## Revisión de la Literatura

Este capítulo presenta una revisión de la literatura relevante que sirve de base conceptual y empírica para el análisis desarrollado. Se abordan los principales determinantes del rendimiento del maíz, las aplicaciones de modelos econométricos en el ámbito agrícola, la importancia de considerar la dependencia espacial en los datos productivos, y los efectos del cambio climático sobre la agricultura. La revisión permite contextualizar el estudio, identificar vacíos en la literatura y fundamentar la elección metodológica.

### 2.1. Determinantes del Rendimiento del Maíz

La temperatura es un factor ambiental crucial que regula el crecimiento y desarrollo del maíz, influyendo no solo en la evapotranspiración y la demanda hídrica, sino también en la velocidad y sincronización de las fases de crecimiento del cultivo. Para cuantificar estos efectos, se utilizan indicadores basados en la acumulación térmica, como los *Growing Degree Days* (GDD), que contabilizan el tiempo térmico efectivo necesario para que una planta complete su desarrollo, considerando umbrales mínimos y máximos propios de cada especie [McMaster and Wilhelm, 1997, Bonhomme, 2000]. Esta medida permite predecir el momento de aparición de distintas fases del ciclo del maíz, y es un criterio fundamental para definir el índice de madurez de cada variedad, especialmente en regiones templadas donde la ventana libre de heladas es limitada.

Sin embargo, exposiciones térmicas por encima de ciertos niveles pueden ser perjudiciales, por lo que también se incluyen métricas complementarias como los *Extreme Degree Days* (EDD), que miden la cantidad de días con temperaturas excesivas que pueden inducir estrés térmico y afectar negativamente al rendimiento del cultivo [Schlenker et al., 2006]. Adicionalmente, el estrés térmico, en combinación con el estrés hídrico, resulta especialmente dañino durante las etapas reproductivas, donde la sensibilidad del cultivo es mayor [Barnabás et al.,

2008].

La precipitación constituye la principal fuente de agua para los cultivos en zonas sin riego artificial, como el *Midwest* de Estados Unidos. En esta región, la mayor parte del maíz se cultiva bajo condiciones de secano, por lo que su desarrollo depende directamente del agua proveniente de la lluvia. El agua disponible en el suelo permite a las plantas realizar la fotosíntesis y el transporte de nutrientes a través del proceso de evapotranspiración. Cuando la humedad del suelo es adecuada, las plantas mantienen abiertos sus estomas, favoreciendo un crecimiento eficiente y la acumulación de biomasa [Mueller et al., 2016]. Sin embargo, un exceso de precipitación puede afectar negativamente el desarrollo del cultivo al provocar anegamientos o limitar la absorción de oxígeno en las raíces. Además, la efectividad de la precipitación depende de factores como la intensidad de la lluvia, el tipo de suelo y la pendiente del terreno, ya que estos influyen en la infiltración y retención del agua.

Por último, variables como las características del suelo, el tipo de semilla, las prácticas de manejo y el uso de insumos (fecha de siembra, rotación de cultivo, uso y tipo de fertilizantes, frecuencia y tipo de riego) también influyen en los rendimientos del maíz. Sin embargo, estas variables no están disponibles cuando se trabaja con datos a un nivel geográfico agregado (por ejemplo, a escala de condado o municipio), lo que refuerza la importancia de incorporar métodos estadísticos robustos para lidiar con la heterogeneidad no observada.

## 2.2. Modelos Econométricos Aplicados a la Agricultura

Debido al problema de sesgo por variables omitidas en un enfoque transversal, existe una larga tradición de utilizar un enfoque de datos de panel en la economía agrícola. Deschênes and Greenstone [2007] es probablemente el primer estudio en evaluar el impacto del cambio climático en el sector agrícola utilizando un enfoque econométrico de panel.

Los modelos de datos de panel han sido ampliamente utilizados en la economía agrícola para analizar los efectos del clima sobre el rendimiento de cultivos. La inclusión de efectos fijos permite controlar por factores inobservables constantes en el tiempo (como la calidad del suelo), mientras que la variación temporal permite capturar los efectos de cambios climáticos año a año.

Modelos como los aplicados por Lobell et al. [2014] y Miao et al. [2016] permiten una identificación más precisa del efecto climático, especialmente al incluir términos no lineales, interacciones y términos autoregresivos. No obstante, estos enfoques suelen asumir independencia entre unidades espaciales, una hipótesis que raramente se sostiene en contextos agrícolas donde los fenómenos naturales y las prácticas de manejo pueden presentar fuerte correlación entre regiones vecinas.



## 2.3. Dependencia Espacial en Datos Agrícolas

La literatura reciente ha comenzado a explorar la dimensión espacial en los análisis agrícolas. La dependencia espacial puede surgir por múltiples razones: similitud climática entre regiones contiguas, difusión de tecnologías agrícolas, mercados de insumos y productos compartidos, o características geográficas comunes. En esta línea, [Yun and Gramig \[2023\]](#) proponen distintos modelos de panel espacial para capturar estas interdependencias, y analizan su desempeño predictivo en el estudio del rendimiento de cultivos frente a condiciones climáticas variables.

Los modelos espaciales permiten capturar estas interdependencias a través de matrices de pesos espaciales que definen el vecindario de cada unidad. Modelos como el SAR (*Spatial Autoregressive Model*) y el SARAR (*Spatial AutoRegressive model with AutoRegressive disturbances*) permiten incorporar efectos de interdependencia entre regiones y corregir la posible autocorrelación espacial, mejorando así la validez estadística de las estimaciones, tal como señalan [Anselin \[2016\]](#), [LeSage and Pace \[2009\]](#), [Auffhammer et al. \[2013\]](#) y [Dell et al. \[2014\]](#).

## 2.4. Cambio Climático y Agricultura

El cambio climático se ha convertido en uno de los principales desafíos para la seguridad alimentaria global. Uno de los principales motivos es que los cambios en los patrones de temperatura, precipitaciones y eventos extremos tienen impactos significativos en la productividad agrícola. Diversos estudios analizaron efectos negativos del aumento de temperaturas sobre los cultivos, especialmente en regiones donde la agricultura depende en gran medida de condiciones climáticas estables [[IPCC, 2014](#)].

Autores como [Lobell et al. \[2011\]](#) y [Schlenker and Roberts \[2009\]](#) muestran que el rendimiento de los cultivos, particularmente el maíz, responde de forma no lineal a las temperaturas: mientras un incremento térmico leve puede ser beneficioso en climas fríos, en regiones cálidas tiende a reducir significativamente los rendimientos. Asimismo, el déficit o exceso de precipitaciones también ha demostrado ser un factor determinante de la productividad agrícola, aunque con efectos más heterogéneos según la región y el sistema productivo.

En un trabajo reciente, [Ortiz-Bobea et al. \[2021\]](#) cuantificaron el impacto global del cambio climático en la productividad agrícola durante las últimas décadas. Los autores encuentran que el calentamiento global ha provocado una pérdida equivalente a siete años de crecimiento en la productividad agrícola mundial, afectando de manera significativa cultivos clave como el maíz. Este impacto negativo se atribuye principalmente al aumento de temperaturas extremas

y a la mayor frecuencia de eventos climáticos adversos. Además, el estudio resalta que las regiones cálidas son las más vulnerables, evidenciando una respuesta no lineal del rendimiento a las variaciones térmicas, lo que coincide con hallazgos previos sobre la sensibilidad del maíz a temperaturas elevadas [[Schlenker and Roberts, 2009](#)].

# Capítulo 3

## Datos

Este capítulo presenta las fuentes de información de las variables relevantes, junto con el proceso de agregación espacial aplicado a los datos climáticos, además de la descripción de las variables incluidas en el estudio. Asimismo, se expone el procedimiento adoptado para la imputación de valores faltantes, distinguiendo entre el rendimiento del cultivo de maíz y las variables climáticas. El capítulo concluye con un análisis exploratorio que compara la cantidad de unidades geográficas disponibles antes y después de la imputación y examina la evolución del rendimiento agrícola a lo largo del tiempo.

### 3.1. Fuentes de Información

Los datos climáticos para Estados Unidos provienen de la NOAA (*National Oceanic and Atmospheric Administration*) [National Oceanic and Atmospheric Administration \[2024\]](#), y fueron recolectados con frecuencia diaria a partir de registros de estaciones meteorológicas. Por su parte, la información sobre el rendimiento del maíz, se obtuvo del [\[United States Department of Agriculture, 2024b\]](#), a través de su plataforma de estadísticas rápidas, con cobertura anual y desagregación a nivel de condado.

El análisis se focaliza en la región del *Midwest*, identificada como el principal centro de producción de maíz en Estados Unidos, con una participación del 86,5 % de la producción nacional en 2023 [\[United States Department of Agriculture, 2024a\]](#). Además, Estados Unidos se consolidó como el mayor productor mundial de maíz, representando el 30,9 % de la producción global en 2024 [\[United States Department of Agriculture, Foreign Agricultural Service, 2024\]](#). Esta posición destaca la importancia estratégica del *Midwest* en el escenario agrícola internacional.

Adicionalmente, el *Midwest* presenta una notable heterogeneidad en cuanto a sus condiciones climáticas y de suelos, lo que permite explorar con mayor granularidad las respuestas

del cultivo ante distintos regímenes climáticos. Estudiar esta región resulta clave para el diseño de estrategias de adaptación y manejo agrícola que contribuyan a fortalecer la resiliencia del sector frente a eventos climáticos extremos y al impacto persistente del cambio climático.

### 3.2. Agregación Espacial de los Datos Climáticos

Para obtener datos climáticos a nivel de condado, se utilizaron registros diarios de estaciones meteorológicas con variables como precipitación, temperatura mínima y máxima. Mediante las coordenadas geográficas de cada estación meteorológica, se realizó la georreferenciación en R utilizando el paquete `sf`, junto con los límites administrativos proporcionados por los archivos de forma (*shapefiles*) del Censo de EE.UU., para asignar cada estación meteorológica su condado correspondiente. Como verificación adicional, se consultó una API pública del gobierno estadounidense [[Federal Communications Commission, n.d.](#)], que permite obtener el código y nombre del estado y condado asociados a las coordenadas de cada estación meteorológica. De este modo, se construyó un panel diario consolidado a nivel de condado.

### 3.3. Variables Utilizadas

Para el análisis empírico se utilizó información anual sobre el rendimiento del maíz (*YIELD*), medido en bushels por acre, correspondiente al período 1970–2023.

Las variables climáticas fueron derivadas de datos diarios durante el ciclo de crecimiento del cultivo (junio, julio y agosto) en el mismo período (1970-2023), las cuales fueron agregadas a nivel anual para cada unidad de observación (condado). En particular, se construyeron las siguientes variables:

- **GDD (*Growing Degree Days*)**: mide la acumulación de calor útil para el crecimiento del cultivo. Se construye a partir de la temperatura media diaria (*TMEAN*), expresada en decenas de grados Celsius, de acuerdo con la siguiente función:

$$GDD_{it} = \begin{cases} 0 & \text{si } TMEAN_{it} \leq 800 \\ TMEAN_{it} - 80 & \text{si } 800 < TMEAN_{it} < 300 \\ 220 & \text{si } TMEAN_{it} \geq 300 \end{cases}$$

donde  $i$  denota el condado y  $t$  el día calendario. Los valores diarios se acumulan durante cada mes del verano (junio, julio y agosto) para obtener la variable mensual por año y unidad geográfica.

- **EDD (*Extreme Degree Days*)**: captura la exposición a temperaturas extremas, consideradas nocivas para el desarrollo del cultivo. También expresada en decenas de grados Celsius, se define mediante la siguiente función:

$$EDD_{it} = \begin{cases} TMEAN_{it} - 300 & \text{si } TMEAN_{it} \geq 300 \\ 0 & \text{si } TMEAN_{it} < 300 \end{cases}$$

Al igual que GDD, los valores diarios de EDD se agregan para cada condado a lo largo del período estival.

- **PRCP (Precipitación)**: corresponde a la suma de la precipitación diaria durante los meses de verano, medida en decenas de milímetros.
- **PRCP<sup>2</sup>**: se incluye el cuadrado de la precipitación acumulada, con el fin de capturar posibles efectos no lineales, tales como rendimientos decrecientes o efectos adversos por exceso o déficit hídrico.
- **PRCP · EDD**: representa la interacción entre precipitación y temperaturas extremas, incorporada para modelar posibles efectos no aditivos. Esta interacción permite examinar cómo el impacto de la precipitación sobre el rendimiento puede variar según el nivel de estrés térmico, capturando relaciones más complejas entre variables climáticas.
- **Tendencia · Condado**: se incluye una tendencia lineal específica por condado. Se modela mediante la interacción entre identificadores de condado y el año, permitiendo capturar patrones sistemáticos de cambio en el tiempo que varían entre condados.
- **Tendencia<sup>2</sup> · Condado**: representa una tendencia cuadrática específica por condado, modelada como la interacción entre el condado y el año al cuadrado. Esta variable permite capturar trayectorias temporales no lineales dentro de cada condado.

### 3.4. Imputación de Datos Faltantes

En esta sección se abordan los procedimientos utilizados para tratar los valores faltantes presentes en el conjunto de datos. Se identifican las variables con datos incompletos y se describe el criterio seguido para imputarlos. Además, se lleva a cabo un análisis comparativo entre la distribución de las variables originales y las imputadas mediante estadísticas descriptivas totales y por estado, incluyendo pruebas de medias y varianzas, con el fin de verificar que el proceso de imputación no introduzca sesgos significativos en los datos.

## Imputación de Variables Climáticas

Se imputaron los valores faltantes de la temperatura media diaria (TMEAN) y de la precipitación acumulada anual (PRCP) para cada condado del *Midwest* de Estados Unidos durante el período de análisis 1970–2023. La imputación se realizó utilizando el promedio simple de los diez condados geográficamente más cercanos, con base en la distancia euclídea entre centroides.

En primer lugar, se excluyeron del análisis aquellos condados que presentaban datos ausentes en la totalidad de los días del ciclo de crecimiento del cultivo (junio, julio y agosto). Luego de esta depuración, se conservaron 710 condados con información climática válida. Sobre este conjunto, se detectó un 5,05 % de valores faltantes en TMEAN. Los estados con mayor proporción de datos a imputar fueron: Missouri (8,66 %), Illinois (6,82 %), Indiana (6,29 %), Minnesota (5,67 %) y North Dakota (5,44 %).

En el caso de PRCP, el porcentaje de valores faltantes fue menor (1,30 %). Los estados con mayores niveles de imputación fueron: Missouri (3,52 %), Illinois (1,96 %), Minnesota (1,52 %), North Dakota (1,46 %) e Indiana (1,34 %).

Una vez imputados los registros diarios de TMEAN, se procedió al cálculo de los índices agroclimáticos anuales *Growing Degree Days* (GDD) y *Extreme Degree Days* (EDD) mediante su acumulación a lo largo del período estival. En el caso de PRCP, la imputación se aplicó directamente sobre las sumas anuales a nivel de condado.

Con el fin de verificar que el proceso de imputación no modificó sustancialmente la distribución de los datos, se compararon estadísticos descriptivos globales y por estado antes y después de la imputación. Los resultados se presentan en las Tablas [3.1](#), [3.2](#) y [3.3](#).

Tabla 3.1: Estadísticos Descriptivos de las Variables Climáticas

| Variable | Estadístico | Original  | Imputado  | Diff     | % Diff     |
|----------|-------------|-----------|-----------|----------|------------|
| PRCP     | Max         | 9.633,00  | 9.633,00  | 0,00     | 0,00 %     |
|          | Mean        | 2.837,12  | 2.837,94  | 0,82     | 0,03 %     |
|          | Median      | 2.713,50  | 2.715,00  | 1,50     | 0,06 %     |
|          | Min         | 0,00      | 0,00      | 0,00     | NA         |
|          | SD          | 1.094,82  | 1.092,91  | -1,90    | -0,17 %    |
|          | N           | 37.840    | 38.340    | 500      | 1,32 %     |
| TMEAN    | Max         | 325,00    | 299,22    | -25,78   | -7,93 %    |
|          | Mean        | 222,05    | 222,16    | 0,10     | 0,05 %     |
|          | Median      | 222,49    | 222,61    | 0,12     | 0,05 %     |
|          | Min         | 111,10    | 130,93    | 19,83    | 17,85 %    |
|          | SD          | 22,90     | 22,71     | -0,19    | -0,83 %    |
|          | N           | 37.438    | 38.340    | 902      | 2,41 %     |
| GDD      | Max         | 19.117,00 | 19.117,00 | 0,00     | 0,00 %     |
|          | Mean        | 12.690,66 | 13.060,89 | 370,23   | 2,92 %     |
|          | Median      | 12.816,50 | 13.117,67 | 301,17   | 2,35 %     |
|          | Min         | 73,00     | 4.769,92  | 4.696,92 | 6.434,14 % |
|          | SD          | 2.302,43  | 2.059,80  | -242,63  | -10,54 %   |
|          | N           | 37.438    | 38.340    | 902      | 2,41 %     |
| EDD      | Max         | 1.453,00  | 1.453,00  | 0,00     | 0,00 %     |
|          | Mean        | 18,42     | 17,87     | -0,55    | -2,99 %    |
|          | Median      | 0,00      | 0,00      | 0,00     | NA         |
|          | Min         | 0,00      | 0,00      | 0,00     | NA         |
|          | SD          | 63,64     | 63,14     | -0,50    | -0,79 %    |
|          | N           | 37.438    | 38.340    | 902      | 2,41 %     |

Posteriormente, se realizaron pruebas estadísticas para comparar las medias y varianzas de las variables originales frente a las versiones imputadas. Con un nivel de confianza del 95 %, los resultados indican que no se observan diferencias estadísticamente significativas en los estadísticos de PRCP, EDD y TMEAN, lo que sugiere que las imputaciones preservan adecuadamente la estructura original de los datos en estos casos. Sin embargo, para GDD se detectan diferencias significativas tanto en la media como en la varianza.

Esta discrepancia se debe principalmente al mecanismo de construcción de GDD, que depende directamente de los valores diarios de TMEAN. En la base original, algunos años presentan una cobertura parcial de datos diarios de temperatura, lo que impide calcular GDD en todos los días del ciclo de crecimiento, resultando en valores anuales subestimados. La imputación de TMEAN permite completar dichos vacíos y extender el cálculo de GDD a un mayor número de días. Como consecuencia, los valores acumulados de GDD para esos años aumentan de forma considerable.

En síntesis, la imputación de TMEAN mejora la cobertura temporal de los registros diarios, lo que, si bien preserva la estructura general del resto de las variables, introduce un incremento sistemático en los totales anuales de GDD en los casos con mayor proporción de datos faltantes.

Tabla 3.2: Pruebas de Comparación de Medias de TMEAN por Estado

| Estado | Original | Imputada | Diferencia | p-valor |
|--------|----------|----------|------------|---------|
| IA     | 222,67   | 222,79   | 0,13       | 0,6378  |
| IL     | 233,18   | 233,32   | 0,14       | 0,7148  |
| IN     | 226,47   | 226,47   | -0,01      | 0,9844  |
| KS     | 250,89   | 250,82   | -0,06      | 0,8075  |
| MI     | 195,94   | 196,18   | 0,23       | 0,6019  |
| MN     | 202,01   | 202,08   | 0,07       | 0,8603  |
| MO     | 244,48   | 244,42   | -0,07      | 0,8115  |
| ND     | 196,81   | 197,19   | 0,39       | 0,4051  |
| NE     | 228,67   | 228,67   | 0,01       | 0,9879  |
| OH     | 219,61   | 219,73   | 0,12       | 0,7096  |
| SD     | 215,69   | 215,77   | 0,08       | 0,8510  |
| WI     | 201,65   | 201,61   | -0,04      | 0,9058  |



Tabla 3.3: Pruebas de Comparación de Medias de PRCP por Estado

| Estado | Original | Imputada | Diferencia | p-valor |
|--------|----------|----------|------------|---------|
| IA     | 3.264,93 | 3.266,33 | 1,40       | 0,9595  |
| IL     | 3.051,19 | 3.050,91 | -0,28      | 0,9924  |
| IN     | 3.143,66 | 3.147,05 | 3,40       | 0,9049  |
| KS     | 2.798,07 | 2.797,29 | -0,79      | 0,9740  |
| MI     | 2.532,18 | 2.532,05 | -0,13      | 0,9947  |
| MN     | 2.935,99 | 2.934,22 | -1,78      | 0,9421  |
| MO     | 3.059,34 | 3.056,85 | -2,49      | 0,9271  |
| ND     | 2.049,22 | 2.051,82 | 2,60       | 0,9160  |
| NE     | 2.459,06 | 2.459,66 | 0,59       | 0,9807  |
| OH     | 3.034,90 | 3.035,48 | 0,58       | 0,9816  |
| SD     | 2.164,70 | 2.164,61 | -0,09      | 0,9969  |
| WI     | 3.110,87 | 3.110,60 | -0,27      | 0,9912  |

Los resultados muestran que las diferencias entre las medias originales y las imputadas son mínimas y estadísticamente no significativas en todos los casos. Esto sugiere que el procedimiento de imputación aplicado a TMEAN y PRCP preservó adecuadamente las propiedades estadísticas de estas variables en cada estado, lo que refuerza la validez y la confiabilidad del análisis empírico posterior.

### Imputación del Rendimiento del Maíz

Para imputar los valores faltantes del rendimiento del maíz, se aplicó un procedimiento de interpolación lineal utilizando la función `na.approx()` del paquete `zoo` en R.<sup>1</sup> La imputación se realizó de manera individual para cada condado, respetando el orden cronológico de las observaciones anuales. Este enfoque permite estimar valores ausentes a partir de los datos observados inmediatamente anteriores y posteriores, sin introducir supuestos adicionales sobre la dinámica temporal del proceso.

Se excluyeron del análisis aquellos condados que presentaban valores ausentes en la totalidad de los días del ciclo de crecimiento (junio, julio y agosto), así como aquellos sin

<sup>1</sup>La interpolación lineal, si bien es un procedimiento no paramétrico y parsimonioso, podría atenuar variaciones reales si existieran shocks idiosincráticos de alto impacto en años sin datos. No obstante, la baja proporción de valores imputados y la alta consistencia con métodos alternativos avalan su uso en este contexto.

información climática disponible. Luego de esta depuración, se conservaron 701 condados con datos válidos de rendimiento.

El procedimiento de imputación completó el 8,55 % de las observaciones faltantes (un total de 3.238 valores), generando así un panel balanceado apto para los análisis posteriores.

Complementariamente, se exploraron métodos alternativos de imputación, tales como la interpolación *spline* y la imputación mediante cadenas de Markov por Monte Carlo (función *mice*, sin predictores adicionales). Los resultados obtenidos fueron altamente consistentes entre sí, con correlaciones cercanas a 1 entre las series imputadas, lo que evidencia la robustez del procedimiento adoptado.

La Tabla 3.4 presenta los estadísticos descriptivos del rendimiento del maíz para la serie original y la versión imputada.

Tabla 3.4: Estadísticos Descriptivos de YIELD

| Estadístico | Original | Imputado | Diff  | % Diff  |
|-------------|----------|----------|-------|---------|
| Max         | 246,70   | 246,70   | 0,00  | 0,00 %  |
| Mean        | 117,16   | 118,20   | 1,04  | 0,89 %  |
| Median      | 115,80   | 117,00   | 1,20  | 1,04 %  |
| Min         | 4,50     | 4,50     | 0,00  | 0,00 %  |
| SD          | 42,11    | 41,91    | -0,19 | -0,45 % |
| N           | 34.616   | 37.854   | 3.238 | 9,35 %  |


### 3.5. Análisis Exploratorio de los Datos

De los 701 condados para los cuales armamos el panel balanceado, el análisis se restringe a los 696 condados para los cuales se identificaron vecinos en la matriz de pesos espaciales. Así, el panel balanceado utilizado comprende 696 condados a lo largo de 54 años, lo que equivale a un total de 37.584 observaciones. En cuanto a los paneles original desbalanceado y balanceado, estos incluyen inicialmente 1.053 y 174 condados, respectivamente. Sin embargo, al aplicar la matriz de pesos espaciales, la muestra se reduce a 1.051 condados en el panel desbalanceado y a 139 en el panel balanceado.


En la Figura 3.1 se muestra la distribución geográfica de los condados incluidos en el panel original desbalanceado (1.051), en el panel original balanceado (139) y en el panel imputado (696), respectivamente.

Luego, la figura 3.2 muestra la evolución temporal del rendimiento del maíz (en escala

Figura 3.1: Distribución Geográfica de los Condados



logarítmica) y su distribución entre condados para cada año del período de análisis. Cada boxplot representa la dispersión de  $\log(\text{YIELD})$  entre los distintos condados en un año determinado, permitiendo observar tanto tendencias generales como cambios en la variabilidad espacial a lo largo del tiempo.

Figura 3.2: Evolución Temporal del  $\log(\text{YIELD})$  y su Heterogeneidad entre Condados

# Capítulo 4

## Metodología

Este capítulo presenta los modelos empíricos utilizados para analizar la relación entre el rendimiento del maíz y las variables climáticas, así como la estrategia de estimación adoptada. Se detallan las especificaciones econométricas empleadas, que incluyen modelos de efectos fijos y modelos espaciales, con el objetivo de capturar adecuadamente la dependencia estructural presente en los datos.

### 4.1. Modelos Econométricos

En esta sección se describen los modelos econométricos aplicados para evaluar la influencia de las condiciones climáticas sobre el rendimiento del maíz, incorporando la estructura de panel y la dimensión espacial de los datos. En primer lugar, se estima un modelo con efectos fijos (FE) que permite controlar por heterogeneidad no observada tanto a nivel de condado como de año. Posteriormente, se introducen modelos espaciales que capturan mecanismos de interdependencia geográfica entre unidades adyacentes, como el modelo SAR y el modelo SARAR. Estos enfoques permiten abordar la posible autocorrelación espacial, mejorar la eficiencia de las estimaciones y obtener inferencias más robustas.

#### 4.1.1. Modelo Base: Regresión en Panel sin Componentes Espaciales

Como punto de partida, se estima un modelo de regresión con efectos fijos. Este tipo de especificación permite controlar por factores inobservables constantes en el tiempo para cada unidad geográfica (efectos fijos por condado), así como por shocks comunes que afectan simultáneamente a todos los condados en un mismo período (efectos fijos temporales).

La forma funcional del modelo es la siguiente:

$$\begin{aligned}
\log(YIELD_{it}) = & \alpha_i + \gamma_t + \sum_{m=6}^8 \beta_{1,m} PRCP_{m,it} + \sum_{m=6}^8 \beta_{2,m} PRCP_{m,it}^2 \\
& + \sum_{m=6}^8 \beta_{3,m} GDD_{m,it} + \sum_{m=6}^8 \beta_{4,m} EDD_{m,it} \\
& + \sum_{m=6}^8 \beta_{5,m} (PRCP_{m,it} \cdot EDD_{m,it}) \\
& + \beta_{6,i} Trend + \beta_{7,i} Trend^2 + \varepsilon_{it}
\end{aligned} \tag{4.1}$$

donde  $m$  es el mes,  $i$  el condado,  $t$  el año y:

- $YIELD_{it}$  es el rendimiento del maíz para el condado  $i$  en el año  $t$ .
- $\alpha_i$  representa los efectos fijos individuales, que capturan características invariables en el tiempo de cada condado.
- $\gamma_t$  representa los efectos fijos temporales, que controlan por factores comunes a todos los condados en un año dado.
- $PRCP_{m,it}$ ,  $PRCP_{m,it}^2$ ,  $GDD_{j,it}$ ,  $EDD_{m,it}$ ,  $PRCP_{m,it} \cdot EDD_{m,it}$  son las variables climáticas incluidas en el modelo para cada mes del verano  $m$  (con  $m = 6, 7, 8$ ).
- $Trend$  y  $Trend^2$  son las tendencias lineales y cuadráticas respectivamente, específicas por condado (es decir, se interactúan con la variable que identifica a cada condado, por lo que el efecto es diferente para cada condado).
- $\varepsilon_{it}$  es el término de error idiosincrático que se asume  $iid \sim N(0, \sigma^2)$ .

En los casos en que no se cumpla con los supuestos de homocedasticidad, ausencia de autocorrelación temporal y espacial, los errores estándares serán corregidos para trabajar con sus versiones robustas y lograr una inferencia válida.

#### 4.1.2. Regresión en Panel Espacial (SAR)

Este tipo de modelo incorpora una dimensión espacial explícita, permitiendo capturar la dependencia entre unidades geográficas vecinas (i.e. condados) en el rendimiento del maíz. Al incluir un término de rezago espacial de la variable dependiente, el modelo SAR reconoce que el rendimiento en un condado puede estar influenciado por el rendimiento en condados cercanos. Además, al incorporar efectos fijos temporales se controla por los shocks comunes a todos los condados en un año determinado.

El modelo estimado es el siguiente:

$$\begin{aligned}
 \log(YIELD_{it}) = & \gamma_t + \lambda \sum_j w_{ij} \log(YIELD_{jt}) + \sum_{m=6}^8 \beta_{1,m} PRCP_{m,it} \\
 & + \sum_{m=6}^8 \beta_{2,m} PRCP_{m,it}^2 + \sum_{m=6}^8 \beta_{3,m} GDD_{m,it} \\
 & + \sum_{m=6}^8 \beta_{4,m} EDD_{m,it} + \sum_{m=6}^8 \beta_{5,m} (PRCP_{m,it} \cdot EDD_{m,it}) \\
 & + \beta_{6,i} Trend + \varepsilon_{it}
 \end{aligned} \tag{4.2}$$

donde:

- $YIELD_{it}$  es el rendimiento del maíz para el condado  $i$  en el año  $t$ .
- $\gamma_t$  representa los efectos fijos temporales, que controlan por factores comunes a todos los condados en un año dado.
- $w_{ij}$  es el elemento de la matriz de pesos espaciales  $W$ , que representa la relación espacial entre los condados  $i$  y  $j$ .
- $\sum_j w_{ij} \log(YIELD_{jt})$  es el promedio ponderado (según la matriz de pesos espaciales) del rendimiento del maíz en logaritmos de los condados vecinos de  $i$  en el año  $t$ .
- $\lambda$  es el coeficiente de dependencia espacial que mide el grado de influencia de los rendimientos en logaritmo de los condados vecinos.
- $PRCP_{m,it}$ ,  $PRCP_{m,it}^2$ ,  $GDD_{m,it}$ ,  $EDD_{m,it}$ ,  $PRCP_{m,it} \cdot EDD_{m,it}$  son las variables climáticas incluidas en el modelo para cada mes del verano  $m$  (con  $m = 6, 7, 8$ ).
- $Trend$  es la tendencia lineal específica por condado (es decir, se interactúa con la variable que identifica a cada uno de los condados, por lo que el efecto de la tendencia es diferente por condado).
- $\varepsilon_{it}$  es el término de error idiosincrático que se asume  $iid \sim N(0, \sigma^2)$ .

La matriz de pesos espaciales  $W$  se construye en base a la vecindad entre condados. Esta matriz permite capturar las relaciones espaciales que fundamentan los efectos indirectos incluidos en los modelos. Se construyó a partir de una lista de condados vecinos dentro del *Midwest* basada en relaciones de contigüidad geográfica: se considera vecino a todo condado que comparte una frontera con otro. A partir de esta lista, se generó un objeto de tipo `nb` que

define para cada unidad su conjunto de vecinos. Luego, se transformó en un objeto `listw` con el estilo de normalización “W”, lo que implica que los pesos son uniformemente distribuidos entre los vecinos de cada unidad y normalizados fila por fila para que la suma de los pesos sea uno.

### 4.1.3. Regresión en Panel Espacial (SARAR)

Este tipo de modelo permite capturar la dependencia espacial existente en la variable dependiente (como en el modelo SAR) y en los términos de error del modelo. En primer lugar, el modelo SARAR asume que el rendimiento en un condado es dependiente del rendimiento de condados cercanos. En segundo lugar, asume que los errores de una unidad geográfica están correlacionados con los errores de sus unidades vecinas, lo que permite controlar por factores no observados que presentan una estructura espacial, es decir, que afectan a grupos de unidades geográficamente próximas de manera similar. Al mismo tiempo, la inclusión de efectos fijos temporales permite capturar los shocks comunes a todos los condados en un período determinado.

El modelo estimado es el siguiente:

$$\begin{aligned} \log(YIELD_{it}) = & \gamma_t + \lambda \sum_j w_{ij} \log(YIELD_{jt}) + \sum_{m=6}^8 \beta_{1,m} PRCP_{m,it} \\ & + \sum_{m=6}^8 \beta_{2,m} PRCP_{m,it}^2 + \sum_{m=6}^8 \beta_{3,m} GDD_{m,it} \\ & + \sum_{m=6}^8 \beta_{4,m} EDD_{m,it} + \sum_{m=6}^8 \beta_{5,m} (PRCP_{m,it} \cdot EDD_{m,it}) \\ & + \beta_{6,i} Trend_{it} + u_{it} \end{aligned} \quad (4.3)$$

$$u_{it} = \rho \sum_j w_{ij} u_{jt} + \varepsilon_{it} \quad (4.4)$$

donde:

- $YIELD_{it}$  es el rendimiento del maíz para el condado  $i$  en el año  $t$ .
- $\gamma_t$  representa los efectos fijos temporales, que controlan por factores comunes a todos los condados en un año dado.
- $w_{ij}$  es el elemento de la matriz de pesos espaciales  $W$ , que representa la relación espacial entre los condados  $i$  y  $j$ .

- $\sum_j w_{ij} \log(YIELD_{jt})$  es el promedio ponderado (según la matriz de pesos espaciales) del rendimiento del maíz en logaritmos de los condados vecinos de  $i$  en el año  $t$ .
- $\lambda$  es el coeficiente de dependencia espacial que mide el grado de influencia de los rendimientos en logaritmo de los condados vecinos.
- $PRCP_{m,it}$ ,  $PRCP_{m,it}^2$ ,  $GDD_{j,it}$ ,  $EDD_{m,it}$ ,  $PRCP_{m,it} \cdot EDD_{m,it}$  son las variables climáticas incluidas en el modelo para cada mes del verano  $m$  (con  $m = 6, 7, 8$ ).
- $Trend$  es la tendencia lineal específica por condado (es decir, se interactúa con la variable que identifica a cada uno de los condados, por lo que el efecto de la tendencia es diferente por condado).
- $u_{it}$  es el término de error estructurado espacialmente.
- $\sum_j w_{ij} u_{jt}$  representa el promedio ponderado (según la matriz de pesos espaciales) de los errores de los condados vecinos de  $i$  en el año  $t$ .
- $\rho$  es el coeficiente de autocorrelación espacial del error.
- $\varepsilon_{it}$  es el término de error idiosincrático que se asume  $iid \sim N(, \sigma^2)$ .

## 4.2. Estrategia de Estimación

La estrategia de estimación se basa en modelos de datos de panel que permiten controlar tanto por heterogeneidad no observada como por posibles correlaciones espaciales.

En una primera etapa, se estima un modelo de efectos fijos con efectos individuales (por condado) y temporales (por año), con la función `feols` del paquete `fixest` en R. Permite capturar características estructurales invariables en el tiempo y shocks comunes a todos los condados en un determinado año. Se utilizaron errores estándar robustos tipo Driscoll-Kraay (SCC), que corrigen por heterocedasticidad, autocorrelación temporal y dependencia cruzada en paneles con dimensión temporal grande. A partir de los residuos del modelo estimado, se aplicó el *test* de dependencia cruzada de Pesaran (*CD test*), el cual permite evaluar la presencia de correlación entre unidades espaciales (i.e. condados). El resultado de esta prueba, resumido en la Tabla 4.1, muestra un estadístico altamente significativo, lo que proporciona evidencia empírica a favor de la existencia de dependencia espacial en los datos.



Tabla 4.1: Test de Dependencia Cruzada de Pesaran

| Test            | Estadístico $z$ | p-valor                 |
|-----------------|-----------------|-------------------------|
| Pesaran CD test | 13,5            | $< 2,2 \times 10^{-16}$ |

Este hallazgo motiva la incorporación posterior de modelos espaciales para capturar dicha estructura en la estimación de los rendimientos del maíz. En particular, se estiman modelos SAR y SARAR, previamente definidos, que permiten considerar distintas formas de autocorrelación espacial, en la variable dependiente y en los errores.

La estimación se realiza con la función `spml` del paquete `splm` en R, utilizando la matriz de pesos espaciales  $W$  basada en la vecindad entre condados, como se comentó anteriormente.

En los modelos espaciales no se incluyen efectos fijos individuales por condado, ya que el componente espacial del modelo ya captura una buena parte de las diferencias persistentes entre unidades geográficas. Incluir al mismo tiempo efectos fijos y términos espaciales genera problemas de colinealidad. Por el mismo motivo tampoco se considera la tendencia cuadrática por condado.

# Capítulo 5

## Resultados

En este capítulo se presentan los hallazgos obtenidos a partir de la estimación y evaluación de los diferentes modelos propuestos. El objetivo principal es analizar cómo la incorporación de la estructura espacial afecta la explicación y predicción de la variable de interés, comparando el desempeño de modelos tradicionales de efectos fijos con aquellos que incluyen términos de autocorrelación espacial.

En particular, se quiere observar cómo varía la estimación de los coeficientes bajo las diferentes especificaciones del modelo para la muestra completa, y luego a partir de los modelos entrenados (muestra *in-sample*), evaluar en qué medida estos cambios pueden mejorar la capacidad predictiva fuera de la muestra (*out-of-sample*). Se incluyen resultados detallados de los coeficientes estimados, su significancia estadística, medidas de bondad de ajuste y capacidad predictiva.

Luego, se realiza un análisis de robustez para evaluar la estabilidad de los resultados frente a modificaciones metodológicas, como la redefinición de la matriz de pesos espaciales  $W$  y la exclusión de unidades con alta proporción de datos imputados.

Finalmente, se utilizan las proyecciones climáticas del IPCC bajo el escenario SSP2-4.5 para el período 2024–2100 con el fin de analizar la evolución esperada del rendimiento del maíz frente a escenarios de cambio climático [[Earth System Grid Federation, 2024](#)].

### 5.1. Estimación del Efecto del Clima sobre el Rendimiento del Maíz

En esta sección se presentan y comparan los resultados obtenidos a partir de la estimación de los modelos para la muestra completa. La tabla 5.1 muestra los coeficientes estimados para cada modelo junto con su significatividad estadística y medidas de bondad de ajuste como

el  $R^2$  ajustado y el *Within*  $R^2$ .

Tabla 5.1: Estimaciones

| Variable                         | FE                        | SAR                       | SARAR                     |
|----------------------------------|---------------------------|---------------------------|---------------------------|
| $\hat{\rho}$                     |                           |                           | $-0,474^{***}$            |
| $\hat{\lambda}$                  |                           | $0,638^{***}$             | $0,821^{***}$             |
| $PRCP_6$                         | $8,02 \times 10^{-5***}$  | $3,38 \times 10^{-5***}$  | $2,29 \times 10^{-5***}$  |
| $PRCP_7$                         | $1,57 \times 10^{-4***}$  | $7,02 \times 10^{-5***}$  | $4,60 \times 10^{-5***}$  |
| $PRCP_8$                         | $5,15 \times 10^{-5***}$  | $3,13 \times 10^{-5***}$  | $2,20 \times 10^{-5***}$  |
| $PRCP_6^2$                       | $-2,53 \times 10^{-8***}$ | $-1,14 \times 10^{-8***}$ | $-7,75 \times 10^{-9***}$ |
| $PRCP_7^2$                       | $-3,43 \times 10^{-8***}$ | $-1,58 \times 10^{-8***}$ | $-1,06 \times 10^{-8***}$ |
| $PRCP_8^2$                       | $-1,54 \times 10^{-8***}$ | $-9,40 \times 10^{-9***}$ | $-6,71 \times 10^{-9***}$ |
| $GDD_6$                          | $1,16 \times 10^{-5***}$  | $2,77 \times 10^{-6}$     | $-1,91 \times 10^{-7}$    |
| $GDD_7$                          | $-2,43 \times 10^{-5***}$ | $-4,77 \times 10^{-6}$    | $-3,01 \times 10^{-6}$    |
| $GDD_8$                          | $-6,70 \times 10^{-5***}$ | $-2,85 \times 10^{-5***}$ | $-1,56 \times 10^{-5***}$ |
| $EDD_6$                          | $8,22 \times 10^{-4***}$  | $3,68 \times 10^{-4**}$   | $2,58 \times 10^{-4**}$   |
| $EDD_7$                          | $-9,40 \times 10^{-4***}$ | $-3,04 \times 10^{-4***}$ | $-1,42 \times 10^{-4***}$ |
| $EDD_8$                          | $-4,01 \times 10^{-4***}$ | $-9,58 \times 10^{-5}$    | $-4,00 \times 10^{-5}$    |
| $PRCP_6 \cdot EDD_6$             | $-1,82 \times 10^{-7}$    | $-5,51 \times 10^{-7**}$  | $-4,50 \times 10^{-7***}$ |
| $PRCP_7 \cdot EDD_7$             | $-6,58 \times 10^{-7***}$ | $-2,84 \times 10^{-7***}$ | $-2,24 \times 10^{-7***}$ |
| $PRCP_8 \cdot EDD_8$             | $-4,08 \times 10^{-7***}$ | $-2,59 \times 10^{-7***}$ | $-1,86 \times 10^{-7***}$ |
| Efectos Fijos Individuales       | Sí                        | No                        | No                        |
| Efectos Fijos Temporales         | Sí                        | Sí                        | Sí                        |
| Tendencia Lineal por Condado     | Sí                        | Sí                        | Sí                        |
| Tendencia Cuadratica por Condado | Sí                        | No                        | No                        |
| R2 Ajustado                      | 0,818                     | 0,876                     | 0,883                     |
| Within R2                        | 0,340                     | 0,824                     | 0,834                     |

\*  $p \leq 0,10$ , \*\*  $p \leq 0,05$ , \*\*\*  $p \leq 0,01$

Nota: Se utilizan errores estándar de Driscoll–Kraay (DK) en las regresiones con efectos fijos; en los demás casos, se utilizan errores estándar clusterizados.

En el modelo SARAR, tanto el coeficiente de autocorrelación espacial en la variable dependiente ( $\hat{\lambda} = 0,821^{***}$ ) como el coeficiente de autocorrelación espacial en los errores ( $\hat{\rho} = -0,474^{***}$ ) son estadísticamente significativos, lo que evidencia una fuerte dependencia espacial. El modelo SAR también presenta un  $\hat{\lambda}$  significativo ( $0,638^{***}$ ). Esto justifica el uso de modelos espaciales sobre un modelo puramente de efectos fijos.

Las precipitaciones ( $PRCP$ ) son estadísticamente significativas en todos los meses y en todos los modelos, pero con coeficientes decrecientes a medida que se agregan efectos espaciales. Esto sugiere que parte del efecto atribuido inicialmente a la lluvia puede estar capturando efectos espaciales no modelados.

Las precipitaciones ( $PRCP$ ) y su cuadrado tienen signos esperados: un efecto positivo hasta cierto punto, tras el cual el efecto marginal se vuelve negativo, reflejando una relación cuadrática típica en cultivos sensibles al exceso de lluvia.

Las variables de temperatura acumulada ( $GDD$ ) muestran resultados menos consistentes: significativas en todos los modelos solo en agosto, pero generalmente con el signo esperado (positivo en junio y negativo en julio y agosto, indicando efectos adversos del calor en las fases finales del ciclo de crecimiento).

El impacto de las temperaturas extremas ( $EDD$ ) también se refleja en los resultados. En particular, en julio el efecto es negativo y estadísticamente significativo en todos los modelos, indicando una reducción en los rendimientos del maíz ante episodios de calor extremo.

Las interacciones entre precipitación y temperaturas extremas también tienden a ser negativas y significativas, lo que sugiere efectos desfavorables cuando se combinan lluvia y calor extremo. Las interacciones en julio ( $PRCP_7 \cdot EDD_7$ ) son relevantes en SAR y SARAR a diferencia de FE, lo que sugiere que los efectos combinados de lluvia y calor extremo son particularmente importantes y mejor capturados por los modelos espaciales.

El modelo FE presenta un  $R^2$  ajustado de 0,818. Al incorporar estructura espacial, SAR mejora hasta 0,876, y SARAR alcanza el mayor ajuste con 0,883. Esto refleja una mejor capacidad de los modelos espaciales para explicar la variabilidad total de la variable dependiente, lo que se traduce en un ajuste superior del modelo a los datos.

El  $Within R^2$ , que mide la capacidad explicativa sobre la variación intra-condado, es bajo (0,340) para el modelo FE, lo que indica una limitada capacidad para explicar la variación intra-individual. Esta métrica mejora sustancialmente con los modelos espaciales: SAR alcanza 0,824 y SARAR llega a 0,834, lo que demuestra que al modelar explícitamente la dependencia entre unidades geográficas, se logra capturar mucho mejor la variación no explicada por los efectos fijos individuales y temporales.

Por último, se realizó la prueba de autocorrelación espacial de Moran sobre los residuos de los modelos SAR y SARAR. Los p-valores obtenidos para ambos modelos fueron superiores al 5%, indicando que no existe autocorrelación espacial significativa en los residuos. Esto confirma que la especificación espacial utilizada en los modelos captura de manera adecuada la dependencia espacial en los datos, evitando que patrones espaciales no explicados influyan en los resultados y asegurando la validez de las inferencias.

En síntesis, los resultados de esta sección destacan la relevancia de incorporar dependencias espaciales en la modelación del rendimiento del maíz frente a variables climáticas. Si bien los modelos de efectos fijos permiten identificar relaciones significativas entre los factores climáticos y el rendimiento, los modelos espaciales, especialmente el SARAR, ofrecen un ajuste sustancialmente superior, tanto a nivel agregado como dentro de los condados. La ausencia de autocorrelación espacial en los residuos confirma la validez de la especificación.

## 5.2. Evaluación Predictiva

Para evaluar la capacidad predictiva de los modelos, el conjunto de datos fue dividido aleatoriamente en un 80 % de observaciones para estimación (*in-sample*) y un 20 % para validación externa (*out-of-sample*). El subconjunto *in-sample* abarca el período 1970-2012 (43 años), mientras que el subconjunto *out-of-sample* corresponde al período 2013-2023 (11 años).

Se calcularon dos métricas estándar sobre el conjunto de evaluación (*out-of-sample*): la raíz del error cuadrático medio (RMSE) y el error medio absoluto porcentual (MAPE). La Tabla 5.2 muestra los resultados para cada modelo.

Tabla 5.2: RMSE y MAPE

| Modelo | RMSE        | MAPE          |
|--------|-------------|---------------|
| FE     | 0,81        | 15,27 %       |
| SAR    | 0,26        | 4,15 %        |
| SARAR  | <b>0,23</b> | <b>3,47 %</b> |

Los resultados de la Tabla 5.2 muestran que los modelos que incorporan dependencia espacial logran una notable mejora en la capacidad predictiva respecto al modelo de efectos fijos (FE). El modelo SARAR ofrece el mejor desempeño, con el menor error en ambas métricas: un RMSE de 0,23 y un MAPE de solo 3,47 %. Esto evidencia una mayor precisión en la predicción de los valores observados, tanto en términos absolutos como relativos. Le sigue el modelo SAR con un RMSE de 0,26 y un MAPE de 4,15 %. En cambio, el modelo FE muestra un desempeño considerablemente inferior (RMSE de 0,81; MAPE de 15,27 %), lo que sugiere que ignorar la autocorrelación entre unidades vecinas reduce la precisión predictiva.

## 5.3. Análisis de Robustez

En esta sección se presenta un análisis de robustez que consiste en replicar los resultados originales bajo modificaciones específicas en la construcción del panel de datos y la matriz de pesos espaciales  $W$ . El propósito es verificar la estabilidad y consistencia de los hallazgos frente a cambios metodológicos relevantes.

En primer lugar, se replican los resultados utilizando un panel de datos que excluye aquellos condados con una proporción de imputación superior al 10 % en al menos una de las variables PRCP, TMEAN o YIELD. De los 701 condados del caso original, se eliminaron 241 condados que superaban el umbral de imputación, resultando en un panel depurado de 460 condados. Luego, tras la construcción de la matriz de pesos espaciales, el panel se ajustó

a 432 condados, frente a los 696 condados considerados originalmente.

En segundo lugar, se replican los resultados utilizando una matriz de pesos espaciales alternativa basada en los cinco vecinos más cercanos para cada unidad geográfica, según su ubicación geodésica. La matriz de pesos original fue construida a partir de relaciones de contigüidad entre condados (es decir, si comparten frontera), y asigna pesos iguales entre vecinos normalizados por fila, lo que implica que cada condado reparte su influencia de manera uniforme entre sus vecinos inmediatos. En contraste, la variante utilizada para el análisis de robustez selecciona los cinco vecinos geográficamente más cercanos y asigna pesos a través de *Inverse Distance Weighting* (IDW), es decir, un peso proporcional a la inversa de la distancia geodésica. Así, los vecinos más próximos tienen una mayor influencia relativa que los más lejanos.

Los resultados obtenidos bajo estos escenarios alternativos se presentan en las Tablas 5.3 y 5.4. En líneas generales, las estimaciones de los coeficientes, su significancia estadística y las métricas de desempeño de los modelos se mantienen estables con respecto al caso base. Esto sugiere que las conclusiones principales del análisis son robustas a la exclusión de condados con alta proporción de imputación y a la adopción de una matriz de pesos construida a partir de las distancias inversas. Asimismo, para ambos escenarios, los p-valores del test de Moran aplicados a los residuos de los modelos fueron superiores al 5 %.

Tabla 5.3: Estimaciones: Robustez

| Variable                         | Estimación Original       |                           |                           | Panel Depurado            |                           |                           | W Distancia Inversa       |                           |
|----------------------------------|---------------------------|---------------------------|---------------------------|---------------------------|---------------------------|---------------------------|---------------------------|---------------------------|
|                                  | FE                        | SAR                       | SARAR                     | FE                        | SAR                       | SARAR                     | SAR                       | SARAR                     |
| $\hat{\rho}$                     |                           |                           | -0,474***                 |                           |                           | -0,427***                 |                           | -0,572***                 |
| $\hat{\lambda}$                  |                           | 0,638***                  | 0,821***                  |                           | 0,663***                  | 0,824***                  | 0,701***                  | 0,874***                  |
| $PRCP_6$                         | $8,02 \times 10^{-5***}$  | $3,38 \times 10^{-5***}$  | $2,29 \times 10^{-5***}$  | $1,04 \times 10^{-4***}$  | $4,35 \times 10^{-5***}$  | $3,13 \times 10^{-5***}$  | $2,93 \times 10^{-5***}$  | $1,88 \times 10^{-5***}$  |
| $PRCP_7$                         | $1,57 \times 10^{-4***}$  | $7,02 \times 10^{-5***}$  | $4,60 \times 10^{-5***}$  | $1,48 \times 10^{-4***}$  | $6,67 \times 10^{-5***}$  | $4,40 \times 10^{-5***}$  | $6,21 \times 10^{-5***}$  | $3,92 \times 10^{-5***}$  |
| $PRCP_8$                         | $5,15 \times 10^{-5***}$  | $3,13 \times 10^{-5***}$  | $2,20 \times 10^{-5***}$  | $5,43 \times 10^{-5***}$  | $3,53 \times 10^{-5***}$  | $2,33 \times 10^{-5***}$  | $2,76 \times 10^{-5***}$  | $1,84 \times 10^{-5***}$  |
| $PRCP_6^2$                       | $-2,53 \times 10^{-8***}$ | $-1,14 \times 10^{-8***}$ | $-7,75 \times 10^{-9***}$ | $-3,55 \times 10^{-8***}$ | $-1,55 \times 10^{-8***}$ | $-1,12 \times 10^{-8***}$ | $-1,00 \times 10^{-8***}$ | $-6,50 \times 10^{-9***}$ |
| $PRCP_7^2$                       | $-3,43 \times 10^{-8***}$ | $-1,58 \times 10^{-8***}$ | $-1,06 \times 10^{-8***}$ | $-3,27 \times 10^{-8***}$ | $-1,51 \times 10^{-8***}$ | $-1,01 \times 10^{-8***}$ | $-1,42 \times 10^{-8***}$ | $-9,24 \times 10^{-9***}$ |
| $PRCP_8^2$                       | $-1,54 \times 10^{-8***}$ | $-9,40 \times 10^{-9***}$ | $-6,71 \times 10^{-9***}$ | $-1,69 \times 10^{-8***}$ | $-1,06 \times 10^{-8***}$ | $-7,04 \times 10^{-9***}$ | $-8,32 \times 10^{-9***}$ | $-5,67 \times 10^{-9***}$ |
| $GDD_6$                          | $1,16 \times 10^{-5***}$  | $2,77 \times 10^{-6}$     | $-1,91 \times 10^{-7}$    | $1,26 \times 10^{-5}$     | $3,29 \times 10^{-6}$     | $7,30 \times 10^{-7}$     | $3,69 \times 10^{-6}$     | $5,44 \times 10^{-7}$     |
| $GDD_7$                          | $-2,43 \times 10^{-5***}$ | $-4,77 \times 10^{-6}$    | $-3,01 \times 10^{-6}$    | $-3,85 \times 10^{-5}$    | $-1,77 \times 10^{-5***}$ | $-1,13 \times 10^{-5***}$ | $-6,01 \times 10^{-6*}$   | $-3,52 \times 10^{-6*}$   |
| $GDD_8$                          | $-6,70 \times 10^{-5***}$ | $-2,85 \times 10^{-5***}$ | $-1,56 \times 10^{-5***}$ | $-7,69 \times 10^{-5***}$ | $-3,66 \times 10^{-5***}$ | $-2,17 \times 10^{-5***}$ | $-2,51 \times 10^{-5***}$ | $-1,26 \times 10^{-5***}$ |
| $EDD_6$                          | $8,22 \times 10^{-4***}$  | $3,68 \times 10^{-4**}$   | $2,58 \times 10^{-4**}$   | $9,83 \times 10^{-4}$     | $1,58 \times 10^{-4}$     | $2,47 \times 10^{-4**}$   | $2,61 \times 10^{-4*}$    | $1,23 \times 10^{-4}$     |
| $EDD_7$                          | $-9,40 \times 10^{-4***}$ | $-3,04 \times 10^{-4***}$ | $-1,42 \times 10^{-4***}$ | $-1,06 \times 10^{-3***}$ | $-3,39 \times 10^{-4***}$ | $-1,65 \times 10^{-4***}$ | $-2,58 \times 10^{-4***}$ | $-9,40 \times 10^{-5***}$ |
| $EDD_8$                          | $-4,01 \times 10^{-4***}$ | $-9,58 \times 10^{-5}$    | $-4,00 \times 10^{-5}$    | $-4,77 \times 10^{-4}$    | $-7,65 \times 10^{-5}$    | $-2,05 \times 10^{-5}$    | $-7,57 \times 10^{-5}$    | $-1,80 \times 10^{-5}$    |
| $PRCP_6 \cdot EDD_6$             | $-1,82 \times 10^{-7}$    | $-5,51 \times 10^{-7**}$  | $-4,50 \times 10^{-7***}$ | $-4,52 \times 10^{-7}$    | $-1,36 \times 10^{-7}$    | $-3,67 \times 10^{-7**}$  | $-4,29 \times 10^{-7*}$   | $-2,69 \times 10^{-7*}$   |
| $PRCP_7 \cdot EDD_7$             | $-6,58 \times 10^{-7***}$ | $-2,84 \times 10^{-7***}$ | $-2,24 \times 10^{-7***}$ | $-5,25 \times 10^{-7*}$   | $-2,82 \times 10^{-7***}$ | $-2,09 \times 10^{-7***}$ | $-2,23 \times 10^{-7***}$ | $-1,84 \times 10^{-7***}$ |
| $PRCP_8 \cdot EDD_8$             | $-4,08 \times 10^{-7***}$ | $-2,59 \times 10^{-7***}$ | $-1,86 \times 10^{-7***}$ | $-3,48 \times 10^{-7}$    | $-2,54 \times 10^{-7***}$ | $-1,88 \times 10^{-7***}$ | $-2,22 \times 10^{-7***}$ | $-1,47 \times 10^{-7***}$ |
| Efectos Fijos Individuales       | Sí                        | No                        | No                        | Sí                        | No                        | No                        | No                        | No                        |
| Efectos Fijos Temporales         | Sí                        | Sí                        | Sí                        | Sí                        | Sí                        | Sí                        | Sí                        | Sí                        |
| Tendencia Lineal por Condado     | Sí                        | Sí                        | Sí                        | Sí                        | Sí                        | Sí                        | Sí                        | Sí                        |
| Tendencia Cuadratica por Condado | Sí                        | No                        | No                        | Sí                        | No                        | No                        | No                        | No                        |
| R2 Ajustado                      | 0,818                     | 0,876                     | 0,883                     | 0,843                     | 0,915                     | 0,922                     | 0,885                     | 0,892                     |
| Within R2                        | 0,340                     | 0,824                     | 0,834                     | 0,375                     | 0,888                     | 0,897                     | 0,837                     | 0,846                     |

\*  $p \leq 0,10$ , \*\*  $p \leq 0,05$ , \*\*\*  $p \leq 0,01$ 

Nota: Se utilizan errores estándar de Driscoll–Kraay (DK) en las regresiones con efectos fijos; en los demás casos, se utilizan errores estándar clusterizados.

Tabla 5.4: RMSE y MAPE: Robustez

|       | Estimación Original |         | Panel Depurado |         | W Distancia Inversa |        |
|-------|---------------------|---------|----------------|---------|---------------------|--------|
|       | RMSE                | MAPE    | RMSE           | MAPE    | RMSE                | MAPE   |
| FE    | 0,81                | 15,27 % | 0,80           | 15,17 % | –                   | –      |
| SAR   | 0,26                | 4,15 %  | 0,22           | 3,56 %  | 0,24                | 3,78 % |
| SARAR | 0,23                | 3,47 %  | 0,20           | 2,96 %  | 0,22                | 3,25 % |

## 5.4. Proyecciones a 2100

Esta sección analiza la evolución esperada del rendimiento del maíz bajo escenarios de cambio climático, utilizando información proyectada para el período 2024–2100 correspondiente al escenario SSP2-4.5 del IPCC para los modelos econométricos presentados previamente [[Earth System Grid Federation, 2024](#)].


### 5.4.1. Escenario de Cambio Climático SSP2-4.5

Para la proyección de variables climáticas futuras se utilizó el escenario SSP2-4.5 del IPCC (*Shared Socioeconomic Pathway 2*, con forzamiento radiativo de  $4.5 \text{ W/m}^2$  hacia 2100). Este escenario representa una trayectoria intermedia de emisiones, tanto en términos de políticas de mitigación como de crecimiento económico y tecnológico.

Se optó por este escenario debido a que, dentro de los disponibles en la base de datos consultada, fue el único que presentaba información completa con la resolución espacial y temporal necesaria para el análisis a nivel de condado (50 km) y frecuencia diaria. Esto garantizó la coherencia entre los modelos estimados y los datos utilizados para la predicción. Esta proyección contaba con información para 648 condados y por la construcción de la matriz de vecinos  $W$  se termina trabajando con 638 condados.

La Tabla 5.5 presenta los estadísticos descriptivos de las variables climáticas proyectadas en bloques de 20 años, junto con el cambio porcentual respecto al promedio observado entre 2001 y 2020. Se observa que la precipitación acumulada (PRCP) muestra una trayectoria oscilante, sin una tendencia creciente sostenida. De hecho, en tres de los cuatro bloques se proyecta una disminución respecto al promedio base, alcanzando un descenso del 9,13 % hacia finales de siglo, aunque con niveles máximos que se mantienen elevados y una variabilidad que incluso aumenta (el desvío estándar crece de 790 a más de 900). En cambio, la temperatura media (TMEAN) evidencia un incremento progresivo y sostenido, con un aumento total del 8,81 % hacia 2081–2100. Este aumento es el reflejo directo del calentamiento global





proyectado bajo trayectorias de emisiones intermedias. Esto se traduce también en un crecimiento de los *Growing Degree Days* (GDD), cuya media pasa de 13.534 en 2041–2060 a 14.756 en 2081–2100, acumulando un aumento del 11,98 % respecto al período base. Sin embargo, el cambio más abrupto se observa en los *Extreme Degree Days* (EDD). A partir de niveles prácticamente nulos en el período base (mediana igual a cero), se proyecta un crecimiento exponencial, alcanzando un incremento del 1227,89 % hacia finales de siglo. Esto refleja una intensificación notable de las olas de calor, con implicancias severas para el desarrollo del cultivo, incluso cuando GDD y la temperatura media crecen de forma aparentemente favorable. En conjunto, estos resultados muestran que el cambio climático no solo implica un aumento en las temperaturas promedio, sino también una mayor exposición a extremos térmicos.

La Figura 5.1 muestra la evolución temporal de las variables climáticas agregadas para el conjunto de condados analizados, incluyendo tanto los datos observados como las proyecciones bajo el escenario SSP2-4.5 del IPCC. A partir del año 2023, se observa que la precipitación mantiene una alta variabilidad interanual sin una tendencia clara. En contraste, la temperatura media presenta una trayectoria ascendente sostenida, que se intensifica hacia finales del período proyectado. En cuanto a los *Growing Degree Days* (GDD), se evidencia una tendencia creciente, coherente con el aumento de temperaturas, lo cual podría acelerar el desarrollo fenológico de los cultivos. Sin embargo, el amplio incremento de los *Extreme Degree Days* (EDD) sugiere un mayor riesgo de estrés térmico, que podría afectar negativamente la productividad, incluso en presencia de condiciones aparentemente favorables.


Tabla 5.5: Estadísticos Descriptivos de las Variables Climáticas: Proyecciones IPCC

| Período   | Estadístico                   | PRCP    | TMEAN  | GDD      | EDD     |
|-----------|-------------------------------|---------|--------|----------|---------|
| 2021–2040 | Max                           | 6330.94 | 298.99 | 18529.00 | 1640.74 |
|           | Mean                          | 2782.61 | 220.76 | 12875.96 | 75.32   |
|           | Median                        | 2681.25 | 218.62 | 12744.59 | 0.00    |
|           | Min                           | 649.70  | 80.90  | 940.84   | 0.00    |
|           | SD                            | 790.46  | 26.63  | 2337.81  | 160.30  |
|           | % $\Delta$ respecto 2001–2020 | -4.72   | -1.20  | -2.29    | 297.43  |
| 2041–2060 | Max                           | 6723.65 | 326.64 | 19339.85 | 3400.29 |
|           | Mean                          | 2943.27 | 228.22 | 13534.59 | 102.50  |
|           | Median                        | 2882.41 | 226.62 | 13482.52 | 1.76    |
|           | Min                           | 482.42  | 85.61  | 1362.65  | 0.00    |
|           | SD                            | 843.89  | 25.88  | 2218.63  | 252.08  |
|           | % $\Delta$ respecto 2001–2020 | 0.78    | 2.14   | 2.71     | 440.85  |
| 2061–2080 | Max                           | 6826.47 | 313.64 | 19038.82 | 2456.95 |
|           | Mean                          | 2882.45 | 236.20 | 14206.84 | 164.18  |
|           | Median                        | 2820.59 | 234.51 | 14187.53 | 18.36   |
|           | Min                           | 814.66  | 87.84  | 1344.46  | 0.00    |
|           | SD                            | 858.72  | 25.24  | 2093.06  | 323.34  |
|           | % $\Delta$ respecto 2001–2020 | -1.30   | 5.71   | 7.81     | 766.30  |
| 2081–2100 | Max                           | 6862.11 | 324.51 | 19520.41 | 3352.27 |
|           | Mean                          | 2653.89 | 243.13 | 14756.36 | 251.66  |
|           | Median                        | 2575.48 | 241.28 | 14755.02 | 50.90   |
|           | Min                           | 714.28  | 95.49  | 1952.03  | 0.00    |
|           | SD                            | 908.75  | 26.06  | 2067.93  | 443.73  |
|           | % $\Delta$ respecto 2001–2020 | -9.13   | 8.81   | 11.98    | 1227.89 |

#### 5.4.2. Proyecciones del Rendimiento del Maíz a 2100

La Figura 5.2 presenta las proyecciones del rendimiento del maíz en términos logarítmicos para el período 2024–2100, comparando distintos modelos econométricos. Se observa que el modelo de efectos fijos (FE) proyecta un aumento más pronunciado del rendimiento a lo largo del siglo, aunque acompañado de mayor variabilidad. Por su parte, los modelos espaciales (SAR y SARAR) predicen una evolución más moderada y estable, lo cual parece más coherente con los cambios climáticos observados: si bien el mayor GDD podría favorecer el desarrollo del cultivo, el aumento abrupto de los EDD hacia finales de siglo representa un riesgo importante que podría limitar el crecimiento de los rendimientos. La diferencia en las proyecciones sugiere que los modelos espaciales capturan mejor la variabilidad entre condados y los extremos térmicos, haciendo sus estimaciones más conservadoras frente a escenarios climáticos adversos.

Figura 5.2: Proyecciones del Rendimiento del Maíz



Nota: Los intervalos de confianza se calculan al 95 %. Los errores estándares del modelo de efectos fijos no incluyen los efectos fijos individuales y las tendencias lineales y cuadráticas ya que eran muy grandes por colinealidad.

# Capítulo 6

## Conclusiones y Discusión

En este capítulo se sintetizan los principales hallazgos del análisis empírico realizado sobre el impacto del clima en el rendimiento del maíz, y se identifican las principales limitaciones del estudio junto con líneas de investigación futura que permitan profundizar y complementar el enfoque adoptado.

### 6.1. Principales Hallazgos

En primer lugar, los resultados confirman la existencia de dependencias espaciales significativas entre condados geográficamente cercanos. Esto se evidencia por la robustez y significancia de los coeficientes espaciales estimados ( $\hat{\lambda}$  y  $\hat{\rho}$ ) en los modelos SAR y SARAR, que capturan la influencia de la autocorrelación espacial.

En segundo lugar, se observa que considerar estas dependencias espaciales modifica la estimación del impacto de las variables climáticas sobre el rendimiento del maíz y mejora sustancialmente el ajuste del modelo.

Por último, en términos de capacidad predictiva, los modelos espaciales muestran un desempeño superior. Adicionalmente, al utilizar las proyecciones climáticas del IPCC, el modelo con efectos fijos anticipa un crecimiento más marcado del rendimiento hacia 2100, mientras que los modelos SAR y SARAR generan proyecciones más conservadoras y coherentes con la evolución esperada de las condiciones climáticas, especialmente ante el aumento de temperaturas extremas.

Esto sugiere que incorporar la dimensión espacial mejora no solo la interpretación de la relación entre variables climáticas y rendimiento agrícola, sino también la calidad de las predicciones bajo escenarios de cambio climático.

## 6.2. Limitaciones del Estudio y Posibles Líneas de Investigación Futura

Una primera limitación de este estudio es su enfoque geográfico restringido al *Midwest* de Estados Unidos. Si bien esta región representa una de las principales zonas productoras de maíz a nivel global, los resultados no necesariamente se generalizan a otros contextos. Por ende, una línea de investigación prometedora consiste en extender el enfoque utilizado a otras regiones o cultivos. En particular, la región de Mato Grosso en Brasil — una de las principales zonas productoras de maíz y soja a nivel mundial — presenta condiciones agroclimáticas comparables al *Midwest* estadounidense, tales como clima cálido, alta disponibilidad de tierras cultivables y agricultura a gran escala. Aplicar un análisis espacial detallado en dicho contexto permitiría contrastar los hallazgos de este estudio, validar su aplicabilidad en entornos diversos y aportar herramientas para una planificación agrícola más resiliente frente a los desafíos climáticos globales.

Una segunda limitación está vinculada a la disponibilidad de proyecciones climáticas completas y consistentes. El análisis se basó exclusivamente en el escenario SSP2-4.5 del IPCC, seleccionado por ser el único con información climática diaria y la resolución espacial necesaria. Sin embargo, no se consideraron escenarios más extremos, como el SSP5-8.5, lo que limita el rango de posibles impactos evaluados. Explorar distintos escenarios permitiría capturar la incertidumbre inherente a las proyecciones climáticas futuras. Además, las proyecciones realizadas no contemplan posibles transformaciones en la tecnología agrícola, políticas públicas, ni cambios en el uso del suelo o en la localización de los cultivos. Estos factores podrían alterar significativamente la evolución futura del rendimiento del cultivo.

# Bibliografía

- L. Anselin. Spatial econometrics. In L. Anselin, editor, *Palgrave Handbook of Econometrics: Volume 1, Econometrics Theory*, pages 901–969. Palgrave Macmillan, Basingstoke, UK, 2016.
- M. Auffhammer, S. M. Hsiang, W. Schlenker, and A. Sobel. Using weather data and climate model output in economic analyses of climate change. *Review of Environmental Economics and Policy*, 2013.
- B. Barnabás, K. Jäger, and A. Fehér. The effect of drought and heat stress on reproductive processes in cereals, 2008.
- R. Bonhomme. Bases and limits to using ‘degree.day’ units, 2000.
- M. Dell, B. F. Jones, and B. A. Olken. What do we learn from the weather? the new climate-economy literature. *Journal of Economic Literature*, 52(3):740–798, 2014.
- O. Deschênes and M. Greenstone. The economic impacts of climate change: evidence from agricultural output and random fluctuations in weather. *American Economic Review*, 97(1):354–385, 2007.
- Earth System Grid Federation. CMIP6 Climate Projections (SSP2-4.5 Scenario). <https://esgf-metagrid.cloud.dkrz.de/search>, 2024. Accessed on [tu fecha de descarga, por ejemplo June 10, 2025].
- Federal Communications Commission. Census block conversions api. <https://geo.fcc.gov/api/census/>, n.d. Accessed June 3, 2025.
- Food and Agriculture Organization of the United Nations. FAOSTAT Analytical Brief 96: Agricultural production statistics 2010–2023, 2024. URL <https://openknowledge.fao.org/server/api/core/bitstreams/df90e6cf-4178-4361-97d4-5154a9213877/content>. Accessed June 3, 2025.

- IPCC. *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, 2014.
- J. LeSage and R. K. Pace. *Introduction to Spatial Econometrics*. CRC Press, New York, 2009.
- D. B. Lobell, W. Schlenker, and J. Costa-Roberts. Climate trends and global crop production since 1980. *Science*, 333(6042):616–620, 2011.
- D. B. Lobell, M. J. Roberts, W. Schlenker, N. Braun, B. B. Little, R. M. Rejesus, and G. L. Hammer. Greater sensitivity to drought accompanies maize yield increase in the us midwest. *Science*, 344(6183):516–519, 2014.
- G. S. McMaster and W. W. Wilhelm. Growing degree-days: one equation, two interpretations, 1997.
- 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.
- N. D. Mueller, E. E. Butler, K. A. McKinnon, A. Rhines, M. Tingley, N. M. Holbrook, and P. Huybers. Cooling of us midwest summer temperature extremes from cropland intensification. *Nature Climate Change*, 6(3):317–322, 2016. doi: 10.1038/nclimate2825.
- National Oceanic and Atmospheric Administration. Global historical climatology network (ghcn) - daily, 2024. Recuperado de <https://www.ncei.noaa.gov/pub/data/ghcn/daily/>. Accedido en febrero de 2025.
- A. Ortiz-Bobea, T. R. Ault, C. M. Carrillo, R. G. Chambers, and D. B. Lobell. Anthropogenic climate change has slowed global agricultural productivity growth. *Nature Climate Change*, 11(4):306–312, 2021.
- W. Schlenker and M. J. Roberts. Nonlinear temperature effects indicate severe damages to us crop yields under climate change. *Proceedings of the National Academy of Sciences*, 106(37):15594–15598, 2009.
- W. Schlenker, W. M. Hanemann, and A. C. Fisher. The impact of global warming on u.s. agriculture: an econometric analysis of optimal growing conditions, 2006.
- United States Department of Agriculture. Crop production report – november 2024, nov 2024a. URL [https://www.nass.usda.gov/Publications/Todays\\_Reports/reports/crop1124.pdf?](https://www.nass.usda.gov/Publications/Todays_Reports/reports/crop1124.pdf?) Accessed: 2025-06-03.

United States Department of Agriculture. Quick stats database, 2024b. Recuperado de <https://quickstats.nass.usda.gov/>. Accedido en febrero de 2025.

United States Department of Agriculture, Foreign Agricultural Service. Corn production overview. <https://www.fas.usda.gov/data/production/commodity/0440000>, 2024. Accedido en junio de 2025.

S. D. Yun and B. M. Gramig. Spatial panel models of crop yield response to weather: Econometric specification strategies and prediction performance. *American Journal of Agricultural Economics*, 105(1):3–27, 2023. doi: 10.1111/ajae.12345.