


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA

DEPARTAMENTO DE INDUSTRIAS



**ANÁLISIS MULTIVARIADO DE LOS FACTORES QUE INCIDEN EN EL  
PRECIO DEL TRIGO  
EN CHILE Y A NIVEL INTERNACIONAL,  
INCORPORANDO REDES NEURONALES EN LOS MODELOS**

**Sebastián Delgado Rubilar**

Memoria para optar al título de

**Ingeniero Civil Industrial**

**Profesor guía:**

Werner Kristjanpoller Rodríguez

**Profesor correferente:**

Bernardo Pincheira Sarmiento

Valparaíso, junio de 2025

EX UMBRA IN SOLEM



## CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

### 1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción):  Memoria o trabajo de título;  Tesis de Postgrado;

Título del trabajo: Análisis multivariado de los factores que inciden en el precio del trigo en Chile y a nivel internacional, incorporando redes neuronales en los modelos.

Nombre del candidato(a): Sebastián Delgado Rubilar

Carrera / Grado: Ingeniería Civil Industrial

Campus: Casa Central Valparaíso ; Departamento: Industrias

### 2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Werner Kristjanpoller Rodríguez, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución

### 3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

El trabajo **NO** contiene información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por:

- 6 meses;  12 meses;  2 años;  3 años;  5 años;  10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

### 4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 23-07-2025

; Firma:

Estudiante o Candidato(a):

Fecha: 23-07-2025

; Firma:

*Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.*

## **0.1. Agradecimientos**

Quisiera agradecer a mi madre por su respaldo constante y por enseñarme la virtud de la perseverancia.

## 0.2. Resumen Ejecutivo

Entre 2018 y 2024, los precios internacionales del trigo se vieron afectados por shocks geopolíticos, energéticos y climáticos. Esta tesis cuantifica tanto el efecto de dichos shocks sobre la cotización del contrato *ZW* de la bolsa CBOT como la velocidad con que ese impacto se transmitió a los precios de productos basados en trigo en el mercado chileno.

El análisis se sustenta en dos enfoques complementarios. En primer lugar, se estima un VAR-X semanal que incorpora las series internacionales de precio (*ZW* y los FOB de Argentina y Brasil), los referenciales energéticos (WTI y TTF), el tipo de cambio USD/CLP y una variable dicotómica asociada a la guerra Rusia-Ucrania; cuando las series resultan cointegradas, el modelo se reformula como VECM. La robustez estadística se verifica para la estabilidad, autocorrelación y heterocedasticidad. En segundo lugar, se entrenan redes neuronales feed-forward en dos configuraciones: un modelo completo que incluye todas las variables exógenas de precio y clima y un modelo reducido que retiene únicamente los determinantes internacionales esenciales. La capacidad predictiva de ambos enfoques se contrasta con la del VAR mediante el error medio absoluto (MAE) en pronósticos a doce semanas para 2025.

Se puede observar que el conflicto Rusia - Ucrania impacta en la serie de cotización *ZW*, ello mediante un análisis econométrico considerando múltiples variables. Por su parte, las anomalías de temperatura y precipitación en Estados Unidos y Canadá mostraron un poder explicativo limitado frente a los factores macrofinancieros.

El VAR(3) muestra una transmisión diferenciada de precios: el pan depende casi exclusivamente de su propio rezago inmediato y del trigo Paraná con tres semanas de desfase. El precio del trigo argentino, en cambio, responde principalmente al shock bélico y a su propio rezago de tres semanas; la influencia del pan es marginal. Paraná es la serie más reactiva: ajusta con rapidez a los movimientos del pan (rezagos 1 y 2) y del precio del trigo argentino (rezago 2), además de exhibir persistencia propia. En términos predictivos, el VAR alcanzó un MAE = 0,156 para los precios locales, superando al modelo de red neuronal reducido (MAE = 0,170) y al modelo neuronal completo (MAE = 0,327), lo que confirma su mayor precisión en este contexto.

# Índice general

0.1. Agradecimientos . . . . .	1
0.2. Resumen Ejecutivo . . . . .	2
0.3. Introducción . . . . .	7
0.4. Problema de Investigación . . . . .	8
0.5. Objetivos de la investigación . . . . .	11
0.5.1. Objetivo general . . . . .	11
0.5.2. Objetivos específicos . . . . .	12
0.6. Marco Teórico . . . . .	13
0.6.1. Determinantes empíricos del precio del trigo . . . . .	13
0.7. Metodología . . . . .	20
0.7.1. Introducción a las series de tiempo . . . . .	20
0.7.2. Recopilación, preparación y análisis exploratorio de datos (EDA) . . . . .	23
0.7.3. Ajuste inicial de las series . . . . .	25
0.7.4. Formulación y estimación del modelo VAR . . . . .	26
0.7.5. Cointegración y modelo VECM . . . . .	28
0.7.6. Diagnósticos adicionales . . . . .	30
0.7.7. Modelo de redes neuronales (MLP) con <i>bootstrap</i> . . . . .	32
0.7.8. Limitaciones . . . . .	35
0.8. Datos y fuentes . . . . .	36
0.8.1. Series de precios de commodities y divisas . . . . .	37

0.8.2.	Producción, comercio y superficie agrícola . . . . .	38
0.8.3.	VARIABLES CLIMÁTICAS . . . . .	38
0.8.4.	Factores demográficos y sentimiento económico . . . . .	38
0.9.	Escenario Internacional . . . . .	39
0.9.1.	Principales exportadores de trigo a nivel mundial . . . . .	39
0.9.2.	Variación de los precios del trigo ruso (2022–2023) . . . . .	47
0.9.3.	Principales importadores de trigo a nivel mundial . . . . .	48
0.10.	Delimitación espacial y obtención de variables climáticas . . . . .	53
0.10.1.	Identificación rigurosa del área productiva . . . . .	53
0.10.2.	Extracción de clima diario (2018–2024) . . . . .	56
0.10.3.	Ventajas y aportes del procedimiento . . . . .	58
0.10.4.	Series térmicas de anomalías Cono Norte . . . . .	59
0.10.5.	Agrupamiento entre provincias por series térmicas . . . . .	61
0.10.6.	Extracción de <i>Drivers</i> Climáticos mediante EOF/PCA . . . . .	65
0.10.7.	Resultados del PCA para Clusters de Temperaturas . . . . .	66
0.10.8.	Ventanas quincenales de precipitación Cono Norte . . . . .	68
0.10.9.	Series térmicas de anomalías Cono Sur . . . . .	73
0.10.10.	Ventanas quincenales de precipitación Cono Sur . . . . .	75
0.10.11.	Diagnóstico series WTI, ZW y percepción de recesión . . . . .	77
0.10.12.	Modelo VAR(3) en diferencias ( $\Delta WTI$ , $\Delta ZW$ ) . . . . .	81
0.11.	Desarrollo del modelo VECM . . . . .	85
0.11.1.	Modelo VECM semanal . . . . .	89
0.11.2.	Aproximación del modelo del trigo a nivel nacional . . . . .	94
0.12.	Resultados del Modelo VAR-X(3) con Variable Binaria . . . . .	100
0.12.1.	Diagnóstico del modelo . . . . .	104
0.13.	Pronóstico con el modelo VAR–X(3) con variable binaria . . . . .	105
0.13.1.	Objetivo del modelo . . . . .	105

0.13.2. Proceso de proyección y pronóstico . . . . .	105
0.13.3. Resultados del pronóstico . . . . .	106
0.14. Pronóstico y bandas de predicción: MLP vs modelo completo . . . . .	107
0.14.1. Carga y preparación de los datos . . . . .	107
0.14.2. Entrenamiento del modelo MLP . . . . .	108
0.14.3. Bootstrap clásico . . . . .	108
0.14.4. Bandas de predicción . . . . .	108
0.14.5. Resultados Obtenidos . . . . .	109
0.14.6. Comparación de resultados mediante MAE . . . . .	110
0.15. Conclusión . . . . .	111

### 0.3. Introducción

El trigo es uno de los commodities agrícolas más influyentes para la seguridad alimentaria mundial y, de manera particular, para la canasta básica de los hogares chilenos (Food and Agriculture Organization of the United Nations, 2023). Como insumo principal de productos de alto consumo —pan, pasta y harina—, su precio impacta directamente la inflación alimentaria y, por extensión, la estabilidad macroeconómica de países importadores netos. Durante la última década, el mercado internacional del trigo ha experimentado una volatilidad creciente, impulsada por factores económicos, climáticos y geopolíticos: tensiones comerciales entre grandes potencias agrícolas, sequías recurrentes en las regiones productoras del Cono Norte y, de forma decisiva, el conflicto bélico entre Ucrania y Rusia, que alteró los flujos de oferta del Mar Negro y redefinió los puntos de equilibrio mundial.

Comprender la formación de precios del trigo y anticipar su evolución resulta esencial para diseñar políticas públicas de mitigación y estrategias privadas de cobertura. Sin embargo, dos retos dificultan esta tarea. Primero, la interacción compleja entre múltiples variables: precios energéticos (WTI, TTF), shocks de oferta localizados y condiciones agroclimáticas que afectan los rendimientos anuales. Segundo, la necesidad de modelos empíricos capaces de capturar tanto relaciones lineales de largo plazo como patrones no lineales de alta frecuencia.

Para enfrentar estos desafíos se adopta un enfoque dual. En primer lugar, se construye un marco econométrico basado en modelos VAR y pruebas de cointegración que examina, a escala internacional, la causalidad y el equilibrio de largo plazo a partir de la serie histórica del contrato de trigo de Chicago (ZW) y, a escala local, las interacciones entre las exportaciones de trigo de Argentina y Brasil y los precios de productos de consumo a base de trigo en Santiago de Chile.

## 0.4. Problema de Investigación

A nivel global, el trigo es uno de los commodities agrícolas más importantes para la seguridad alimentaria y la economía mundial. Durante las últimas décadas, su contribución a la dieta humana ha mostrado una tendencia al alza, situándose entre las principales fuentes de energía y proteína para la población, en especial en los países en desarrollo (Food and Agriculture Organization of the United Nations, [2023](#)). Su carácter de bien esencial lo convierte en un insumo estratégico en los mercados internacionales, donde cualquier variación en su precio repercute en economías dependientes y en hogares vulnerables. Según el Instituto Internacional de Investigación sobre Políticas Alimentarias, las tensiones geopolíticas recientes han intensificado la volatilidad en los precios de los granos, afectando la estabilidad de mercados clave (Glauber, [2023](#)).

Durante los últimos años, los precios internacionales del trigo han mostrado una alta volatilidad, influenciados por factores climáticos, económicos y geopolíticos. La pandemia de COVID-19 generó disrupciones en las cadenas de suministro, incrementando los costos logísticos y reduciendo los niveles de producción agrícola. Más recientemente, la guerra entre Rusia y Ucrania, dos de los mayores exportadores de trigo a nivel mundial, provocó un aumento abrupto de los precios internacionales, generando inseguridad alimentaria en regiones como África y Medio Oriente. Naciones Unidas advierte que las sanciones relacionadas con el conflicto han exacerbado la inseguridad alimentaria global, afectando desproporcionadamente a las economías más vulnerables. Este tipo de crisis puede llevar a millones de personas a la pobreza extrema debido al encarecimiento de los alimentos básicos (European Commission, [2022](#)).

En el caso de Chile, el trigo desempeña un papel central tanto en la producción agrícola como en el consumo doméstico. A nivel local, es el cultivo más importante en términos de superficie sembrada y valor económico, concentrándose principalmente en las regiones de Maule, Ñuble, Biobío y La Araucanía. Sin embargo, la producción nacional no cubre la demanda interna, lo que obliga al país a depender de importaciones. Por lo tanto, las fluctuaciones internacionales en el precio del trigo afectan directamente productos de la canasta básica, como el pan y las pastas, componentes esenciales en la dieta de las familias chilenas (Oficina de Estudios y Políticas Agrarias, [2024](#)).

El impacto de estas fluctuaciones es particularmente crítico en los hogares de menores ingresos, donde una mayor proporción del presupuesto se destina a la alimentación. Estudios indican que un aumento en el precio de los alimentos puede provocar una disminución significativa del poder adquisitivo de los hogares más vulnerables, incrementando la inseguridad alimentaria (Global Network Against Food Crises, [2024](#)). Las proyecciones para los cultivos de cereales muestran una recuperación lenta tras las disrupciones globales recientes, lo que refuerza la necesidad de soluciones políticas y económicas.

A pesar de su importancia, persiste un vacío en la comprensión de los factores que determinan las fluctuaciones del precio del trigo a nivel internacional y de su impacto en mercados locales como el chileno. Resulta imprescindible analizar la interacción entre variables climáticas, factores económicos globales (por ejemplo, tasas de interés y tipo de cambio) y precios de commodities sustitutos o complementarios para explicar estas dinámicas.

Por consiguiente, esta investigación propone analizar el comportamiento del precio del trigo como commodity internacional y su relación con los precios de la canasta básica en Chile. Mediante un análisis econométrico de series de tiempo, se pretende modelar las fluctuaciones del precio del trigo y evaluar su interacción con factores globales y locales. Este estudio servirá como punto de partida para comprender las dinámicas del mercado del trigo en el mediano plazo, permitiendo identificar patrones relevantes y sus implicaciones en economías dependientes de importaciones.

## **0.5. Objetivos de la investigación**

### **0.5.1. Objetivo general**

Estudiar el comportamiento de las series de tiempo del precio del trigo, tanto a nivel internacional como nacional, mediante modelos econométricos; identificar patrones explicativos y evaluar sus repercusiones en el costo de productos básicos en Chile, con el fin de contribuir al entendimiento de las dinámicas de mercado y su relación con el contexto local.

### **0.5.2. Objetivos específicos**

Para cumplir con el objetivo general, se definen los siguientes objetivos específicos:

1. Examinar las dinámicas del comercio internacional y del precio del trigo, con el propósito de identificar los factores que explican sus fluctuaciones y aportar a la comprensión del mercado global.
  - a) Analizar el precio internacional del trigo basado en la serie ZW de la Bolsa de Chicago, incorporando variables climáticas, percepción de riesgo y otros commodities.
  - b) Evaluar el impacto de eventos globales, como la guerra en Ucrania, en las fluctuaciones del precio internacional del trigo, para entender cómo estos acontecimientos han afectado las dinámicas del mercado global.
2. Desarrollar un modelo econométrico para explicar el comportamiento del precio del trigo en Chile, utilizando variables nacionales e internacionales, con el propósito de comprender cómo dichas variables influyen en los precios locales y en productos derivados como el pan.
3. Realizar proyecciones de corto plazo para las series de precios nacionales afectadas por las variaciones del mercado del trigo .

---

## 0.6. Marco Teórico

### 0.6.1. Determinantes empíricos del precio del trigo

#### Factores climáticos

Sequías prolongadas, olas de calor y lluvias torrenciales se han convertido en los principales motores de la variabilidad anual del rendimiento del trigo. Se estima que los fenómenos meteorológicos extremos provocan pérdidas de la cosecha mundial cada año, con *peak* significativamente mayores en las regiones del Mar Negro, Norteamérica y el sur de Asia (Convención de las Naciones Unidas de Lucha contra la Desertificación, [2023](#)). Cada vez que un gran exportador —EE. UU., Canadá o Rusia— anuncia recortes de producción por estrés hídrico o térmico, el mercado reacciona casi de inmediato con subidas de precio, anticipando la escasez de oferta.

#### Factor geopolítico: guerra en Ucrania

Antes del conflicto, Rusia y Ucrania figuraban entre los principales abastecedores mundiales de trigo, aportando una fracción sustancial del comercio global. El cierre del corredor del Mar Negro en 2023 disparó los precios de los contratos futuros negociados en Chicago y encareció los embarques procedentes de esa zona. Para economías altamente dependientes de dicha ruta —Egipto, Turquía o Bangladesh— el costo de importación del cereal aumentó con rapidez y se trasladó casi de inmediato al precio del pan en sus mercados internos (Nagurney, [2023](#)).

### **Mercado de futuros y transmisión al precio físico**

El contrato de trigo blando número 2 del Chicago Board of Trade (CBOT) funciona como referencia mundial: prácticamente todos los embarques reales se pactan con un pequeño descuento o recargo respecto de esa cotización. Diversos análisis empíricos muestran que las variaciones en el precio futuro se trasladan con rapidez al mercado físico: un incremento de alrededor de diez dólares por tonelada en el CBOT suele traducirse, la semana siguiente, en una subida de entre seis y ocho dólares por tonelada en el grano que efectivamente se entrega. Este efecto se acentúa cuando los grandes fondos financieros amplían sus posiciones ante señales de escasez climática o geopolítica, lo que añade volatilidad en el corto plazo (van Huellen, [2013](#)).

## **Pilar de alimentación**

El trigo constituye uno de los pilares de la seguridad alimentaria mundial: aporta cerca de una quinta parte de las calorías y proteínas que consume la población global. Su extraordinaria adaptabilidad a climas templados y semiáridos —desde los 25° S hasta los 60° N— le permite abastecer a más de 160 países, donde se transforma en productos tan diversos como pan, pasta, fideos, cuscús y tortillas (Shiferaw et al., [2013](#)).

Su densidad energética, facilidad de almacenamiento y versatilidad culinaria han afianzado al trigo como fuente primaria de carbohidratos en amplias regiones de Asia, el Magreb, Europa y Norteamérica. En la dieta mediterránea, por ejemplo, el pan figura en prácticamente todas las comidas; en China y Japón, los fideos de trigo complementan o sustituyen al arroz; mientras que en el Magreb el cuscús y la sémola constituyen la base calórica diaria (Erenstein et al., [2022](#)).

Dada su relevancia nutricional y cultural, cualquier perturbación en la oferta de trigo —sea climática, logística o geopolítica— repercute de forma inmediata en la disponibilidad de alimentos esenciales, especialmente en los países importadores netos y en los hogares de menores ingresos.

## Patrones globales de consumo

Los patrones contemporáneos de consumo de trigo a escala global reflejan un crecimiento moderado en términos absolutos—impulsado sobre todo por la expansión demográfica de Asia, con India y China como principales motores—, pero también una desaceleración relativa del ritmo de aumento *per cápita*. El informe conjunto de la OECD-FAO proyecta un aumento en el consumo global «wheat consumption is expected to be 11 % higher in 2034 than in the base period . . . global use of wheat for food is projected to increase by 57 Mt but to remain stable at about 65 % of total consumption» (Organisation for Economic Co-operation and Development & Food and Agriculture Organization of the United Nations, [2025](#), “Cereals”, párr. 5).

## Turquía y Oriente Próximo

Turquía figura entre los mayores consumidores per cápita de trigo, con un consumo promedio de alrededor de 160 kg por habitante al año, mientras que países como Siria, Irak e Irán registran niveles de consumo comprendidos entre 120 y 157 kg por persona, impulsados por subsidios estatales y reservas estratégicas (Organisation for Economic Co-operation and Development & Food and Agriculture Organization of the United Nations, [2021](#), p. 162).

### **Magreb: Marruecos, Argelia y Túnez**

En el Magreb se registran los consumos de trigo más elevados del planeta, reflejo de su arraigo cultural y de políticas de apoyo al cereal. En particular, **Marruecos** mantiene un consumo per cápita que ronda los 256 kg al año, utilizado sobre todo para pan tradicional como el *khobz* y diversas preparaciones de harina. Por su parte, **Argelia** y **Túnez** presentan consumos similares, en torno a 219 kg anuales por persona, donde el trigo no solo se destina a la elaboración de pan sino también a platos emblemáticos como el *cuscús* y la *chakchouka*. Estos elevados niveles de consumo son posibles gracias a subsidios estatales al precio de la harina y a reservas gubernamentales que garantizan el abasto ante fluctuaciones de mercado (Abis, 2012, párr. 42).

Dado que entre dos y tres de cada cuatro hogazas consumidas en el Magreb proceden de importaciones, la región muestra una gran vulnerabilidad ante cualquier alteración en las rutas marítimas del Mediterráneo. Así, fenómenos meteorológicos extremos —como tormentas o nieblas densas— o tensiones políticas en los estrechos y puertos pueden desencadenar cierres temporales o demoras en el embarque del cereal. Estas interrupciones se traducen de forma casi inmediata en subidas pronunciadas de los precios y en riesgo de escasez, afectando especialmente a los colectivos más desfavorecidos que dedican buena parte de su presupuesto familiar al pan (Abis, 2012, p. 3).

### **Balcanes y Europa oriental**

En los Balcanes y Europa oriental, **Serbia** destaca por un consumo per cápita de trigo cercano a 170 kg al año, con la dieta de las familias —especialmente las de menores ingresos— centrada en el pan y la pasta. A diferencia de regiones con déficit, Serbia genera una cosecha de más de 3 millones de toneladas frente a un consumo doméstico de unos 2 millones de toneladas, lo que le permite exportar el excedente y mitigar el impacto de las fluctuaciones de precios internacionales (USDA Foreign Agricultural Service, [2025](#), p. 2).

### **Asia central**

En Asia central, el trigo desempeña un papel esencial en la alimentación cotidiana y las economías nacionales. **Uzbekistán** destaca con un consumo per cápita que supera los 200 kg anuales, un volumen que refleja tanto la tradición del pan en la mesa uzbeka como los apoyos estatales que mantienen bajos los precios del cereal. Por su parte, **Kazajistán** presenta un consumo medio de alrededor de 178 kg por persona al año, apoyado en su condición de exportador neto: las divisas generadas por las ventas exteriores financian subvenciones y reservas que estabilizan el mercado interno. Estas dinámicas permiten a Kazajistán amortiguar mejor las oscilaciones de precios internacionales, mientras que Uzbekistán, aunque protegido por controles de precio, sigue sujeto a la disponibilidad de divisas para importar trigo cuando la producción local no cubre la demanda (World Bank, [2021](#), pp. 115–116).

## Contexto nacional

**Consumo interno.** Chile demanda alrededor de 2,2 millones de toneladas de trigo al año para abastecer su industria panadera y molinera, consumo que se mantiene estable en la última década gracias a la consolidación de hábitos de panificación casera y a la diversificación de productos elaborados con harina de trigo (Köbrich Gruebler, 2024, p. 3). El consumo per cápita, que supera los 100 kg anuales, refleja tanto la preferencia cultural por el pan como la capacidad industrial de molinerías y panaderías artesanales para adaptar su oferta a nuevas tendencias —como masas madre y pan integral— sin alterar significativamente el volumen total de demanda (Köbrich Gruebler, 2024, p. 3). Además, las campañas de promoción de consumo responsable y los esfuerzos por optimizar la cadena logística han contribuido a sostener estos niveles, incluso ante variaciones en los precios internacionales o incrementos en los costos de producción.

**Origen del trigo importado.** La producción nacional cubre aproximadamente la mitad de esa demanda, mientras que las importaciones, que ascienden a cerca de 1,1 millones de toneladas anuales, provienen mayoritariamente de Argentina (50 %), Canadá (30 %) y Estados Unidos (10 %) (Köbrich Gruebler, 2024, p. 4). Este patrón de suministro refleja la búsqueda de equilibrio entre precio y calidad: Argentina aporta grano con buena relación costo-flete, Canadá es valorado por su mayor contenido proteico y Estados Unidos garantiza continuidad de envíos.

## 0.7. Metodología

### 0.7.1. Introducción a las series de tiempo

El análisis de series temporales constituye un pilar de la econometría moderna, pues permite modelar procesos dinámicos cuyos valores presentan dependencia secuencial. Una serie temporal se define como el conjunto ordenado de observaciones  $\{y_t\}_{t=1}^T$  registradas en intervalos equidistantes (por ejemplo, días o meses) (Box & Jenkins, 1976, p. 23). En finanzas, energía o macroeconomía, estas series exhiben patrones de tendencia, ciclos y estacionalidad que deben diagnosticarse y, en su caso, eliminarse antes del modelado (Chatfield, 2003, p. 12).

#### Supuestos fundamentales para un modelo VAR

Para que las estimaciones y pronósticos de un Vector Autoregresivo (VAR) sean estadísticamente válidos, deben verificarse una serie de condiciones inherentes a la teoría de procesos estocásticos y a la inferencia multivariante. A continuación se detallan los cinco supuestos clave, su justificación teórica, las pruebas empleadas y las implicancias de su violación.

1. **Estacionariedad en media y varianza  $I(0)$ .** El VAR se define sobre un vector  $\mathbf{y}_t$  con propiedades de segundo orden constantes:  $\mathbb{E}[\mathbf{y}_t] = \boldsymbol{\mu}$  y  $\text{Var}(\mathbf{y}_t) = \Sigma_{yy}$  invariables en el tiempo (Lütkepohl, 2005, p. 13). Cuando las variables son integradas de orden uno ( $I(1)$ ) pero exhiben relaciones de equilibrio a largo plazo, se recurre al modelo VECM, que añade un término de corrección de error para preservar la coherencia entre corto y largo plazo (Lütkepohl, 2005, p. 237). La estacionariedad se contrasta mediante la prueba ADF para cada componente individual y, de forma complementaria, con KPSS; la combinación reduce errores de tipo I y II (Lütkepohl, 2005, p. 68).

1. **Selección adecuada del número de rezagos  $p$ .** Un orden insuficiente omite dependencias dinámicas, mientras que uno excesivo introduce sobre-parametrización y pérdida de eficiencia. El valor óptimo se determina minimizando los criterios de información

$$\text{AIC} = -2 \ln L + 2k, \quad \text{BIC} = -2 \ln L + k \ln n,$$

donde  $L$  es la verosimilitud y  $k$  el número de parámetros (Enders, 2009, p. 89).

2. **Normalidad multivariante de los residuos.** Aunque la consistencia de los estimadores MLE no exige normalidad estricta, la obtención de intervalos y contrastes basados en  $t$  y  $\chi^2$  sí la presupone. Se aplica la prueba de Jarque–Bera multivariante y se inspeccionan gráficos Q–Q (Enders, 2009, p. 192).

3. **Ausencia de autocorrelación serial.** Los residuos  $\hat{\varepsilon}_t$  deben aproximarse a un ruido blanco para asegurar que toda la dinámica relevante se haya capturado. El contraste portmanteau generalizado define

$$Q(h) = n \sum_{k=1}^h \text{tr}(\hat{C}_k' \hat{C}_k),$$

donde  $\hat{C}_k$  es la matriz de autocorrelación residual en el rezago  $k$ . En la práctica se emplean las pruebas de Ljung–Box y su extensión multivariante (Enders, 2009, p. 205).

**Estabilidad dinámica.** Un VAR( $p$ ) es estable si las *raíces inversas* del polinomio característico se ubican dentro del círculo unitario:

$$\det(I_k - A_1z - A_2z^2 - \dots - A_pz^p) = 0. \quad (1)$$

Sea  $\{\zeta_i\}$  el conjunto de raíces de (1) y defínase  $\rho_i = \zeta_i^{-1}$  como sus raíces inversas. La condición de estabilidad se expresa como

$$|\rho_i| < 1 \quad \forall i,$$

lo que equivale a  $|\zeta_i| > 1$  para las raíces originales. Esta condición garantiza que las trayectorias ante choques exógenos converjan y que las varianzas de largo plazo permanezcan acotadas (Hamilton, 1994, p. 463).<sup>1</sup>

---

<sup>1</sup>En `statsmodels` (Python), las funciones para VAR reportan y grafican las *inverse roots of the AR characteristic polynomial*; por ello, la verificación empírica consiste en comprobar que dichas raíces inversas se mantengan dentro del círculo unitario.

## 0.7.2. Recopilación, preparación y análisis exploratorio de datos (EDA)

Este trabajo emplea series temporales de precios internacionales de trigo, tipos de cambio y variables macroeconómicas conexas. Las fuentes primarias corresponden a organismos multilaterales y plataformas financieras, complementadas con bases de datos nacionales. Antes de cualquier modelado, se ejecuta un protocolo riguroso de revisión, depuración y descripción gráfica, siguiendo lineamientos estándar para el análisis de series de tiempo (Shumway & Stoffer, 2017).

### Verificación de consistencia

1. **Chequeo de metadatos.** Se comprueban unidades, zonas horarias y frecuencia de muestreo. Las series se armonizan a la periodicidad correspondiente mediante promedios aritméticos (precios) o valores de fin de período.
2. **Alineación temporal.** Se garantiza la coexistencia de observaciones para todas las series; los vacíos remanentes se documentan para su tratamiento posterior.

### Análisis exploratorio (EDA)

**Visualización temporal.** Se elaboran gráficos de líneas y suavizados locales para detectar tendencias, quiebres estructurales y patrones estacionales (Cleveland, 1979).

**Estadística descriptiva.** Se calculan estadísticas descriptivas básicas (media, mediana, desviación estándar, asimetría, curtosis) como síntesis de tendencia, variabilidad y forma de los datos (Joanes & Gill, 1998).

**Correlación.** La matriz de correlaciones de Pearson proporciona un mapa preliminar de interrelaciones. Los coeficientes significativos orientan la inclusión de variables exógenas en modelos multivariados (Rodgers & Nicewander, 1988).

**Pruebas de raíz unitaria preliminares.** Antes de ajustar cualquier modelo, es imprescindible verificar la estacionariedad de las series. Para ello se aplica la prueba de Dickey–Fuller aumentada (ADF) primero sobre la serie en nivel y, de ser necesario, sobre su primera diferencia (Dickey & Fuller, 1979). Este barrido preliminar permite decidir si la serie puede modelarse directamente o si requiere transformaciones para asegurar inferencias válidas.

### **Repositorio reproducible**

Los scripts de limpieza y visualización se implementan en Python (bibliotecas `pandas`, `matplotlib` y `seaborn`) de tal modo que los resultados sean reproducibles.

Esto garantiza que los datos de entrada satisfagan los criterios de integridad y consistencia necesarios, reduciendo la probabilidad de inferencias espurias y potenciando la robustez de los modelos econométricos y de redes neuronales que se revisarán en las secciones posteriores.

### 0.7.3. Ajuste inicial de las series

La estacionariedad se diagnostica mediante las pruebas de Dickey–Fuller aumentada (ADF) y KPSS. La primera contrasta la hipótesis nula de raíz unitaria y la segunda adopta la estacionariedad como hipótesis nula (Enders, 2009, p. 100). La evidencia combinada guía las transformaciones:

- **Diferenciación simple:**  $\Delta y_t = y_t - y_{t-1}$ .
- **Diferenciación estacional:**  $\Delta_s y_t = y_t - y_{t-s}$  (por ejemplo,  $s = 12$  en datos mensuales).
- **Descomposición** (aditiva o multiplicativa) cuando coexisten tendencia y estacionalidad pronunciadas.

#### 0.7.4. Formulación y estimación del modelo VAR

El modelo Vector Autorregresivo de orden  $p$  (VAR( $p$ )) para el vector de  $k$  variables endógenas  $Y_t = (y_{1t}, \dots, y_{kt})'$  se escribe como

$$Y_t = \mathbf{c} + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + \varepsilon_t, \quad \varepsilon_t \sim \mathcal{N}_k(\mathbf{0}, \Sigma), \quad (2)$$

donde cada  $A_j$  es una matriz ( $k \times k$ ) de coeficientes y  $\Sigma$  la matriz de covarianza contemporánea de los innovadores (Lütkepohl, 2005).

##### Selección del rezago óptimo $p$

El número de rezagos controla la capacidad del modelo para capturar la dinámica temporal. Se evalúan los criterios de información

$$\text{AIC}(p) = -2 \ln L(p) + 2k_p, \quad \text{BIC}(p) = -2 \ln L(p) + k_p \ln T, \quad (3)$$

donde  $L(p)$  es la verosimilitud del VAR( $p$ ),  $T$  el tamaño muestral efectivo y  $k_p = k^2 p + k$  cuando sólo se incluye una constante.<sup>2</sup> El valor óptimo  $p^*$  minimiza el criterio elegido; ante empates, se prefiere el menor por parsimonia (Lütkepohl, 2005).

---

<sup>2</sup>Si se incorporan tendencias u otras variables exógenas, deben sumarse sus parámetros a  $k_p$ .

## Diagnóstico posterior de la especificación

1. **Autocorrelación de residuos.** Se aplican pruebas portmanteau multivariantes. El estadístico básico es

$$Q(h) = T \sum_{k=1}^h \text{tr}(\hat{C}'_k \hat{C}_k),$$

donde  $\hat{C}_k = \hat{\Gamma}_0^{-1/2} \hat{\Gamma}_k \hat{\Gamma}_0^{-1/2}$  es la matriz de autocorrelaciones residuales en el rezago  $k$ . Bajo  $H_0$  (ruido blanco hasta  $h$ ),  $Q(h) \sim \chi^2_{k^2(h-p)}$ . La versión de Ljung–Box ajusta cada término por  $\frac{T(T+2)}{T-k}$  (Lütkepohl, 2005).

2. **Normalidad y heterocedasticidad.** Se contrasta la normalidad multivariante (p. ej., Jarque–Bera multivariante) y, ante heterocedasticidad condicional, se reportan errores estándar robustos (HC0) (Lütkepohl, 2005).

3. **Estabilidad dinámica.** Se calculan las *raíces inversas* del polinomio característico

$$\det(I_k - A_1 z - \dots - A_p z^p) = 0.$$

La condición de estabilidad requiere que todas ellas se ubiquen dentro del círculo unitario ( $|\rho_i| < 1$ ), equivalente a  $|\zeta_i| > 1$  para las raíces originales. Esto garantiza convergencia de trayectorias y varianzas acotadas (Lütkepohl, 2005).<sup>3</sup>

**Causalidad de Granger.** El test de causalidad de Granger evalúa si, en la ecuación de  $y_i$ , los coeficientes de los rezagos de  $x_j$  son nulos en conjunto. Un contraste Wald/F con  $p$ -valor inferior al nivel de significancia elegido (por ejemplo,  $\alpha = 0,05$ ) permite rechazar la hipótesis nula de no causalidad (Lütkepohl, 2005).

---

<sup>3</sup>En `statsmodels`, se reportan y grafican las *inverse roots of the AR characteristic polynomial*; por tanto, la comprobación empírica consiste en verificar que dichas raíces inversas permanezcan dentro del círculo unitario.

### 0.7.5. Cointegración y modelo VECM

Si las series son integradas de orden uno,  $I(1)$ , y comparten al menos un vector de cointegración, modelar únicamente las diferencias  $\Delta Y_t$  implicaría perder la relación de equilibrio de largo plazo. Para identificar dicha relación se aplica el procedimiento de máxima verosimilitud de Johansen, que contrasta los estadísticos de traza y de máximo autovalor (Johansen, 1991):

$$\lambda_{\text{tr}}(r) = -T \sum_{i=r+1}^k \ln(1 - \hat{\lambda}_i), \quad \lambda_{\text{máx}}(r) = -T \ln(1 - \hat{\lambda}_{r+1}), \quad (4)$$

donde  $\hat{\lambda}_i$  son los valores propios ordenados y  $r$  es el número de vectores cointegrantes hipotetizado. Sus distribuciones son no estándar; se utilizan valores críticos provistos por Johansen o por MacKinnon et al. (1999).

#### Formulación del VECM

Verificada la cointegración, el VAR( $p$ ) se reparametriza como un modelo de corrección del error:

$$\Delta Y_t = \Pi Y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta Y_{t-i} + \Phi D_t + \varepsilon_t, \quad \varepsilon_t \sim \mathcal{N}_k(\mathbf{0}, \Sigma), \quad (5)$$

donde  $\Pi = \alpha\beta'$  con:

- $\beta$  ( $k \times r$ ): vectores de cointegración ( $\beta'Y_{t-1} = 0$  en equilibrio),
- $\alpha$  ( $k \times r$ ): coeficientes de velocidad de ajuste hacia el equilibrio,
- $\Gamma_i$  ( $k \times k$ ): matrices que recogen la dinámica de corto plazo,
- $D_t$ : términos determinísticos o exógenos  $I(0)$  (constantes, tendencias, dummies, etc.).

Así, el término  $\Pi Y_{t-1} = \alpha\beta'Y_{t-1}$  captura el ajuste de largo plazo, mientras que  $\sum_{i=1}^{p-1} \Gamma_i \Delta Y_{t-i}$  describe las interacciones de corto plazo (Johansen, 1991).

**Selección de rezagos y variables determinísticas** La especificación final del VECM requiere fijar el orden máximo de rezagos  $p$  (por ejemplo,  $p_{\text{máx}} = 12$  en datos mensuales) y el rango de cointegración  $r$  obtenido con los estadísticos de traza y máximo autovalor. En la práctica, se elige  $r$  como el primer valor para el cual el test de traza no rechaza la hipótesis nula, confirmando luego con el estadístico de máximo autovalor (Johansen, [1991](#)).

### 0.7.6. Diagnósticos adicionales

**Heterocedasticidad condicional.** Se aplica la prueba ARCH–LM ecuación por ecuación (Engle, 1982). El estadístico se define como:

$$LM = T R_{\text{aux}}^2 \sim \chi_q^2, \quad (6)$$

donde  $R_{\text{aux}}^2$  proviene de la regresión auxiliar de  $\hat{\varepsilon}_t^2$  sobre sus  $q$  rezagos (y, si se desea, sobre regresores originales). Un valor  $p$  inferior al nivel de significancia elegido lleva a rechazar la homocedasticidad. En tal caso, se reportan errores estándar robustos tipo White (HC0) (Engle, 1982; White, 1980).

**Causalidad temporal.** La causalidad de Granger se contrasta mediante un test Wald sobre el bloque de coeficientes rezagados de  $x_j$  en la ecuación de  $y_i$ ; bajo la nula de no causalidad, el estadístico sigue una distribución  $\chi^2$  con los grados de libertad correspondientes (Granger, 1969). En presencia de integración y posible cointegración, se adopta el procedimiento de Toda–Yamamoto: se estima un VAR con  $(p + d_{\text{máx}})$  rezagos, donde  $d_{\text{máx}}$  es el máximo orden de integración entre las series, y el contraste Wald se aplica solo a los primeros  $p$  rezagos (Toda & Yamamoto, 1995).

## Estimación, pronóstico y evaluación del modelo VAR-X

**Estimación del VAR-X( $p$ ).** Fijado  $p$  mediante criterios de información, se estima el modelo en diferencias:

$$\Delta Y_t = \mathbf{c} + \sum_{i=1}^p \Phi_i \Delta Y_{t-i} + \Gamma X_t + u_t, \quad u_t \sim \mathcal{N}_k(\mathbf{0}, \Sigma_u), \quad (7)$$

donde  $X_t$  contiene regresores exógenos  $I(0)$ ,  $\mathbf{c}$  es un vector de constantes y cada ecuación se estima por MCO (equivalente a MLE bajo normalidad). Los residuos se someten a pruebas portmanteau multivariantes y se verifica la estabilidad dinámica mediante raíces inversas del polinomio característico (Lütkepohl, 2005).

**Pronóstico recursivo.** Con las últimas  $p$  observaciones y un perfil base de exógenas  $X_t$ , se generan predicciones  $h$  pasos adelante. Al trabajar en diferencias, los niveles se reconstruyen acumulando las predicciones sobre el último valor observado (Lütkepohl, 2005).

**Evaluación.** La precisión predictiva se resume con la utilización del error absoluto medio (MAE), con la finalidad de medir las desviaciones respecto a los valores reales observados.

### 0.7.7. Modelo de redes neuronales (MLP) con *bootstrap*

El auge del *deep learning* ha demostrado que las redes neuronales pueden superar a enfoques lineales clásicos cuando existen no linealidades y dependencias complejas (Goodfellow et al., 2016, p. 1). En este estudio se implementa un perceptrón multicapa (MLP) entrenado con ventanas deslizantes y se incorpora un esquema *moving-block bootstrap* (MBB) para construir bandas de predicción al 95 % sin requerir supuestos gaussianos (Bergmeir & Benítez, 2012, p. 192).

#### Preprocesamiento de las series

1. **Diferenciación primera.** Para eliminar tendencia y estabilizar la media, cada serie  $y_t$  se transforma en  $\Delta y_t = y_t - y_{t-1}$ .
2. **Escalado *min-max*.** Las diferencias se normalizan a  $[0, 1]$  para acelerar la convergencia y evitar saturación de activaciones (Goodfellow et al., 2016, p. 12).
3. **Ventanas deslizantes.** Se generan pares entrada-salida con una ventana de longitud  $p = 3$  rezagos:  $[\Delta y_{t-2}, \Delta y_{t-1}, \Delta y_t] \rightarrow \Delta y_{t+1}$ . (La construcción se replica para cada variable endógena.)

## Arquitectura y entrenamiento del MLP

La red consta de una capa oculta con ocho neuronas y activación ReLU; la capa de salida es lineal y entrega simultáneamente las cinco variables endógenas. El entrenamiento se realiza mediante *backpropagation* usando el optimizador Adam (tasa de aprendizaje inicial  $10^{-3}$ ) y *early stopping* tras 10 épocas sin mejora (Pedregosa et al., 2011, p. 2830). El 85 % inicial de la muestra diferenciada se utiliza para entrenar.

## Bootstrap no paramétrico

Para cuantificar la incertidumbre de predicción se adopta el MBB (Bergmeir & Benítez, 2012, p. 192): bloques solapados de tamaño  $b$  se remuestran con reemplazo, generando  $B = 300$  trayectorias sintéticas. Cada réplica alimenta una MLP independiente (misma arquitectura, pesos reinicializados), produciendo así  $B$  pronósticos  $\{\hat{y}_{T+h}^{(b)}\}$ . Los percentiles 2.5 % y 97.5 % definen las bandas inferior (LI) y superior (LS); la mediana empírica se reporta como pronóstico central (PC).

## Reconversión a niveles y bandas de confianza

Los pronósticos de diferencias se acumulan sobre el último nivel observado  $y_T$ :

$$\hat{y}_{T+h}^{(b)} = y_T + \sum_{j=1}^h \Delta \hat{y}_{T+j}^{(b)}.$$

A partir del conjunto  $\{\hat{y}_{T+h}^{(b)}\}$  se obtienen LI, PC y LS al 95 %.

## Evaluación

La precisión predictiva se cuantifica con el error absoluto medio (MAE), definido como

$$\text{MAE} = \frac{1}{H} \sum_{h=1}^H |y_{T+h} - \hat{y}_{T+h}|, \quad (8)$$

donde  $H$  es el horizonte de evaluación,  $y_{T+h}$  el valor observado y  $\hat{y}_{T+h}$  el pronóstico puntual (PC) obtenido a partir del conjunto bootstrap. El MAE resume la magnitud promedio del error en las mismas unidades de la serie, facilitando la interpretación práctica.

### **0.7.8. Limitaciones**

Entre las principales restricciones se destacan: (i) frecuencia de los datos, (ii) supuestos de linealidad inherentes al VAR/VECM, (iii) riesgo de *overfitting* en la MLP. Estas limitaciones orientan líneas de trabajo futuro, como incorporar variables dicotómicas adicionales o explorar arquitecturas más avanzadas (p. ej., LSTM).

## 0.8. Datos y fuentes

El conjunto de datos reúne variables climáticas, de mercado y demográficas registradas inicialmente en frecuencia diaria entre el 2 de enero de 2018 y el 31 de diciembre de 2024. Para armonizar las distintas fuentes se aplicaron los siguientes pasos:

- i) **Normalización temporal.** Todas las fechas se estandarizaron al mismo formato. Posteriormente, las series que solamente se encontraban en frecuencia diaria, se agregaron a frecuencia semanal.
- ii) **Homogeneización monetaria.** Las series expresadas en moneda local se convirtieron a dólares corrientes mediante el tipo de cambio diario correspondiente (USD/ARS, USD/CLP o GBP/USD, según la divisa original). No se aplicó deflactación adicional; los valores resultantes permanecen en USD nominales de la fecha de observación.
- iii) **Clave de integración.** Una vez normalizadas, todas las variables se enlazaron mediante la fecha como clave primaria, garantizando que cada registro semanal contenga la información climática, económica y demográfica coherente en el tiempo.

Este procedimiento asegura la alineación temporal y la comparabilidad monetaria entre países, facilitando el análisis conjunto de los choques de oferta, la demanda y las condiciones financieras que influyen en el mercado del trigo.

### 0.8.1. Series de precios de commodities y divisas

- **Investing.com – U.S. Wheat Futures (ZW):** precios diarios del contrato continuo de trigo CBOT (USD/bu) (Investing.com, [2025c](#)).
- **Investing.com – Dutch TTF Natural Gas Futures:** liquidaciones diarias del gas natural europeo (EUR/MWh) (Investing.com, [2025a](#)).
- **Investing.com – WTI Crude Futures:** precios diarios del contrato continuo de petróleo WTI (USD) (Investing.com, [2025f](#)).
- **Investing.com – USD/ARS, USD/CLP, GBP/USD:** tipos de cambio diarios (Investing.com, [2025b](#), [2025d](#), [2025e](#)).
- **Bolsa de Comercio de Rosario – Cotizaciones locales (FOB Up River):** precios FOB diarios del trigo argentino (USD/t) (Bolsa de Comercio de Rosario, [2025](#)).
- **CEPEA/ESALQ – Indicadores de Trigo (PR y RS):** precios spot diarios en BRL/t (Centro de Estudos Avançados em Economia Aplicada (CEPEA), ESALQ–USP, [2025](#)).
- **Gobierno de Alberta – Wheat Price Dashboard:** precios mensuales de trigo (CAD/t) interpolados a diario (Government of Alberta, [2025](#)).
- **IKAR (Rusia) vía Reuters:** reportes cualitativos sobre el mercado exportador de trigo ruso, empleados para validar shocks geopolíticos (Devitt & Polityuk, [2022](#)).

### 0.8.2. Producción, comercio y superficie agrícola

- **FAOSTAT – Trade Domain (TCL)**: producción, exportaciones e importaciones anuales de trigo (Food and Agriculture Organization of the United Nations, [2025](#)).
- **USDA FAS – Global Agricultural Trade System (GATS)**: estadísticas de comercio agrícola (HS 1001) (United States Department of Agriculture, Foreign Agricultural Service, [2025](#)).
- **SPAM 2020 v2.0 (IFPRI)**: capas GeoTIFF/CSV de área física, cosechada, producción y rendimiento para el trigo (International Food Policy Research Institute (IFPRI), [2025](#)).

### 0.8.3. Variables climáticas

- **NASA POWER API**: temperatura medida a 2 metros de altura y precipitaciones medidas en milímetros para los *bounding boxes* trigueros definidos con SPAM (NASA POWER Project Team, [2025](#)).

### 0.8.4. Factores demográficos y sentimiento económico

- **ONU – World Population Prospects 2022 (Rev. 1)**: población total y urbana anual por país (United Nations, Department of Economic and Social Affairs, Population Division, [2022](#)).
- **Media Cloud – Global South Corpus**: índice diario de *recession sentiment* (Media Cloud Project, MIT Center for Civic Media and Berkman Klein Center, [2025](#)).

---

## **0.9. Escenario Internacional**

### **0.9.1. Principales exportadores de trigo a nivel mundial**

El comercio internacional de trigo ha estado dominado, en las últimas décadas, por un reducido grupo de países que concentran la mayor parte de las exportaciones globales. Entre 2018 y 2023 destacaron como principales exportadores naciones con alta capacidad productiva, infraestructura logística consolidada y acceso preferencial a mercados internacionales.

Durante este período, Rusia y la Unión Europea ocuparon consistentemente las primeras posiciones del ranking mundial, seguidos por Australia, Canadá, Estados Unidos, Argentina y Ucrania. Estos países han mantenido una oferta exportable significativa, incluso frente a condiciones climáticas adversas o restricciones geopolíticas como las derivadas del conflicto en Europa del Este.

La concentración de las exportaciones en estos actores no solo condiciona la disponibilidad global de trigo, sino que también amplifica la sensibilidad de los precios internacionales ante eventos climáticos, logísticos o políticos que afecten a alguno de ellos. Esta dependencia estructural del comercio mundial refuerza la necesidad de monitoreo continuo y de estrategias de abastecimiento diversificadas para los países importadores.

En la siguiente tabla se presenta un resumen del volumen promedio anual exportado por los principales países exportadores de trigo durante el período 2018–2023.

**Tabla 1**  
*Principales exportadores de trigo en 2018*

<b>Productor</b>	<b>Año</b>	<b>Valor [ton]</b>	<b>Participación [ %]</b>
Federación de Rusia	2018	43 965 626	23 %
Canadá	2018	22 874 182	12 %
Estados Unidos de América	2018	22 498 926	12 %
Francia	2018	18 940 343	10 %
Ucrania	2018	16 373 389	9 %
Australia	2018	12 352 837	7 %
Argentina	2018	11 724 765	6 %
Kazajistán	2018	6 198 354	3 %
Rumanía	2018	5 880 584	3 %
Alemania	2018	5 228 811	3 %

*Nota.* Fuente: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024. Elaboración propia.

Como muestra la Tabla 1, la Federación de Rusia encabezó las exportaciones mundiales de trigo en 2018 con casi 44 millones de toneladas, lo que equivale a un 23 % del total. A una considerable distancia, Canadá y Estados Unidos aportaron cada uno alrededor de 22.5 millones de toneladas (12 % cada uno), seguidos por Francia con casi 19 millones (10 %) y Ucrania con más de 16 millones (9 %). En un segundo nivel aparecen Australia y Argentina, con participaciones del 7 % y 6 % respectivamente, mientras que Kazajistán, Rumanía y Alemania, con volúmenes cercanos a los 5–6 millones de toneladas, comparten un 3 % cada uno del mercado global. Este reparto ilustra un mercado dominado por unos pocos grandes productores, aunque con una presencia significativa de varias regiones tanto del hemisferio norte como del sur.

**Tabla 2**  
*Principales exportadores de trigo en 2019*

<b>Productor</b>	<b>Año</b>	<b>Valor [ton]</b>	<b>Participación [ %]</b>
Federación de Rusia	2019	31 873 170	17 %
Estados Unidos de América	2019	27 068 496	15 %
Canadá	2019	22 805 172	12 %
Ucrania	2019	20 022 073	11 %
Francia	2019	19 956 974	11 %
Argentina	2019	10 536 578	6 %
Australia	2019	9 591 796	5 %
Rumanía	2019	6 103 188	3 %
Alemania	2019	5 550 392	3 %
Kazajstán	2019	5 375 940	3 %

*Nota.* Fuente: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024. Elaboración propia.

Como evidencia la Tabla 2, la Federación de Rusia mantuvo el liderazgo en las exportaciones de trigo en 2019, aunque su volumen cayó a aproximadamente 31.9 millones de toneladas, representando un 17 % del total. Estados Unidos escaló al segundo puesto con unos 27.1 millones de toneladas (15 %), superando a Canadá, que exportó 22.8 millones (12 %). Ucrania y Francia mostraron cifras muy similares, con cerca de 20.0 y 20.0 millones de toneladas cada uno, aportando un 11 % respectivamente. En un nivel intermedio, Argentina y Australia tuvieron participaciones más modestas —6 % y 5 %— con volúmenes de 10.5 y 9.6 millones de toneladas. Finalmente, Rumanía, Alemania y Kazajstán completan el grupo de los diez principales exportadores, cada uno con alrededor del 3 % del mercado global, lo que refleja una ligera diversificación respecto a 2018.

**Tabla 3**  
*Principales exportadores de trigo en 2020*

<b>Productor</b>	<b>Año</b>	<b>Valor [ton]</b>	<b>Participación [ %]</b>
Federación de Rusia	2020	37 267 014	19 %
Estados Unidos de América	2020	26 130 976	13 %
Canadá	2020	26 105 479	13 %
Francia	2020	19 792 597	10 %
Ucrania	2020	18 055 673	9 %
Australia	2020	10 400 418	5 %
Argentina	2020	10 196 931	5 %
Alemania	2020	9 259 470	5 %
Kazajstán	2020	5 198 943	3 %
Polonia	2020	4 684 731	2 %

*Nota.* Fuente: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024. Elaboración propia.

Como indica la Tabla 3, la Federación de Rusia recuperó parte de su volumen en 2020, alcanzando 37.3 millones de toneladas (19 %). Estados Unidos y Canadá quedaron muy cerca el uno del otro, con aproximadamente 26.1 millones cada uno (13 % cada uno). Francia aportó casi 19.8 millones (10 %), mientras que Ucrania se situó en torno a 18.1 millones (9 %). En un segundo nivel, Australia, Argentina y Alemania tuvieron cuotas similares de un 5 %, con volúmenes cercanos a los 10.3, 10.2 y 9.3 millones de toneladas, respectivamente. Finalmente, Kazajstán y Polonia cerraron el top diez con participaciones del 3 % y 2 %, lo que refleja una ligera ampliación de los actores relevantes en el mercado global.

**Tabla 4**  
*Principales exportadores de trigo en 2021*

<b>Productor</b>	<b>Año</b>	<b>Valor [ton]</b>	<b>Participación [ %]</b>
Federación de Rusia	2021	27 263 087	14 %
Australia	2021	25 563 035	13 %
Estados Unidos de América	2021	24 013 666	12 %
Canadá	2021	21 546 479	11 %
Ucrania	2021	19 394 935	10 %
Francia	2021	16 090 547	8 %
Argentina	2021	9 175 480	5 %
Alemania	2021	7 100 075	4 %
Rumanía	2021	6 907 746	4 %
India	2021	6 090 607	3 %

*Nota.* Fuente: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024. Elaboración propia.

Como muestra la Tabla 4, la Federación de Rusia siguió siendo el principal exportador en 2021, aunque su volumen disminuyó a 27.3 millones de toneladas (14 %). Le sigue Australia con 25.6 millones (13 %) y Estados Unidos con 24.0 millones (12 %). Canadá alcanzó 21.5 millones (11 %), mientras que Ucrania aportó 19.4 millones (10 %). Francia quedó en sexto lugar con 16.1 millones (8 %). En un nivel inferior, Argentina (5 %), Alemania (4 %), Rumanía (4 %) e India (3 %) completan el top diez de exportadores, reflejando una diversificación geográfica más amplia respecto a años anteriores.

**Tabla 5**  
*Principales exportadores de trigo en 2022*

<b>Productor</b>	<b>Año</b>	<b>Valor [ton]</b>	<b>Participación [ %]</b>
Australia	2022	28 781 090	17 %
Estados Unidos de América	2022	20 916 500	12 %
Francia	2022	20 151 547	12 %
Canadá	2022	18 548 392	11 %
Argentina	2022	12 938 182	8 %
Ucrania	2022	11 223 216	7 %
India	2022	6 798 598	4 %
Kazajstán	2022	6 345 733	4 %
Alemania	2022	6 221 112	4 %
Rumanía	2022	5 684 673	3 %

*Nota.* Fuente: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024. Elaboración propia.

Como evidencia la Tabla 5, Australia encabezó las exportaciones de trigo en 2022 con 28.8 millones de toneladas (17 %). Estados Unidos y Francia le siguieron con cifras muy similares, alrededor de 20.9 y 20.2 millones de toneladas respectivamente (12 % cada uno). Canadá aportó 18.5 millones (11 %), mientras que Argentina sumó casi 12.9 millones (8 %) y Ucrania cerca de 11.2 millones (7 %). En un nivel secundario, India, Kazajstán y Alemania comparten cada uno un 4 % del mercado, con volúmenes entre 6.3 y 6.8 millones de toneladas, y Rumanía cierra el top diez con un 3 % (5.7 millones), lo que refleja una distribución algo más equilibrada entre los principales exportadores.

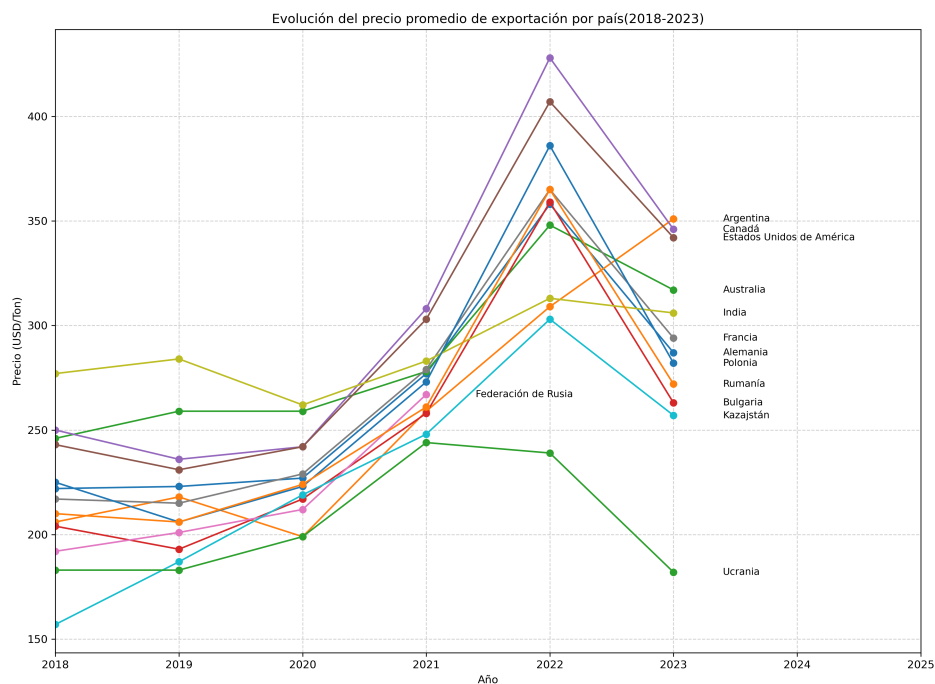
**Tabla 6**  
*Principales exportadores de trigo en 2023*

<b>Productor</b>	<b>Año</b>	<b>Valor [ton]</b>	<b>Participación [ %]</b>
Australia	2023	29 292 038	18 %
Canadá	2023	25 571 109	15 %
Estados Unidos de América	2023	17 941 722	11 %
Ucrania	2023	16 151 705	10 %
Francia	2023	13 476 663	8 %
Rumanía	2023	8 171 213	5 %
Kazajistán	2023	7 202 626	4 %
Polonia	2023	6 962 828	4 %
Alemania	2023	6 783 901	4 %
Bulgaria	2023	6 386 634	4 %

*Nota.* Fuente: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024. Elaboración propia.

Como muestra la Tabla 6, Australia se mantuvo al frente de las exportaciones de trigo en 2023 con 29.3 millones de toneladas (18 %). Le siguieron Canadá con 25.6 millones (15 %) y Estados Unidos con 17.9 millones (11 %). Ucrania aportó 16.2 millones (10 %) y Francia 13.5 millones (8 %). En posiciones secundarias, Rumanía alcanzó un 5 % del total, mientras que Kazajistán, Polonia, Alemania y Bulgaria comparten cada uno alrededor de un 4 %, lo que evidencia una mayor presencia de exportadores europeos en el *Top 10* de 2023.

**Figura 1**  
*Evolución del precio medio de exportación de trigo, 2018–2023*



*Nota: Datos de FAOSTAT (FAO, 2024). Elaboración propia.*

La Figura 1 presenta la evolución del precio promedio de exportación de trigo (USD/t) para los principales países entre 2018 y 2023. Se distinguen tres fases: de 2018 a 2020 los precios se mantuvieron relativamente estables (200–260 USD/t) con oscilaciones moderadas; a partir de finales de 2021 se produjo un aumento abrupto—alcanzando entre 370 y 430 USD/t en 2022—coincidiendo con el inicio y la escalada del conflicto Rusia–Ucrania; y en 2023 se registra un descenso parcial a niveles intermedios, reflejo de una moderación de las tensiones de mercado tras la fase más intensa de la guerra. Esta dinámica pone de manifiesto el impacto significativo del conflicto en la volatilidad de los precios globales de exportación de trigo.

### **0.9.2. Variación de los precios del trigo ruso (2022–2023)**

En enero de 2022, el trigo ruso se mantuvo estable a pesar de la incertidumbre geopolítica derivada de la situación en Kazajistán, un mercado clave para Rusia (Devitt & Polityuk, 2022). A finales de ese mes, los precios cayeron levemente hasta 325 USD/tonelada debido a las preocupaciones geopolíticas y a la debilidad del rublo, que redujo la competitividad del trigo ruso en los mercados internacionales (Devitt & Polityuk, 2022). En marzo de 2022, la prohibición de exportaciones a varios países de la UEEA y la disminución de la producción interna provocaron un aumento temporal de los precios al restringirse la oferta (Devitt & Polityuk, 2022). Además, la ausencia de datos para Rusia en FAOSTAT, reflejada en el gráfico, impidió evaluar con precisión la tendencia global de los precios de exportación de trigo ruso.

### 0.9.3. Principales importadores de trigo a nivel mundial

**Tabla 7**  
*Principales importadores de trigo en 2018*

Importador	Año	Valor [ton]	Participación [%]	Consumo [kg/año-pers]	Estimación [Miles]
Egipto	2018	12 144 514	8 %	137	104 717
Indonesia	2018	10 096 299	6 %	31	268 673
Italia	2018	7 453 326	5 %	148	60 336
Brasil	2018	6 817 138	4 %	54	205 431
Filipinas	2018	6 690 772	4 %	33	108 799
España	2018	6 028 088	4 %	101	46 952
Türkiye	2018	5 781 712	4 %	170	83 875
Japón	2018	5 652 191	4 %	47	127 003
Países Bajos	2018	5 538 731	4 %	89	17 369
Viet Nam	2018	5 158 196	3 %	18	95 747
México	2018	4 920 401	3 %	32	123 978
Bélgica	2018	4 328 195	3 %	111	11 400
República de Corea	2018	3 863 951	3 %	54	51 572
Marruecos	2018	3 851 009	2 %	181	35 652
Alemania	2018	3 750 191	2 %	87	83 253
Estados Unidos de América	2018	3 136 161	2 %	86	333 675
China, Continental	2018	2 876 129	2 %	71	1 416 413
Tailandia	2018	2 847 139	2 %	19	71 291

*Nota.* Fuentes: *FAOSTAT*, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024; *World Population Prospects* (United Nations, Department of Economic and Social Affairs, Population Division), 2024. Elaboración propia.

La Tabla 7 presenta los principales importadores de trigo en 2018. Egipto lideró con 12.1 millones de toneladas (8 %), un consumo medio de 137 kg/año-pers y una población estimada de 104.7 millones. Le siguieron Indonesia (10.1 millones; 6 %; 31 kg/año-pers; 268.7 millones) e Italia (7.5 millones; 5 %; 148 kg/año-pers; 60.3 millones). Brasil, Filipinas y España importaron entre 6.0 y 6.8 millones de toneladas (4 %), con consumos de 33–101 kg/año-pers. Turquía (170 kg/año-pers) y Japón (47 kg/año-pers) también alcanzaron un 4 %. El resto de países, como Países Bajos, Viet Nam, México y Bélgica, aportaron entre 2 % y 4 % de las importaciones, mostrando variaciones notables en consumo per cápita y tamaño de población.

**Tabla 8**  
*Principales importadores de trigo en 2019*

Importador	Año	Valor [ton]	Participación [%]	Consumo [kg/año-pers]	Estimación [Miles]
Indonesia	2019	11 009 400	7 %	31	271 231
Egipto	2019	10 424 423	7 %	142	106 647
Türkiye	2019	10 004 830	6 %	169	84 957
Italia	2019	7 474 381	5 %	144	60 219
Filipinas	2019	7 153 747	5 %	40	110 131
Brasil	2019	6 576 302	4 %	54	206 784
Japón	2019	5 331 435	3 %	46	126 824
España	2019	5 292 711	3 %	98	47 233
Países Bajos	2019	5 266 197	3 %	94	17 473
México	2019	4 804 872	3 %	34	125 169
Bélgica	2019	3 876 059	3 %	98	11 457
Marruecos	2019	3 844 806	3 %	178	36 028
República de Corea	2019	3 745 955	2 %	53	51 710
China, Continental	2019	3 204 807	2 %	70	1 421 605
Alemania	2019	3 190 973	2 %	74	83 484
Tailandia	2019	2 782 685	2 %	18	71 461
Viet Nam	2019	2 760 120	2 %	17	96 727

*Nota.* Fuentes: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024; *World Population Prospects* (United Nations, Department of Economic and Social Affairs, Population Division), 2024. Elaboración propia.

La Tabla 8 muestra los principales importadores de trigo en 2019. Indonesia y Egipto lideraron con 11.0 y 10.4 millones de toneladas (7 % cada uno), consumos de 31 y 142 kg/año-pers y poblaciones de 271.2 y 106.6 millones respectivamente. A continuación se ubica Turquía con 10.0 millones (6 %; 169 kg/año-pers; 85.0 millones) e Italia con 7.5 millones (5 %; 144 kg/año-pers; 60.2 millones). Filipinas, Brasil y Japón aportaron entre 3 % y 5 % del total, mientras que España, Países Bajos, México y Bélgica completan el grupo con aproximadamente 3 % cada uno, mostrando diferencias en consumo per cápita (34–98 kg/año-pers) y tamaño poblacional (11.5–206.8 millones).

**Tabla 9**  
*Principales importadores de trigo en 2020*

Importador	Año	Valor [ton]	Participación [%]	Consumo [kg/año-pers]	Estimación [Miles]
Indonesia	2020	10 299 702	6 %	35	273 748
Türkiye	2020	9 659 186	6 %	164	85 758
Egipto	2020	8 969 215	6 %	137	108 460
China, Continental	2020	8 151 572	5 %	71	1 425 436
Italia	2020	7 994 396	5 %	139	60 041
Brasil	2020	6 159 926	4 %	53	208 127
Filipinas	2020	6 150 365	4 %	45	111 478
Marruecos	2020	5 521 529	3 %	181	36 394
Japón	2020	5 373 862	3 %	46	126 575
Países Bajos	2020	4 296 917	3 %	89	17 602
España	2020	4 151 810	3 %	100	47 637
Alemania	2020	3 999 368	3 %	72	83 635
Bélgica	2020	3 852 303	2 %	91	11 524
República de Corea	2020	3 709 068	2 %	53	51 826
México	2020	3 698 769	2 %	34	126 357
Irán	2020	3 284 625	2 %	153	87 482
Viet Nam	2020	3 147 629	2 %	17	97 620
Tailandia	2020	3 096 832	2 %	16	71 583
Uzbekistán	2020	2 799 621	2 %	171	33 269
Pakistán	2020	2 490 628	2 %	102	232 776

*Nota.* Fuentes: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024; *World Population Prospects* (United Nations, Department of Economic and Social Affairs, Population Division), 2024. Elaboración propia.

La Tabla 9 muestra los principales importadores de trigo en 2020. Indonesia, Turquía y Egipto encabezaron las listas con alrededor de 10.3, 9.7 y 9.0 millones de toneladas respectivamente (6 % cada uno), presentando consumos per cápita de 35, 164 y 137 kg/año·pers y poblaciones de 273.7; 85.8 y 108.5 millones. China Continental e Italia siguieron con 8.2 y 8.0 millones (5 %), mientras que Brasil y Filipinas importaron aproximadamente 6.2 millones (4 %). En el grupo secundario, Marruecos, Japón y Países Bajos alcanzaron entre 3 % y 3 % de las importaciones totales, y Alemania, España y Bélgica aportaron cerca de 3 %–2 %, destacando además la presencia de Irán, Viet Nam, Tailandia, Uzbekistán y Pakistán con 2 % cada uno, reflejo de un mercado global diverso.

**Tabla 10**  
*Principales importadores de trigo en 2021*

Importador	Año	Valor [ton]	Participación [%]	Consumo [kg/año-pers]	Estimación [Miles]
Indonesia	2021	11 481 353	7 %	39	275 882
China, Continental	2021	9 711 387	6 %	71	1 426 776
Türkiye	2021	8 877 310	5 %	164	86 425
Italia	2021	7 298 488	4 %	140	59 784
Irán	2021	7 075 227	4 %	152	87 965
Brasil	2021	6 225 073	4 %	54	209 195
Filipinas	2021	6 029 337	4 %	44	112 685
Egipto	2021	5 873 256	4 %	134	110 171
Japón	2021	5 126 087	3 %	45	126 034
Países Bajos	2021	4 963 009	3 %	83	17 672
Viet Nam	2021	4 698 868	3 %	16	98 538
Marruecos	2021	4 668 548	3 %	181	36 774
México	2021	4 434 802	3 %	36	127 241
República de Corea	2021	4 422 092	3 %	54	51 891
Bélgica	2021	4 394 683	3 %	86	11 556
España	2021	4 017 658	2 %	101	47 722
Alemania	2021	3 921 491	2 %	74	83 623
Omán	2021	2 803 560	2 %	26	4 474
Tailandia	2021	2 675 271	2 %	16	71 700
Uzbekistán	2021	2 509 371	2 %	158	33 904
Pakistán	2021	2 486 191	2 %	104	237 228

*Nota.* Fuentes: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024; *World Population Prospects* (United Nations, Department of Economic and Social Affairs, Population Division), 2024. Elaboración propia.

La Tabla 10 presenta los principales importadores de trigo en 2021. Indonesia lideró con 11.5 millones de toneladas (7 %), un consumo medio de 39 kg/año·pers y una población estimada de 275.9 millones. A continuación, China continental importó 9.7 millones (6 %; 71 kg/año·pers; 1 426.8 millones) y Turquía 8.9 millones (5 %; 164 kg/año·pers; 86.4 millones). Italia e Irán comparten cada uno 4 % del total con 7.3 y 7.1 millones respectivamente, seguidos por Brasil y Filipinas con 4 % (6.2 y 6.0 millones). El grupo secundario incluye Egipto (5.9 millones; 4 %), Japón y Países Bajos (3 % cada uno) y otros países como Viet Nam, Marruecos, México y Corea del Sur, todos en torno al 3 %. Finalmente, Omán, Tailandia, Uzbekistán y Pakistán aportan cada uno un 2 %, reflejando un perfil de importación diversificado en cuanto a tamaño de mercado y consumo per cápita.

**Tabla 11**  
*Principales importadores de trigo en 2022*

Importador	Año	Valor [ton]	Participación [%]	Consumo [kg/año-pers]	Estimación [Miles]
China, Continental	2022	9 873 100	7 %	72	1 426 098
Indonesia	2022	9 459 252	6 %	25	277 635
Türkiye	2022	8 907 417	6 %	160	86 948
Egipto	2022	8 010 427	5 %	137	111 743
Italia	2022	6 916 967	5 %	137	59 674
Filipinas	2022	6 250 777	4 %	44	113 517
Marruecos	2022	6 007 647	4 %	179	37 134
Brasil	2022	5 716 592	4 %	54	209 906
Japón	2022	5 346 036	4 %	45	125 324
España	2022	4 926 807	3 %	108	47 749
República de Corea	2022	4 405 846	3 %	56	51 806
Alemania	2022	4 112 490	3 %	75	83 772
Países Bajos	2022	4 069 274	3 %	77	17 789
México	2022	3 938 944	3 %	37	128 055
Bélgica	2022	3 730 236	3 %	87	11 586
Uzbekistán	2022	2 792 063	2 %	152	34 584
Pakistán	2022	2 336 609	2 %	103	241 728

*Nota.* Fuentes: FAOSTAT, Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), 2024; *World Population Prospects* (United Nations, Department of Economic and Social Affairs, Population Division), 2024. Elaboración propia.

La Tabla 11 presenta los principales importadores de trigo en 2022. China continental encabezó la lista con 9.9 millones de toneladas (7 %), seguida por Indonesia (9.5 millones; 6 %) y Turquía (8.9 millones; 6 %). Egipto importó 8.0 millones (5 %), mientras que Italia y Filipinas aportaron 5 % y 4 % con 6.9 y 6.3 millones respectivamente. Marruecos y Brasil registraron importaciones de 6.0 y 5.7 millones (4 %), y Japón alcanzó 5.3 millones (4 %). España, República de Corea, Alemania y Países Bajos compartieron alrededor de un 3 % cada uno, con volúmenes entre 4.1 y 4.9 millones. Finalmente, México y Bélgica también alcanzaron un 3 % (3.9 y 3.7 millones), y Uzbekistán y Pakistán cerraron el top con 2 % cada uno, reflejando un conjunto variado de mercados nacionales.

## 0.10. Delimitación espacial y obtención de variables climáticas

El objetivo de esta sección es describir, con el mayor grado de detalle y transparencia metodológica, cómo se definieron las áreas efectivamente productoras de trigo en el continente americano y de qué manera se extrajeron las variables meteorológicas que alimentarán los modelos econométricos posteriores. Todo el procedimiento se apoya exclusivamente en fuentes de libre acceso y en herramientas de código abierto, garantizando la reproducibilidad completa del flujo de trabajo.

### 0.10.1. Identificación rigurosa del área productiva

#### **Fuente de producción y delimitación geoespacial.**

El análisis utiliza de base la producción de trigo por áreas disponible en el archivo `WHEA_PROD_2020.tif`, estimada por el *Spatial Production Allocation Model* (SPAM 2020). Este dataset, elaborado por IFPRI (Zhe Guo, Shuang Zhou & Liangzhi You), ofrece una resolución de 5 arcmin (aprox. 10 km en el ecuador) Lo cual permite tener mayor precisión para la estimación de las zonas geográficas relevantes.<sup>4</sup>

---

<sup>4</sup>IFPRI & University of Minnesota (2022). *Global Gridded Crop Production Statistics v2*.

### **Delimitación geoespacial.**

Para ajustar el límite espacial a las fronteras políticas relevantes, se descargaron las geometrías administrativas de *Natural Earth*<sup>5</sup> (escala 1:50 M). Estas geometrías se reproyectaron al sistema de coordenadas geográficas WGS 84 del ráster y se utilizaron como máscara de recorte. Con GDAL y GeoPandas se generaron dos mosaicos independientes:

- (i) **Cono Sur:** áreas dentro de Argentina y Brasil.
- (ii) **Cono Norte:** áreas dentro de Estados Unidos y Canadá.

Este procedimiento garantizó la coincidencia exacta de píxeles entre los datos vectoriales y raster, evitando saltos o pérdidas de información en las fronteras.

### **Selección áreas relevantes**

En cada subregión se seleccionaron únicamente las celdas con producción y se ordenaron en forma descendente. Luego, se acumuló la producción hasta cubrir al menos el 90 % del total regional, permitiendo un margen de tolerancia de 1 % en casos límite. El subconjunto resultante, denominado *TOP-90 %*, delimita los principales focos de agricultura comercial, excluyendo las áreas marginales de bajo impacto.

### **Cuantificación de la reducción de superficie.**

Para evaluar el ahorro computacional y la mejora en resolución climática, se comparó el área de la *bounding-box* (BB) original de cada ráster con el área de la máscara *TOP-90 %*. El procedimiento mostró una reducción máxima de 78 % en el Cono Norte, lo que evidencia una optimización sustancial del volumen de datos sin comprometer la representatividad de las zonas trigueras más relevantes.

---

<sup>5</sup><https://www.naturalearthdata.com/>

**Tabla 12**  
**Comparación de áreas geográficas entre el total y el bounding-box TOP-90 % por región**

<b>Región</b>	<b>Área total (km<sup>2</sup>)</b>	<b>Área TOP-90 % (km<sup>2</sup>)</b>	<b>Reducción ( %)</b>
Saskatchewan	629 150	351 526	44.1
Alberta	773 875	689 636	10.9
Kansas	207 434	207 434	0.0
Buenos Aires	486 757	–	–
North Dakota	184 330	178 046	3.4
Montana	401 355	314 312	21.7
Manitoba	1 001 615	222 608	77.8
Santa Fe	246 130	–	–
Washington	217 132	143 300	34.0
Paraná	272 252	230 612	15.3

*Nota.* Elaboración propia usando datos de SPAM 2020. Para *Buenos Aires* y *Santa Fe* se utilizó el área base completa, dado que los datos presentaban polígonos abiertos asociados a zonas geográficas conflictivas.

## 0.10.2. Extracción de clima diario (2018–2024)

### Variables elegidas y horizonte temporal.

Con el fin de caracterizar las condiciones atmosféricas que actúan directamente sobre el cultivo, se descargaron dos variables meteorológicas fundamentales—temperatura y precipitación—para cada *bounding-box*. Los datos provienen de la API pública [NASA-POWER](#), dicha aplicación ofrece series de datos climáticos a escala global desde 1984.

**Figura 2**  
*Variables climáticas*

Código	Descripción	Unidad
T2M	Temperatura media diaria del aire a 2 m	°C
PRECTOT	Precipitación total diaria	mm

*Nota: Cuadro de elaboración propia.*

El intervalo seleccionado comienza el 1 de enero de 2018 al 31 de diciembre de 2024, cubriendo siete ciclos agrícolas completos. Dicho periodo resulta suficientemente largo para detectar tendencias interanuales y, a la vez, reciente para reflejar la variabilidad climática relevante para la producción actual.

### Construcción de la rejilla de consulta.

A partir de los vértices de cada conjunto *bounding-box* se generó una malla regular con pasos  $\Delta\varphi = \Delta\lambda = 0.5^\circ$ , que coincide con la resolución nativa de NASA-POWER. Para cada nodo  $(\varphi_i, \lambda_j)$  se emitió una petición GET, indicando la fecha inicial, la fecha final y el formato de salida JSON. Las respuestas fueron parseadas y almacenadas en objetos `pandas DataFrame`, preservando metadatos y códigos de calidad.

**Agregación espacial diaria.**

Sea  $x_{k,t}$  el valor de la variable climática en la celda  $k$  el día  $t$ . El promedio espacial diario se obtuvo mediante

$$\bar{x}_t = \frac{1}{N_t} \sum_{k=1}^{N_t} x_{k,t},$$

Donde  $N_t$  es el número de nodos disponibles ese día (idéntico para T2M y PRECTOT, salvo celdas marinas excluidas). De este modo, se construyeron cuatro series temporales: temperatura y precipitación promedio para el Cono Sur, y las mismas dos series para el Cono Norte. Estas series agregadas constituyen la base climatológica de los modelos de correlación con rendimiento que se presentan posteriores.

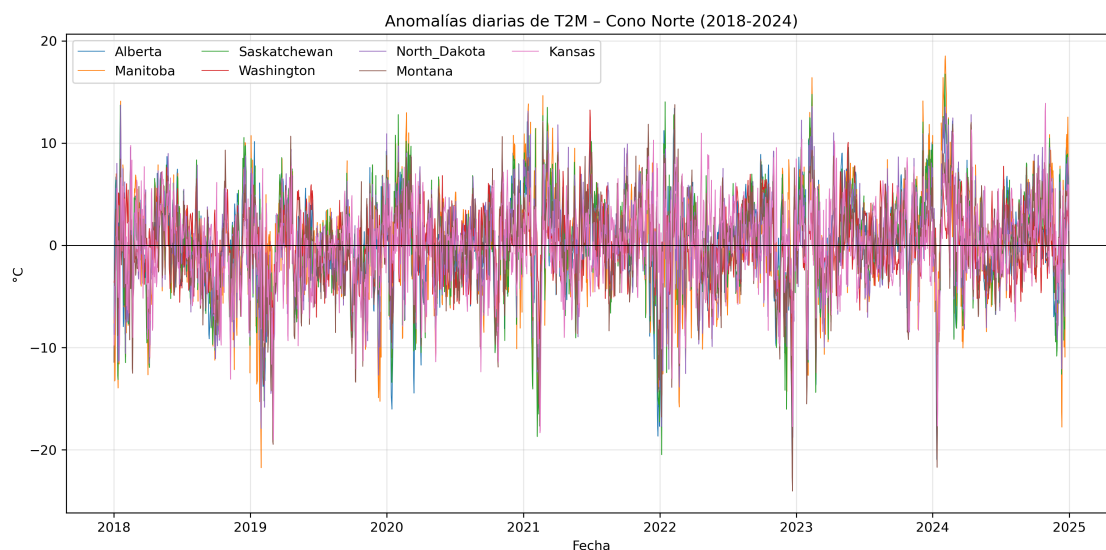
### **0.10.3. Ventajas y aportes del procedimiento**

El enfoque propuesto presenta una serie de beneficios clave para el análisis agroclimático. En primer lugar, mejora la relevancia geográfica al aplicar el criterio de agrupamiento por regiones de mayor producción, lo cual permite excluir áreas marginales y, en consecuencia, incrementar la señal climática-productiva en las zonas efectivamente utilizadas para el cultivo. Además, este procedimiento mejora la eficiencia computacional al reducir el volumen de datos climáticos procesados entre 0% hasta 77.8%, facilitando el manejo y análisis de la información. Desde una perspectiva agronómica, los promedios espaciales obtenidos a partir de esta metodología describen con mayor fidelidad las condiciones reales de cultivo, aportando representatividad técnica a los resultados. Finalmente, el enfoque favorece la reproducibilidad del estudio, ya que se basa exclusivamente en fuentes abiertas y accesibles, como SPAM 2020 y NASA-POWER, lo que permite replicar y extender el análisis en otros contextos o escalas geográficas.

#### **0.10.4. Series térmicas de anomalías Cono Norte**

Con base en el análisis de las series de temperatura diaria correspondientes a las provincias seleccionadas durante el periodo 2018–2024, se optó por trabajar con anomalías diarias calculadas como la diferencia entre cada valor observado y el promedio diario multi-anual del mismo día calendario. Esta metodología es ampliamente utilizada en la comunidad meteorológica y climatológica, ya que permite comparar regiones con climas estructuralmente distintos al eliminar sesgos asociados a diferencias topográficas o latitudinales (National Centers for Environmental Information, 2025). Además, el uso de anomalías mejora la detección de patrones comunes y aumenta la correlación entre series en comparación con los valores absolutos, lo cual ha sido discutido y ejemplificado en estudios metodológicos recientes (Hansen et al., 2010).

**Figura 3**  
*Evolución serie térmica de anomalías, 2018–2024*



*Nota:* Gráfica de elaboración propia con datos de la API NASA-POWER.

En la Figura 3 se presentan las anomalías diarias de temperatura media del aire a 2 metros (T2M) para siete regiones del Cono Norte durante el periodo 2018–2024. A pesar de la alta variabilidad diaria inherente a la escala temporal utilizada, es posible observar indicios de un comportamiento relativamente similar entre las series a lo largo del tiempo. En particular, destacan ciertos episodios de desviaciones térmicas intensas —tanto positivas como negativas— que parecen coincidir temporalmente entre regiones, esto motiva el análisis cuantitativo de correlación con el fin de explorar relaciones estadísticas entre las áreas geográficas implicadas.

### 0.10.5. Agrupamiento entre provincias por series térmicas

Para investigar si las anomalías térmicas diarias comparten una señal regional coherente, se aplicaron los siguientes pasos a la serie de temperatura media (**T2M**) centrada en su climatología diaria

1. **Correlaciones:** se calcularon los coeficientes de Pearson ( $r$ ) entre todas las parejas de provincias-estado. Aquellas con  $r \geq 0.70$  se consideraron *fuertemente sincronizadas*.
2. **Agrupamiento jerárquico:** se generó un dendrograma de vínculo promedio. El corte en  $r = 0.70$  definió *clusters* de comportamiento térmico homogéneo.
3. **Pruebas de causalidad de Granger:** para cada par dentro de un mismo *cluster* se evaluó la causalidad bidireccional (hasta 30 días de rezago) sobre la serie de anomalías  $\Delta T$ .

### Resultados principales.

- **Clúster 1 (“Rocosas”)**: Alberta–Montana [ $r = 0.77$ ]. La causalidad de Granger resultó bidireccional con  $p < 10^{-78}$  y rezago óptimo de 1 día en ambas direcciones, lo que sugiere un forzante sinóptico prácticamente simultáneo (probablemente la advección de masas de aire desde las Montañas Rocosas).
- **Clúster 3 (“Pradera”)**: Manitoba–Saskatchewan–North Dakota [ $r \in (0.86, 0.89)$ ]. Las tres series mostraron causalidad mutua al lag 1 día ( $p < 10^{-70}$ ). Además, se detectó una propagación sistemática Norte→Sur: Manitoba antecede a North Dakota con un rezago medio de 4–6 días.

Los estados de Washington y Kansas no alcanzaron el umbral de correlación ( $r < 0.70$ ) con ninguna otra jurisdicción, por lo que se trataron individualmente.

El test de Granger confirma que las series de temperatura de las provincias analizadas no sólo están fuertemente correlacionadas, sino que, además, presentan *capacidad predictiva mutua* en escalas de uno a pocos días. En la Tabla 13 se resumen los estadísticos más relevantes.

**Tabla 13**  
*Causalidad de Granger en los clusters térmicos*

Dirección	p-mín.	Lag óptimo (d)
<b>Clúster 1 — Alberta ↔ Montana</b>		
Alberta → Montana	$3.1 \times 10^{-209}$	1
Montana → Alberta	$2.4 \times 10^{-79}$	1
<b>Clúster 3 — “Pradera”</b>		
Saskatchewan → North Dakota	$2.0 \times 10^{-290}$	1
Saskatchewan → Manitoba	$3.5 \times 10^{-247}$	1
North Dakota → Saskatchewan	$2.4 \times 10^{-112}$	1
Manitoba → Saskatchewan	$5.7 \times 10^{-73}$	1
Manitoba → North Dakota	$9.6 \times 10^{-10}$	4
North Dakota → Manitoba	$1.6 \times 10^{-3}$	6

*Nota.* Datos diarios de temperatura ( $\Delta T$ ) descargados de NASA-POWER, comunidad AG (período 2018–2024). Los valores corresponden al  $p$ -valor mínimo y al rezago óptimo de la prueba de causalidad de Granger (máx. 30 días). Elaboración propia.

- a) **Clúster 1 (Alberta–Montana)**. Ambas series se “causan” recíprocamente con un rezago óptimo de un solo día y valores  $p \ll 10^{-70}$ , lo que implica una dinámica prácticamente simultánea. Este resultado es coherente con la rápida propagación de masas de aire desde la vertiente oriental de las Rocosas, donde los sistemas frontales afectan a ambas provincias casi al mismo tiempo.
- b) **Clúster 3 (Saskatchewan, Manitoba, North Dakota)**. Existe una malla causal densa a 1 día entre Saskatchewan y sus dos vecinos, confirmando que comparte la señal térmica dominante de la Pradera central. Además, se observa un *rezago coherente Norte → Sur*: Manitoba adelanta a North Dakota en 4–6 días, indicando la propagación meridional de ondas baroclínicas sobre la llanura interior. La bidireccionalidad Saskatchewan North Dakota refuerza su papel como “nodo puente” de la circulación sinóptica regional.

### 0.10.6. Extracción de *Drivers* Climáticos mediante EOF/PCA

El análisis de Funciones Ortogonales Empíricas (EOF), matemáticamente equivalente al Análisis de Componentes Principales (PCA), se ha consolidado como una herramienta esencial en climatología para descomponer campos espacio–temporales en modos ortogonales que facilitan la exploración de datos y la reducción de la dinámica a sus estructuras más relevantes. Monahan et al. (2009) destacan que, tras su introducción en meteorología por Lorenz (1956), este enfoque se ha convertido en un recurso estadístico fundamental en ciencias atmosféricas, oceánicas y climáticas para el análisis exploratorio y la simplificación de sistemas complejos (Monahan et al., 2009, p. 6501).

Para cada conjunto de anomalías de temperatura —Cluster 1 (Alberta–Montana) y Cluster 3 (Saskatchewan–Manitoba–North Dakota)— se calculará la matriz de covarianza de las series centradas y se extraerán sus valores y vectores propios. Con el fin de obtener un *driver* que concentre la mayor proporción de la variabilidad, se truncará la expansión EOF manteniendo únicamente el primer modo, conforme a la recomendación de conservar tantos modos como sea necesario para capturar la máxima varianza posible en espacios de dimensión reducida (Monahan et al., 2009, p. 6503). De este modo, el primer componente principal (PC1) servirá como índice representativo de las fluctuaciones térmicas dominantes en cada región y podrá emplearse en modelos econométricos, reduciendo de esta forma la cantidad de variables.

### 0.10.7. Resultados del PCA para Clusters de Temperaturas

Para el Cluster 1 (Alberta–Montana), el PCA arrojó dos componentes, donde el primer componente (PC1) concentra el 88.53 % de la variabilidad total y el segundo (PC2) aporta el 11.47 %. Las participaciones del PC1 son iguales en magnitud para Alberta y Montana (0.7071), pero de signo opuesto en PC2, lo que indica que el primer modo representa un patrón de variación conjunta y equilibrada entre ambas series. Dado que PC1 explica claramente la mayor parte de la varianza y refleja una contribución equitativa de las dos estaciones, se selecciona PC1 como el *driver* climático.

Para el Cluster 3 (Saskatchewan–Manitoba–North Dakota), el análisis reveló tres componentes. El PC1 explica el 91.49 % de la varianza, seguido de PC2 con 4.93 % y PC3 con 3.58 %. Las cargas de PC1 son similares para Manitoba (0.5787), Saskatchewan (0.5730) y North Dakota (0.5804), confirmando un patrón dominante común. Por su alta capacidad de reducción dimensional y su carácter representativo del comportamiento conjunto de las tres series, se adopta PC1 como *driver*.

**Tabla 14**

*Varianza explicada y cargas del primer modo para Cluster 1 (Alberta–Montana)*

	PC1 (88.53 %)	PC2 (11.47 %)
Alberta	0.7071	-0.7071
Montana	0.7071	0.7071

**Nota.** Tabla de elaboración propia.

**Tabla 15**

*Varianza explicada y cargas del primer modo para Cluster 3 (Saskatchewan–Manitoba–North Dakota)*

	PC1 (91.49 %)	PC2 (4.93 %)	PC3 (3.58 %)
Manitoba	0.5787	-0.4822	-0.6577
Saskatchewan	0.5730	0.8143	-0.0929
North Dakota	0.5804	-0.3231	0.7475

**Nota.** Tabla de elaboración propia.

### 0.10.8. Ventanas quincenales de precipitación Cono Norte

Para analizar la distribución de las precipitaciones y su relación con el desarrollo del cultivo de trigo, se adoptó un enfoque basado en *ventanas quincenales fijas*. Esta metodología permite una mayor claridad en la identificación de eventos climáticos extremos que podrían afectar críticamente al cultivo. La segmentación en bandas de 15 días fue construida considerando tanto las fases fenológicas del trigo como el tipo de trigo cultivado en las provincias del Cono Norte.

La humedad diaria estimada se calculó en base al procedimiento propuesto por Allen et al. (1998), quienes indican que la evapotranspiración del cultivo ( $ET_c$ ) bajo condiciones estándar se determina como el producto entre la evapotranspiración de referencia ( $ET_o$ ) y el coeficiente de cultivo ( $K_c$ ), según la siguiente ecuación:

$$ET_c = K_c \times ET_o \quad (9)$$

donde:

- $ET_c$  representa la *evapotranspiración del cultivo* en milímetros por día (mm/día), la cual refleja el requerimiento hídrico del cultivo bajo condiciones óptimas de crecimiento;
- $K_c$  es el *coeficiente de cultivo*, un valor adimensional que varía según la etapa de desarrollo del cultivo;
- $ET_o$  es la *evapotranspiración de referencia*, estimada para una cubierta de pasto de altura uniforme, bien regada y activa en crecimiento.


Para las provincias analizadas, caracterizadas por climas húmedos y subhúmedos, se adoptaron valores de  $ET_o$  en el rango de 1 a 4 mm/día, en concordancia con lo señalado en la FAO (Allen et al., 1998, p. 8).

En cuanto al coeficiente de cultivo  $K_c$ , se consideró un valor de 1.15 como representativo del trigo en condiciones normales, tal como se indica el documento FAO 56 (Allen et al., 1998, p. 112). Adicionalmente, para situaciones de clima extremo o alta velocidad de viento, se incorporó un valor reducido de  $K_c = 1.05$  como medida de sensibilidad ante el estrés ambiental (Allen et al., 1998, p. 124).


Con estos parámetros, y tomando un intervalo de acumulación de 15 días, los valores de evapotranspiración del cultivo ( $ET_c$ ) estimados dieron origen a bandas hídricas que varían aproximadamente entre 15 mm (mínimo) y 70 mm (máximo), reflejando las demandas hídricas potenciales del trigo en dicho contexto agroclimático.

Las ventanas se codifican así en las figuras subsiguientes: rojo (< 15 mm), verde (15–70 mm) y azul (> 70 mm). Esta clasificación permite (i) detectar con rapidez quincenas críticas para la implantación y sanidad del cultivo y (ii) comparar de forma homogénea el régimen pluvial entre provincias.


**Figura 4**  
*Precipitación quincenal fija (15 días) — Grupo 1*



(a) *Alberta*




(b) *Saskatchewan*




(c) *Manitoba*

*Nota:* Cuadro de elaboración propia con datos de la API NASA-POWER.


**Figura 5**  
*Precipitación quincenal fija (15 días) — Grupo 2*



**(a)** *North Dakota*




**(b)** *Montana*



**(c)** *Kansas*

*Nota:* Cuadro de elaboración propia con datos de la API NASA-POWER.

**Figura 6**  
*Precipitación quincenal fija (15 días) en Washington, 2018–2024*



*Nota: Elaboración propia a partir de datos descargados de la API NASA-POWER.*


La comparación detallada de las series climáticas con el precio internacional del trigo (contrato ZW, CBOT) revela una dinámica considerablemente más compleja que la sugerida por la mera existencia de causalidad interna entre variables meteorológicas. Durante el periodo 2018–2024 no se identificó, mediante análisis exploratorios básicos, un patrón ni una tendencia consistente que vincule de forma directa las anomalías pluviométricas o térmicas con las variaciones de la cotización ZW. Ello no implica descartar la relevancia del clima como factor de mercado, sino reconocer que su efecto puede quedar enmascarado por otros acontecimientos de gran magnitud. En particular, el estallido del conflicto Rusia–Ucrania provocó un impacto abrupto y severo en la serie de precios, de modo que las posibles señales climáticas quedaron solapadas bajo la volatilidad geopolítica.

Por consiguiente, el presente trabajo concluye la exploración climática en el plano descriptivo, dejando abierto el camino a estudios multivariados que incorporen variables de oferta mundial, logística y riesgo político para aislar adecuadamente la influencia meteorológica sobre los precios internacionales.


### 0.10.9. Series térmicas de anomalías Cono Sur

Se utiliza la misma metodología que en las provincias del Cono Norte para analizar las anomalías diarias de la temperatura, en este caso las zonas de estudio para el Cono Sur corresponde: Buenos Aires y Santa Fé (Argentina) y Paraná (Brasil). También se utiliza como periodo de referencia 2018–2024.


**Figura 7**  
*Evolución series térmicas, 2018–2024*



**(a)** *Buenos Aires*



**(b)** *Santa Fé (ARG)*



**(c)** *Paraná (BRA)*

*Nota.* Gráfico de elaboración propia a partir de los datos de NASA POWER.

Se calculó el coeficiente de correlación de Pearson entre las series de anomalías diarias de temperatura (T2M) para las provincias de Buenos Aires, Paraná y Santa Fé en el periodo 2018–2024. Como muestra la Tabla 16, las anomalías de Buenos Aires y Santa Fé presentan una correlación alta ( $r= 0.83$ ), mientras que Paraná registra correlaciones débiles con ambas provincias.

**Tabla 16**

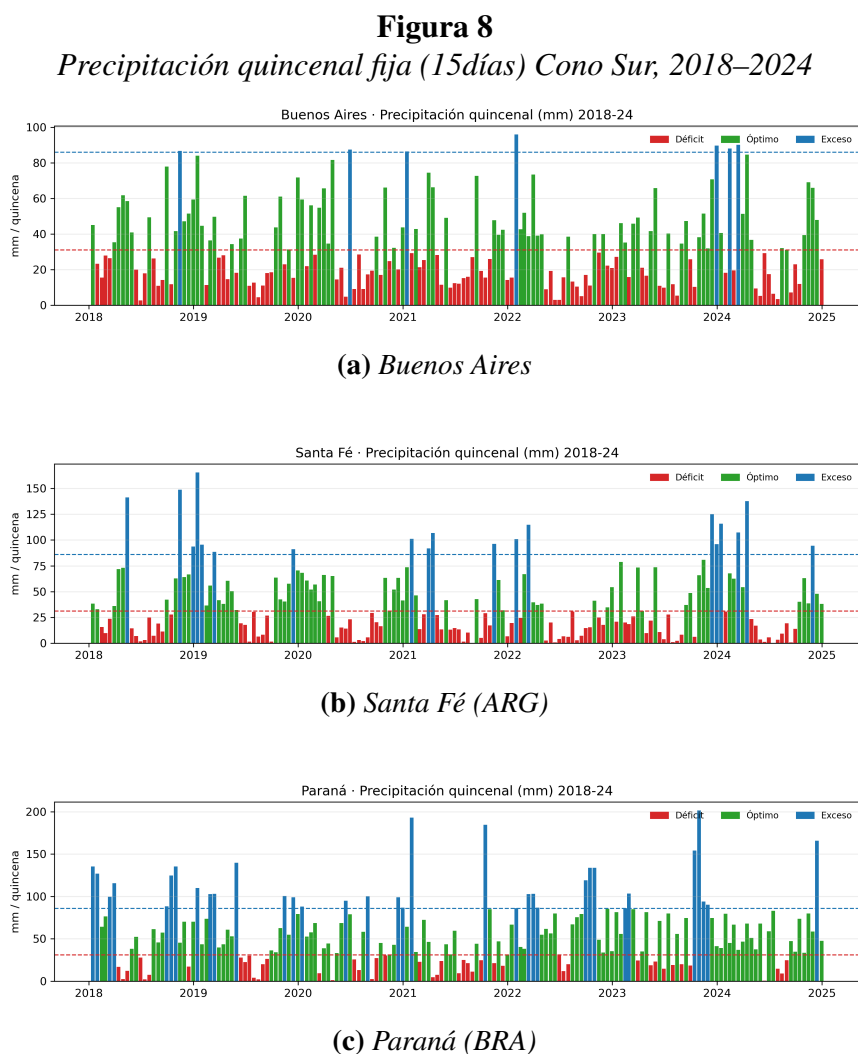
*Correlaciones de Pearson entre series de anomalías de T2M (2018–2024)*

	Buenos Aires	Paraná	Santa Fé
Buenos Aires	1.000	0.007	0.830
Paraná	0.007	1.000	0.245
Santa Fé	0.830	0.245	1.000

*Nota.* Tabla de elaboración propia.

### 0.10.10. Ventanas quincenales de precipitación Cono Sur

El análisis de precipitación quincenal para las provincias de Paraná (Brasil), Santa Fe y Buenos Aires (Argentina) replicó la metodología de ventanas fijas de 15 días aplicada en el Cono Norte. Sin embargo, se ajustaron los valores de evapotranspiración de referencia ( $ET_o$ ) conforme a las condiciones de climas húmedo a subhúmedo tropicales de esta región, desplazando la banda de zona de confort a un rango de confort hídrico [31 mm, 86 mm].



*Nota.* Gráfico de elaboración propia a partir de los datos de NASA POWER.

Pese a que es posible observar en Buenos Aires periodos de escasez hídrica —los cuales pueden afectar los rendimientos agrícolas—, no se identifica un patrón conjunto en la región que escape de la banda de confort hídrico [31 mm, 86 mm]; por ello, el análisis no se profundizará, dado que las series de precios internacionales del trigo (ZW) no evidencian a simple vista una influencia apreciable de los cambios de precipitación en el Cono Sur.

### **0.10.11. Diagnóstico series WTI, ZW y percepción de recesión**

Con el propósito de incorporar una variable que represente el *sentimiento de riesgo* del mercado, se exploraron diversas series disponibles en bases de datos de acceso abierto. No obstante, dado que la utilización de este tipo de indicadores es relativamente reciente, las plataformas consultadas presentan un conjunto limitado tanto en términos de frecuencia como de horizonte temporal. Por esta razón, se optó por utilizar el conjunto de datos abiertos de *Media Cloud Project*, el cual se basa en una amplia recopilación de periódicos estadounidenses y proporciona información desde el año 2020.

Se construyó una base de datos diaria ( $n = 1\,275$ ) que abarca desde el 1 de enero de 2020 hasta el 31 de diciembre de 2024 e incluye el precio spot del crudo WTI, el precio del trigo CBOT (ZW) y un índice que representa el *sentimiento de riesgo*.

El índice en cuestión es medido como el ratio de apariciones del término *recession* en los principales medios financieros de EE. UU. (Media Cloud Project, MIT Center for Civic Media and Berkman Klein Center, 2025). La matriz de correlaciones en niveles arrojó coeficiente  $|r| < 0.10$  entre *sentimiento de riesgo* (REC) y la serie internacional del precio del trigo (ZW), señalando una relación lineal prácticamente inexistente.

**Tabla 17**

*Matriz de correlación de Pearson*

	ZW	WTI	REC
ZW	1.000	0.687	0.079
WTI	0.687	1.000	-0.268
REC	0.079	-0.268	1.000

**Nota.** Elaboración propia. La tabla presenta los coeficientes de correlación de Pearson entre el precio del trigo (ZW), el precio del crudo WTI, y un índice de recesión emocional (REC).

Las pruebas de estacionalidad (ADF y KPSS) confirmaron que WTI, ZW y *sentimiento de riesgo* no son estacionarias en niveles, pero si en primeras diferencias  $I(1)$ . Con lo cual se realiza test de cointegración y se detecta que existe una única relación de largo plazo entres las tres variables.

**Tabla 18**

*Resultados de la prueba de cointegración de Johansen (método Trace)*

Hipótesis nula	Estadístico Trace	Valor crítico (95 %)
$r \leq 0$	35.13	29.80
$r \leq 1$	12.18	15.49
$r \leq 2$	3.15	3.84

Nota. Prueba de cointegración de Johansen realizada con  $\text{det\_order}=0$  y  $k_{\text{ar\_diff}} = 1$ . Tabla de elaboración propia.

## Comparativa de modelos VECM

En ambos modelos el Johansen Trace Test fija el rango en  $r = 1$ . La ecuación de equilibrio normalizada apenas cambia:

$$\text{VECM}(1) : ZW - 8.86 WTI - 28\,950 REC = \text{constante},$$

$$\text{VECM}(3) : ZW - 7.84 WTI - 22\,910 REC = \text{constante}.$$

### Velocidades de ajuste ( $\alpha$ )

- $\alpha_{ZW}$ : no significativo (débilmente exógeno) en ambos modelos.
- $\alpha_{WTI}$  y  $\alpha_{REC}$ : positivos y significativos, con magnitudes muy similares.

### Dinámica de corto plazo

En ambos modelos, los choques diarios en el precio del petróleo ( $\Delta WTI$ ) ejercen un impacto inmediato y muy significativo sobre el cambio diario del trigo ( $\Delta ZW$ ), con coeficientes cercanos a 1 en el rezago de un día (1.10 en VECM(1) y 0.999 en VECM(3), ambos  $p < 0.001$ ). Además,  $\Delta ZW$  muestra persistencia y reversión cuando se incluyen más rezagos: en VECM(3) aparecen efectos positivos de propio rezago a dos días (0.092,  $p < 0.01$ ) y una reversión significativa a tres días ( $-0.102$ ,  $p < 0.001$ ). Por su parte, el petróleo responde levemente a variaciones previas del trigo en un día (coeficientes de 0.010 y 0.011,  $p < 0.01$  en ambos modelos) y presenta reversión propia notable en los rezagos 2 y 3 en VECM(3) ( $-0.092$ ,  $p < 0.01$ ;  $-0.065$ ,  $p < 0.05$ ). El índice de recesión (REC) corrige sus propios choques de manera rápida y sostenida: en VECM(1) solo el rezago 1 es significativo ( $-0.200$ ,  $p < 0.001$ ), mientras que en VECM(3) los tres primeros rezagos muestran fuertes coeficientes de reversión ( $-0.293$ ,  $-0.216$ ,  $-0.176$ ; todos  $p < 0.001$ ), aunque sus intercambios con trigo y petróleo permanecen débiles o no significativos.

### Causalidad de Granger a corto plazo

Se estimó un VAR(2) sobre las primeras diferencias  $\Delta$ WTI,  $\Delta$ ZW y  $\Delta$ REC. Las pruebas de Wald–Granger ( $\alpha = 0.05$ ) arrojaron los siguientes resultados:

**Tabla 19**

*Resultados de Wald–Granger para  $\Delta$ WTI,  $\Delta$ ZW y  $\Delta$ REC*

Hipótesis nula ( $H_0$ )	$F$	$p$	Decisión
$\Delta$ WTI $\rightarrow$ $\Delta$ ZW	8.475	0.000	Rechazar
$\Delta$ REC $\rightarrow$ $\Delta$ ZW	1.685	0.186	No rechazar
$\Delta$ REC $\rightarrow$ $\Delta$ WTI	2.087	0.124	No rechazar
$\Delta$ ZW $\rightarrow$ $\Delta$ WTI	8.848	0.000	Rechazar

*Nota: Elaboración propia.*

Los contrastes de Granger evidencian una transmisión bidireccional e inmediata entre las variaciones diarias del crudo WTI y del trigo (ZW); en otras palabras, los movimientos en cualquiera de estos mercados se reflejan en el otro en un plazo máximo de dos días. Por el contrario, el índice *sentimiento de riesgo* —cuyo cálculo se basa en la frecuencia de menciones del término *recession* en la prensa económica de EE. UU.— no aporta poder predictivo, con lo cual sus rezagos no explican los cambios ni del trigo ni del petróleo dentro del mismo horizonte temporal.

Se da por concluido el análisis que incorpora al índice de riesgo, dado que este presenta una baja correlación con las variables ZW y WTI. Además, no participa de manera significativa en la dinámica de corto plazo, según lo evidenciado por la prueba de causalidad de Granger. Si bien forma parte de la relación de largo plazo identificada mediante pruebas de cointegración, su inclusión desplaza el foco del estudio, ya que dicha relación no está dominada por la evolución del precio del trigo, que constituye la variable de interés principal en el presente análisis.

### 0.10.12. Modelo VAR(3) en diferencias ( $\Delta WTI$ , $\Delta ZW$ )

Dado el análisis previamente expuesto, compuesto por las series del precio del trigo ( $ZW$ ), el precio del petróleo ( $WTI$ ) y el índice de emoción de riesgo, se procede a examinar de forma aislada la relación entre las variables  $ZW$  y  $WTI$ . Para ello, se estima un modelo VAR bivariado con el objetivo de identificar la dinámica conjunta entre ambas variables.

Primeramente, se realizó un análisis de estacionariedad de las series (ADF), concluyéndose que las mismas no son estacionarias en su nivel, pero sí tras aplicarles la primera diferencia (I(1)). A continuación, se aplicó la prueba de cointegración de Johansen, cuyos resultados indicaron que las series no se encuentran cointegradas. Posteriormente, se ajustó la cantidad de rezagos mediante el criterio de información de Akaike (AIC), evaluado hasta 12 rezagos, obteniéndose un valor óptimo de  $p = 3$ . En consecuencia, el análisis considera un modelo VAR(3) con término constante.

**Tabla 20**  
*Prueba de cointegración de Johansen —*  
*Trace (95 %)*

$r \leq i$	$\lambda_{\text{trace}}$	<b>Crit. 95 %</b>
0	14.7903	15.4943
1	3.6979	3.8415

Nota. Prueba de cointegración de Johansen realizada con  $\text{det\_order}=0$  y  $k_{\text{ar\_diff}} = 2$ . Tabla de elaboración propia.

### **Ecuación de $\Delta WTI$**

En la ecuación para  $\Delta WTI$  se observa que el rezago 1 de  $\Delta ZW$  presenta un coeficiente positivo y significativo,  $\beta = 0.00606$  ( $p = 0.041$ ), lo cual indica que un aumento en  $\Delta ZW$  tiende a impulsar levemente  $\Delta WTI$  al periodo siguiente. Asimismo, el rezago 2 de  $\Delta WTI$  muestra un coeficiente negativo y significativo,  $\beta = -0.06579$  ( $p = 0.007$ ), sugiriendo un efecto de reversión parcial en la dinámica de la variación del precio del petróleo. Por otra parte, los rezagos 2 y 3 de  $\Delta ZW$  resultan también negativos y significativos, con  $\beta_{L2, \Delta ZW} = -0.00593$  ( $p = 0.045$ ) y  $\beta_{L3, \Delta ZW} = -0.00669$  ( $p = 0.024$ ), lo que apunta a efectos retardados de la variación del precio del trigo que atenúan los cambios en  $\Delta WTI$ .

### **Ecuación de $\Delta ZW$**

En la ecuación correspondiente a  $\Delta ZW$ , ninguno de los coeficientes rezagados alcanzó significancia al nivel del 5 % (todos los  $p$ -valores fueron mayores que 0.05), lo que implica que no se detecta un patrón sistemático de retroalimentación de  $\Delta WTI$  sobre  $\Delta ZW$  dentro de los tres rezagos considerados.

**Estabilidad (raíces características)**

Se calcularon las raíces del polinomio característico del VAR(3), obteniéndose aproximadamente los valores 0.2588, 0.3021, 0.3646, 0.3646, 0.3787 y 0.3787. Al ser todas estrictamente menores que 1 en módulo, se confirma la estabilidad del sistema, lo que implica que cualquier choque transitorio tiende a disiparse con el tiempo.

**Autocorrelación de residuos (Portmanteau multivariante)**

Para evaluar la existencia de autocorrelación conjunta en los residuos se aplicó el test de Ljung–Box (Portmanteau) hasta el rezago 10. El estadístico obtenido fue

$$\chi_{10}^2 = 33.40, \quad \text{crítico } 95\% = 41.34, \quad p = 0.221.$$

Dado que  $\chi^2 = 33.40 < 41.34$  y  $p = 0.221 > 0.05$ , no se rechaza la hipótesis nula de ausencia de autocorrelación, lo que indica que los residuos se comportan como ruido blanco.

**Heterocedasticidad condicional (ARCH–LM univariante)**

Se realizó el test ARCH–LM con 5 rezagos en cada ecuación, obteniéndose:

$$\Delta WTI : \chi_5^2 = 163.11, \quad p < 0.001,$$

$$\Delta ZW : \chi_5^2 = 425.07, \quad p < 0.001.$$

En ambos casos  $p < 0.001$ , por lo que se rechaza la hipótesis de homocedasticidad condicional, revelando la presencia de efectos ARCH en los residuos, se sugiere que la volatilidad de los errores varía en el tiempo.

### Coefficientes con errores White/HCO

El siguiente cuadro resume los parámetros estimados con varianza robusta. Tras corregir la heterocedasticidad, únicamente el rezago dos de  $\Delta WTI$  resultó significativo al 5 %. La aparente causalidad del trigo sobre la serie WTI que se observó con estimadores OLS desaparece tras corregir la varianza.

**Tabla 21**

*Estimaciones robustas HCO del VAR(3)*

Ecuación	Parámetro	Coef.	se <sub>HCO</sub>	$t_{HCO}$
7* $\Delta WTI$	const	0.00659	0.03774	0.1745
	L1.WTI	-0.01934	0.03896	-0.4965
	L1.ZW	0.00606	0.00451	1.3422
	L2.WTI*	-0.06579	0.03360	-1.9582
	L2.ZW	-0.00593	0.00481	-1.2318
	L3.WTI	-0.02306	0.03261	-0.7072
	L3.ZW	-0.00669	0.00466	-1.4359
7* $\Delta ZW$	const	0.07020	0.31116	0.2256
	L1.WTI	0.18747	0.24913	0.7525
	L1.ZW	-0.00013	0.04699	-0.0028
	L2.WTI	-0.02509	0.25916	-0.0968
	L2.ZW	-0.04012	0.04507	-0.8902
	L3.WTI	-0.13243	0.27637	-0.4792
	L3.ZW	0.02621	0.03985	0.6577

Nota: errores estándar robustos obtenidos con `cov_white_simple` (White/HCO). \* Único coeficiente con  $|t_{HCO}| \approx 1.96$ , significativo al 5 % de forma marginal.

## 0.11. Desarrollo del modelo VECM

Se exploran las series diarias correspondientes a los precios del gas natural (NG), petróleo crudo WTI y trigo (ZW), todas expresadas en dólares para asegurar coherencia monetaria. La base de datos cuenta con 1770 observaciones diarias. Posteriormente, se procedió a identificar y eliminar valores atípicos utilizando el método de *Z-scores*, descartando observaciones que excedían tres desviaciones estándar respecto de la media.

Para asegurar que las series fueran aptas para un análisis VECM, se aplicaron pruebas de Augmented Dickey–Fuller (ADF). En niveles, todas las variables mostraron no estacionariedad ( $p$ -values  $>0.10$ ), mientras que en primeras diferencias resultaron claramente estacionarias ( $p$ -values  $<0.01$ ), confirmando que cada variable es integrada de orden uno. Por último, se consideró la prueba de cointegración de Johansen, detectándose que existe una única relación de largo plazo entre las tres series estudiadas en el horizonte considerado.

**Tabla 22**  
*Prueba de cointegración de Johansen —*  
*Trace (95 %)*

$r \leq i$	$\lambda_{\text{trace}}$	Crit. 95 %
0	43.42	29.80
1	11.93	15.49

Nota. Prueba de cointegración de Johansen realizada con `det_order=0` y `k_ar_diff=7`.  
Tabla de elaboración propia.

Con las variables integradas de orden uno, se estimó inicialmente un modelo VECM diario con ocho rezagos (siete en diferencias). Este modelo incluyó dos variables dummy exógenas para capturar efectos del conflicto bélico entre Rusia y Ucrania: *war\_peak* (24 de febrero - 30 de junio de 2022) y *war\_post* (1 de julio - 31 de diciembre de 2022). Este primer intento reveló problemas significativos de autocorrelación residual y heterocedasticidad condicional.

Se realizó un análisis de raíces unitarias a la matriz compañera del VAR de orden  $p = 8$ . De los 24 valores propios obtenidos, dos tenían módulo uno, lo cual coincide con la existencia de un único vector de cointegración ( $r = 1$ ), pues en un modelo con tres variables integradas de orden uno se esperan  $k - r = 2$  raíces-unidad. Las 22 raíces restantes presentaron módulo estrictamente menor que uno, indicando que las desviaciones transitorias respecto al equilibrio se disipan con el tiempo. Por tanto, el sistema de corto plazo es estable.

A continuación, se aplicó el test de Portmanteau para autocorrelación residual hasta 12 rezagos. Bajo la hipótesis nula de ausencia de autocorrelación, el estadístico resultó 102.5, superando el valor crítico de 58.12 ( $df = 42$ ,  $p < 0.001$ ), lo que conduce al rechazo de la normalidad de los residuos. Esto sugiere que aún queda dinámica no capturada por el modelo, por lo que podría ser necesario incluir rezagos adicionales o variables exógenas.

Finalmente, el test de heterocedasticidad condicional mediante tests ARCH-LM univariantes (5 rezagos) reveló significativa presencia de efectos ARCH en cada ecuación ( $\chi_{NG}^2 = 225.03$ ,  $\chi_{WTI}^2 = 95.80$ ,  $\chi_{ZW}^2 = 362.35$ ; todos con  $p < 0.001$ ). En conjunto, estos diagnósticos indican que, si bien el VECM con  $p = 8$ ,  $k_{ar\_diff} = 7$  y  $r = 1$  es estable, los residuos presentan autocorrelación y heterocedasticidad.

## Eliminación variable WTI

Al eliminar WTI, el Portmanteau-test para autocorrelación residual hasta 12 rezagos sigue rechazando la ausencia de autocorrelación con estadístico = 48.00 ( $df = 18$ ,  $p < 0.001$ ), lo que equivale a una razón de  $48.00/18 \approx 2.67$ , frente a  $102.5/42 \approx 2.44$  en el modelo con WTI. Esto muestra que, a pesar de la simplificación, el nivel de autocorrelación en los errores permanece elevado. Además, la heterocedasticidad condicional en NG empeora ligeramente (ARCH-LM NG:  $\chi^2$  pasa de 225.03 a 233.86), mientras que en ZW se mantiene prácticamente idéntica (362.35 vs. 363.33).

La prueba de Johansen confirma un único vector de cointegración ( $r = 1$ ) en ambos modelos, pero el coeficiente de equilibrio ( $\beta$ ) entre NG y ZW se aplana de  $-1.9864$  a  $-0.7233$ . Un  $|\beta|$  menor implica una relación de largo plazo menos pronunciada y, por tanto, un argumento económico menos robusto. Asimismo, el coeficiente de ajuste de NG ( $\alpha$ ) disminuye en magnitud (de  $-0.0282$  a  $-0.0201$ ), lo que refleja una velocidad de corrección al equilibrio más lenta.

En el modelo sin WTI, las variables binarias que delimitan los periodos de conflicto —war\_peak (pico de guerra) y war\_post (posguerra)— dejan de influir de manera estadísticamente significativa en el precio de NG: sus valores-p ( $p \approx 0.40$  y  $p \approx 0.91$ ) están muy por encima del umbral habitual de 0.05. En cambio, cuando WTI está incluido, la dummy war\_post tenía un efecto claro sobre ZW ( $p \approx 0.02$ ), sin la variable WTI los indicadores de guerra pierden relevancia en la explicación de NG y ZW.

La variable WTI actuaba como canal de shocks, impactando directamente a NG. Al excluirlo, la varianza residual de NG aumenta (reflejado en un ARCH-LM mayor) y parte de la dinámica queda sin capturar, introduciendo riesgo de sesgo por variable omitida.

### Reducción de rezagos modelo diario

En el VECM con sólo  $p = 3$  rezagos y  $k_{ar\_diff} = 2$ , la prueba de Johansen basada en el estadístico de traza al 5 % de significancia confirma la existencia de un único vector de cointegración ( $r = 1$ ). En particular, para  $r \leq 0$  se obtiene un estadístico de 48.09 que supera el valor crítico de 29.80, mientras que para  $r \leq 1$  el estadístico es 12.11, por debajo del umbral de 15.49. Este resultado coincide con los modelos previos de mayor orden y garantiza que las tres series comparten una relación de largo plazo. Además, el análisis de estabilidad mediante los valores propios de la matriz compañera revela dos raíces-unidad (esperadas para  $k - r = 2$ ) y seis restantes con módulo menor que 1, lo cual indica que las desviaciones transitorias del equilibrio se disipan con el tiempo y el sistema es estable.

A pesar de esta estabilidad de largo plazo, los diagnósticos de los residuos empeora al reducir el número de rezagos. El Portmanteau-test hasta 12 rezagos da un estadístico de 201.2 frente a un crítico de 109.8 ( $df = 87$ ,  $p < 0.001$ ), lo que evidencia autocorrelación significativa no corregida y un ajuste de corto plazo inferior al modelo con más rezagos. Asimismo, los tests ARCH-LM univariantes con 5 rezagos para NG, WTI y ZW muestran  $\chi^2 = 237.19$ , 112.72 y 354.51 respectivamente (todos  $p < 0.001$ ), lo cual refleja persistente heterocedasticidad condicional.

En conjunto, aunque el modelo con  $p = 3$  sigue capturando la cointegración y la estabilidad dinámica, empeora de manera notable los residuos: la autocorrelación y la heterocedasticidad aumentan.

### **0.11.1. Modelo VECM semanal**

Para simplificar el modelo y reducir el ruido diario, las series de precios se agregaron a frecuencia semanal. El procedimiento consistió en promediar los valores de lunes a viernes y asignar ese promedio al viernes de cada semana, de modo que las 1673 observaciones diarias se convirtieron en 357 observaciones semanales por variable.

Las variables ficticias que capturan el impacto de la guerra se consideraron en la misma frecuencia: la dummy asociada al conflicto entre Rusia y Ucrania vale 1 durante las semanas comprendidas entre el 24 de febrero al 30 de junio de 2022, coincidiendo con la fase más intensa del conflicto, mientras que la variable pos conflicto adopta el valor 1 en las veinticuatro semanas siguientes, del 1 de julio al 31 de diciembre de 2022, con el fin de representar el periodo posterior al *peak* inicial.

Se aplicaron pruebas de raíces unitarias (*ADF* y *KPSS*) a las series semanales del precio del crudo WTI, del gas natural (NG) y del trigo CBOT (ZW). Los resultados indicaron que ninguna serie es estacionaria en nivel; sin embargo, todas se vuelven integradas de primer orden,  $I(1)$ , tras una primera diferenciación. Con este antecedente, se utilizó la prueba de cointegración de Johansen, la cual confirmó la existencia de una única relación de equilibrio de largo plazo que vincula simultáneamente a las tres variables.

**Tabla 23**

*Prueba de cointegración de Johansen — Trace (95 %)*

$r \leq i$	$\lambda_{\text{trace}}$	Crit. 95 %
0	41.78	29.80
1	12.98	15.49

Nota. Prueba de cointegración de Johansen realizada con `det_order=0` y `k_ar_diff=2` ( $p = 3$  rezagos semanales). Tabla de elaboración propia.

En la relación de equilibrio de largo plazo, el peso asignado al crudo WTI casi triplica al del trigo ZW, lo que evidencia la dominancia del primero en el vector cointegrante:

$$NG_t - 1.91 WTI_t - 0.63 ZW_t = 0.$$

En la etapa de corrección de errores, los coeficientes  $\alpha$  muestran que el gas natural ( $NG$ ) y el trigo ( $ZW$ ) son las variables que efectivamente restauran el equilibrio:  $\alpha_{NG} = -0.075$  y  $\alpha_{ZW} = 0.132$  (ambos con  $p < 0.01$ ). En términos sencillos, ello implica que, cada semana, el precio del gas corrige cerca del 7.5 % de cualquier desajuste y el precio del trigo corrige aproximadamente un 13 %. El crudo ( $WTI$ ), en cambio, presenta un coeficiente no significativo ( $\alpha_{WTI} = 0.003$ ,  $p = 0.23$ ), por lo que actúa como referente de largo plazo.

La dinámica de corto plazo refuerza esta lectura. El gas natural exhibe inercia propia ( $\Delta NG_{t-1}$  positivo) y reacciona a los choques del crudo con dos semanas de retraso ( $\Delta WTI_{t-2}$  negativo). El crudo, por su parte, sólo se ve influido por su propio rezago inmediato, mientras que el trigo mantiene un patrón autoregresivo simple ( $\Delta ZW_{t-1}$  positivo) sin impactos cruzados significativos.

El análisis de raíces del polinomio característico confirma que el modelo es dinámicamente estable: se observan exactamente dos raíces–unidad, tal como prescribe  $k - r = 2$ , y las restantes se ubican dentro del círculo unitario  $|\lambda| < 1$ . Esta condición garantiza que los impulsos no provocan trayectorias explosivas y que el sistema converge hacia su equilibrio de largo plazo.

No obstante, el test Portmanteau aplicado hasta 12 rezagos rechaza la hipótesis de ausencia de autocorrelación ( $p = 0.000$ ), lo que revela dependencia serial remanente en los residuos. Este resultado sugiere incorporar rezagos adicionales, efectos de calendario o dummies estacionales para absorber la dinámica faltante.

Asimismo, la heterocedasticidad condicional es significativa: el test ARCH–LM univariante de orden 5 detecta varianza cambiante en el gas natural ( $\chi^2 = 48.69$ ,  $p < 0.001$ ) y en el trigo ( $\chi^2 = 30.72$ ,  $p < 0.001$ ), y en menor medida en el crudo ( $\chi^2 = 15.14$ ,  $p = 0.010$ ).

Por último, las dummies exógenas *war\_peak* (12 semanas) y *war\_post* (24 semanas) capturan adecuadamente el choque bélico de 2022, resultando significativas solo en la ecuación de ZW y sin comprometer la estabilidad del sistema.

## Reducción rezagos

Al reducir los rezagos del VECM semanal de  $p = 3$  a  $p = 2$  ( $k_{ar\_diff} = 2 \rightarrow 1$ ), la estructura de largo plazo permanece prácticamente inalterada: el rango de cointegración sigue siendo  $r = 1$  y los coeficientes del vector cointegrante se mantienen en  $\beta_{WTI} \approx -1.91$  y  $\beta_{ZW} \approx -0.62$ . De igual modo, la matriz de velocidades de ajuste muestra variaciones mínimas ( $\alpha_{NG}$  pasa de  $-0.075$  a  $-0.080$  y  $\alpha_{ZW}$  de  $0.132$  a  $0.131$ ), lo que indica que el gas y el trigo continúan corrigiendo los desajustes semanales, mientras que el crudo permanece débilmente exógeno al no presentar un  $\alpha$  significativo.

No obstante, la parsimonia añadida no mejora la calidad de los residuos. El estadístico Portmanteau aumenta de  $187.4$  a  $200.7$  y se mantiene el rechazo de la hipótesis de ausencia de autocorrelación a  $12$  rezagos ( $p < 0.001$ ), evidenciando dependencia serial remanente. La heterocedasticidad condicional persiste: las pruebas ARCH-LM siguen siendo altamente significativas para  $NG$  y  $ZW$ , y moderadamente significativas para  $WTI$ . Aun así, el modelo conserva la estabilidad dinámica.

Finalmente, la reducción de rezagos conserva la relación de equilibrio y las velocidades de corrección, pero no resuelve —e incluso acentúa— la autocorrelación residual y deja intacta la heterocedasticidad.

### 0.11.2. Aproximación del modelo del trigo a nivel nacional

Con el propósito de examinar la dinámica de los factores que influyen en el precio del trigo en el mercado chileno, se compiló un conjunto de  $n = 357$  observaciones semanales correspondientes al período 2018–2024, periodicidad determinada por la disponibilidad de datos locales. Dado que el mercado chileno carece de una referencia *spot* diaria comparable con las cotizaciones internacionales de Argentina o Brasil, se decidió aproximar el precio interno mediante productos de consumo masivo derivados del grano. El procedimiento fue el siguiente:

1. **Recopilación de datos.** Se extrajeron del portal de la Oficina de Estudios y Políticas Agrarias (ODEPA)<sup>6</sup> las series semanales de precios al consumidor —expresados en CLP/kg— correspondientes a harina de trigo, pastas alimenticias tipo *spaghetti* N°5 (presentación de 400 g) y cuatro variedades tradicionales de pan (marraqueta, marraqueta integral, hallulla y pan amasado) para la Región Metropolitana (formatos de venta en supermercados) medido en kg.
2. **Preprocesamiento y depuración.** Se eliminaron registros atípicos evidentes (saltos  $>3$  desviaciones estándar respecto de la media móvil de cuatro semanas).
3. **Homogeneización de la frecuencia.** Dado que las cotizaciones de Rosario (Argentina) y Paraná (Brasil) están en frecuencia diaria, se remuestrearon a frecuencia semanal usando el precio medio de cierre de cada viernes, de modo de alinear todas las series en una misma escala temporal ( $T = \text{semana}$ ).

---

<sup>6</sup><https://www.odepa.gob.cl/precios/consumidor>

#### 4. Análisis de colinealidad y agregación.

- a) *Harinas*. El coeficiente de correlación de Pearson entre las diferentes marcas y tipos de harina superó 0.98 ( $p < 0.001$ ), indicando colinealidad casi perfecta. Se generó, por tanto, un índice de **precio medio de la harina** ( $\overline{\text{Harina}}_t$ ) calculado como el promedio aritmético simple de todas sus variantes.
- b) *Panes*. Las seis combinaciones por formato y presentación mostraron correlaciones altas, aunque sensiblemente menores que en el caso de las harinas (rango 0.78–0.87). Para simplificar la dimensionalidad y conservar información representativa del consumo, se construyó el **precio medio del pan** ( $\overline{\text{Pan}}_t$ ) a partir del promedio ponderado de los cuatro productos especificados.

#### 5. Definición del vector de estudio.

El conjunto final de variables semanal queda definido como

$$\mathbf{y}_t = (\text{Trigo}_{\text{BRA},t}, \text{Trigo}_{\text{ARG},t}, \overline{\text{Harina}}_t, \overline{\text{Pan}}_t, \text{Spaghetti}_t)$$

donde:

**Trigo<sub>BRA,t</sub>** Precio FOB Paraná (USD/t).

**Trigo<sub>ARG,t</sub>** Precio FOB Rosario (USD/t).

**$\overline{\text{Harina}}_t$**  Precio medio harina (CLP/kg).

**$\overline{\text{Pan}}_t$**  Precio medio pan (CLP/kg).

**Spaghetti<sub>t</sub>** Precio spaghetti N°5 (CLP/0,4 kg).

### Análisis 1: Modelo con todas las variables

Esta sección examina las series de tiempo semanales del **precio promedio del pan**, el **precio medio de las harinas** y el **precio de los espaguetis** recopilados en supermercados de la Región Metropolitana (Santiago de Chile), junto con el **precio representativo del trigo** negociado en Paraná, Brasil, y el precio del trigo argentino negociado en la Bolsa de Rosario. Tras una inspección gráfica preliminar, se aplicaron las pruebas de raíz unitaria de Dickey–Fuller aumentada y KPSS para evaluar la estacionariedad en niveles; ninguna serie resultó estacionaria, pero todas alcanzaron estacionariedad después de la primera diferencia. En consecuencia, se evaluó la cointegración mediante la prueba de trazas de Johansen, la cual confirmó la existencia de al menos un vector de cointegración entre las variables. Dada esta evidencia, se procedió a estimar un *Vector Error-Correction Model* (VECM) que permite capturar simultáneamente la dinámica de corto plazo y la relación de equilibrio de largo plazo entre los precios analizados.

**Tabla 24**  
*Prueba de cointegración de Johansen —*  
*Trace (95 %)*

$r \leq i$	$\lambda_{\text{trace}}$	Crit. 95 %
0	81.28	69.82
1	39.74	47.85

Nota. Prueba de cointegración de Johansen con  $\text{det\_order}=0$  y  $\text{k\_ar\_diff}=1$  ( $p = 2$  rezagos semanales). Tabla de elaboración propia.

El test de trazas de Johansen indicó evidencia de cointegración entre los cinco precios analizados. Con un rezago en primeras diferencias ( $k_{ar\_diff} = 1$ ) y sin términos deterministas adicionales, la hipótesis nula de  $r \leq 0$  vectores de cointegración se rechazó,  $\lambda_{trace} = 84.70 > 69.82$  (valor crítico al 95 %), mientras que la hipótesis  $r \leq 1$  no fue rechazada,  $\lambda_{trace} = 38.44 < 47.85$ , estableciendo un rango  $r = 1$ .

La relación de equilibrio de largo plazo se estimó como:

$$PAN_t - 1.27 HARINA_t - 1.04 PASTA_t + 0.01 ARG_t - 0.01 BRA_t \approx 0,$$

donde los coeficientes negativos sobre harina y pasta reflejan sustitución casi proporcional con el precio del pan, y los parámetros sobre los precios externos capturan la transmisión internacional.

Las *velocidades de ajuste* ( $\alpha$ ) indican qué fracción de la brecha con el equilibrio de largo plazo corrige cada variable en una semana. Para los precios internos, los coeficientes fueron positivos y relativamente pequeños— $\alpha_{PAN} = 0.035$  ( $z=2.36$ ,  $p=0.018$ ),  $\alpha_{HARINA} = 0.039$  ( $z=3.77$ ,  $p<0.001$ ) y  $\alpha_{PASTA} = 0.019$  ( $z=2.80$ ,  $p=0.005$ )—lo que significa que, tras un shock, el pan corrige cerca de 3.5 % del desequilibrio por semana, la harina 3.9 % y la pasta 1.9 %.

El coeficiente de corrección  $\alpha_{\text{ARG}} = -11.88$  ( $z = -3.60$ ,  $p < 0.001$ ) para el precio FOB argentino indica un ajuste *inverso* al desvío respecto del equilibrio. En términos simples, si el diferencial entre los precios internos y externos (*spread*) se agranda porque los valores locales suben por encima de lo que dicta la relación de largo plazo, el precio argentino tiende a bajar de forma pronunciada en la semana siguiente, ayudando a cerrar esa brecha.

Por el contrario, el precio del trigo en Paraná exhibió un coeficiente positivo y elevado,  $\alpha_{\text{BRA}} = 6.81$  ( $z = 3.88$ ,  $p < 0.001$ ). Esto significa que cuando el *spread* se amplía, la cotización brasileña se ajusta en la *misma* dirección que los precios internos.

En la dinámica de corto plazo, la evidencia de transmisión inmediata fue limitada: sólo el propio rezago del precio del pan ( $\beta = -0.239$ ,  $p = 0.016$ ) y el rezago del precio brasileño ( $\beta = -0.001$ ,  $p = 0.040$ ) resultaron estadísticamente significativos. El coeficiente del pan indica un efecto de reversión parcial—si el pan sube una semana, tiende a moderarse la siguiente—mientras que el coeficiente del precio Paraná apunta a un ajuste tenue, pero en la misma dirección que el movimiento doméstico. La falta de significancia en los demás coeficientes sugiere que un solo rezago puede no captar del todo las interacciones semanales.

Los diagnósticos revelaron problemas de forma: el portmanteau multivariante rechazó la hipótesis de residuos no autocorrelados,  $\chi^2(270) = 390.30$ ,  $p < 0.001$ ; la prueba de normalidad de Jarque–Bera multivariante también resultó significativa,  $\chi^2(10) = 2.49 \times 10^4$ ,  $p < 0.001$ ; y las pruebas ARCH–LM evidenciaron heterocedasticidad condicional en todas las series consideradas—pan:  $\chi^2(5) = 55.30$ ,  $p < 0.001$ ; harina:  $\chi^2(5) = 38.39$ ,  $p < 0.001$ ; pasta:  $\chi^2(5) = 11.94$ ,  $p = 0.036$ ; FOB-Argentina:  $\chi^2(5) = 15.12$ ,  $p = 0.010$ ; y Paraná-Brasil:  $\chi^2(5) = 18.37$ ,  $p = 0.003$ . No obstante, la estructura de raíces del polinomio característico fue consistente con la teoría: se observaron cuatro raíces unidad ( $|\lambda| = 1$ )—las esperadas para  $K - r = 4$ —y el resto dentro del círculo unidad, lo que confirma la estabilidad cointegrada del sistema.

## **Incremento de rezagos en el modelo**

Para contrastar los efectos de la longitud de memoria, se estimó un modelo VECM con tres rezagos ( $k_{ar\_diff}=3$ ). La relación de cointegración se mantuvo en  $r = 1$ .

### **Diagnósticos de residuos**

En el modelo de un rezago la autocorrelación multivariante fue pronunciada,  $\chi^2(270) = 390.30$ ,  $p < 0.001$ , mientras que con tres rezagos se redujo a  $\chi^2(220) = 287.80$ ,  $p = 0.001$ . La no normalidad también disminuyó (Jarque–Bera multivar.:  $2.49 \times 10^4$  frente a  $1,10 \times 10^4$ ). En cuanto a heterocedasticidad (ARCH–LM, 5 rezagos), las cinco series resultaron significativas en el modelo corto; al incluir tres rezagos, el estadístico de Paraná se elevó a  $\chi^2(5) = 9.77$  con  $p = 0.082$ , de modo que solo esta serie dejó de mostrar heterocedasticidad condicional al 5 % de significancia.

### **Velocidades de ajuste**

Los coeficientes  $\alpha$  de PAN, HARINA y PASTA aumentaron ligeramente, sugiriendo correcciones algo más rápidas. El ajuste de Paraná, aunque sigue positivo, perdió significancia estadística ( $p = 0.137$ ), lo que apunta a que su influencia de largo plazo se reparte entre rezagos adicionales.

### **Estabilidad estructural**

En ambos modelos se observaron las cuatro raíces unidad teóricas ( $|\lambda| = 1$ ) y el resto dentro del círculo unidad, confirmando la estabilidad cointegrada.

Aumentar los rezagos reduce la autocorrelación y atenúa la heterocedasticidad (sobre todo en Paraná) sin alterar la relación de equilibrio, aunque a costa de mayor complejidad.

## 0.12. Resultados del Modelo VAR-X(3) con Variable Binaria

Para examinar la dinámica de corto plazo se estimaron modelos VAR que incluyeron inicialmente cinco variables: el precio promedio del pan, el precio del trigo brasileño, el precio del trigo argentino, el precio medio de la harina y el precio de la pasta. Tras probar órdenes de rezago  $p = 3$  a  $p = 5$ , los test de autocorrelación multivariante (Portmanteau) mostraron que la exclusión de la harina y la pasta reducía significativamente la dependencia serial de los residuos. Por lo cual, se decidió implementar un modelo con tres variables— precio local del pan, precio del trigo Paraná y precio del trigo Argentina—que mantiene la capacidad explicativa necesaria y presenta diagnósticos de autocorrelación aceptables.

A continuación, se presentan los resultados del modelo VAR-X(3) con la inclusión de la dummy de guerra (24 de febrero de 2022 a 30 de abril de 2022), que se introdujo para capturar el impacto de la crisis de Ucrania en los precios de los productos. El modelo incluye las variables PAN (precio del pan en Santiago), ARG (precio del trigo en Rosario, Argentina) y BRA (precio del trigo en Paraná, Brasil).

**Tabla 25**  
*Ecuación PAN — VAR(3)*

Parámetro	Coef.	Error std.	<i>t</i>	<i>p</i>
const	0.000345	0.002870	0.120	0.904
DUM_GUERRA	0.007888	0.018998	0.415	0.678
L1.PAN	-0.160060	0.053739	-2.978	0.003**
L1.ARG	0.000381	0.000240	1.590	0.112
L1.BRA	-0.000609	0.000484	-1.258	0.209
L2.PAN	-0.058939	0.055138	-1.069	0.285
L2.ARG	0.000352	0.000240	1.465	0.143
L2.BRA	-0.000724	0.000471	-1.537	0.124
L3.PAN	-0.073398	0.056191	-1.306	0.191
L3.ARG	-0.000090	0.000243	-0.370	0.711
L3.BRA	0.001217	0.000455	2.674	0.007**

*Nota.* \*  $p < 0.05$ ; *Elaboración propia.*

**Tabla 26**  
*Ecuación ARG — VAR(3)*

Parámetro	Coef.	Error std.	<i>t</i>	<i>p</i>
const	-0.306516	0.635119	-0.483	0.629
DUM_GUERRA	13.717249	4.204555	3.262	0.001***
L1.PAN	21.961023	11.893293	1.847	0.065
L1.ARG	0.018580	0.053038	0.350	0.726
L1.BRA	0.082496	0.107156	0.770	0.441
L2.PAN	10.336674	12.203048	0.847	0.397
L2.ARG	0.006279	0.053146	0.118	0.906
L2.BRA	0.050787	0.104224	0.487	0.626
L3.PAN	3.153928	12.435945	0.254	0.800
L3.ARG	-0.178831	0.053889	-3.318	0.001***
L3.BRA	-0.071159	0.100705	-0.707	0.480

*Nota. Elaboración propia.*

**Tabla 27**  
*Ecuación BRA — VAR(3)*

Parámetro	Coef.	Error std.	<i>t</i>	<i>p</i>
const	-0.108217	0.322578	-0.335	0.737
DUM_GUERRA	3.661347	2.135498	1.715	0.086
L1.PAN	18.734706	6.040615	3.101	0.002**
L1.ARG	0.013294	0.026938	0.494	0.622
L1.BRA	0.232330	0.054425	4.269	0.000***
L2.PAN	34.209437	6.197940	5.519	0.000***
L2.ARG	0.089278	0.026993	3.307	0.001***
L2.BRA	0.051949	0.052935	0.981	0.326
L3.PAN	-1.665079	6.316229	-0.264	0.792
L3.ARG	0.041512	0.027370	1.517	0.129
L3.BRA	0.002253	0.051148	0.044	0.965

Nota. *Elaboración propia.*

### 0.12.1. Diagnóstico del modelo

**Estabilidad estructural.** El módulo máximo de las raíces propias del sistema fue 0.604, muy por debajo del umbral crítico de 1.0; por tanto, el modelo cumple la condición de estabilidad exigida por la teoría VAR (no hay explosiones en la dinámica).

**Autocorrelación multivariante.** El test Portmanteau aplicado a  $h = 12$  rezagos entregó  $\chi^2(81) = 112.20$  y  $p = 0.012$ . El estadístico supera el valor crítico al 95 % ( $\chi^2_{0.95, 81} = 103.00$ ) en 9.20 unidades—equivalente a un exceso relativo de 8.9 %. Esto indica *moderada* autocorrelación remanente: el rechazo es estadísticamente significativo, pero la magnitud del exceso no sugiere un problema severo (por experiencia, excesos > 25 % son considerados “graves”).

**Heterocedasticidad condicional (ARCH-LM,  $q = 5$ ).**  $\Delta$ PAN presentó  $\chi^2(5) = 45.00$  ( $p < 0.001$ ), superando en 33.9 puntos el valor crítico ( $\chi^2_{0.95, 5} = 11.07$ ); esto revela heterocedasticidad marcada. Para  $\Delta$ ARG el resultado fue  $\chi^2 = 19.73$  ( $p = 0.001$ ), 8.7 puntos por encima del crítico; el problema es *moderado*. En  $\Delta$ BRA se obtuvo  $\chi^2 = 10.23$  ( $p = 0.069$ ), 0.84 puntos por debajo del umbral, de modo que no se rechaza la homocedasticidad al 5 %.

**Balance.** El sistema es estable y la autocorrelación, aunque estadísticamente significativa, excede la referencia crítica en menos del 10 %. La heterocedasticidad es más relevante en el pan y, en menor medida, en el FOB argentino. En síntesis, los problemas detectados son manejables y no invalidan el modelo.

## **0.13. Pronóstico con el modelo VAR–X(3) con variable binaria**

### **0.13.1. Objetivo del modelo**

El objetivo de este análisis fue generar un pronóstico de los precios futuros de tres commodities clave, considerando tanto su dinámica histórica como el impacto de un choque externo representado por una dummy de guerra. Para ello, se empleó un modelo VAR–X(3), un modelo autorregresivo vectorial extendido que captura las relaciones interdependientes entre las variables y ajusta las predicciones en función de eventos exógenos, como conflictos o crisis de mercado.

### **0.13.2. Proceso de proyección y pronóstico**

El proceso de proyección comenzó con la preparación de los datos, transformando los precios a diferencias semanales ( $\Delta$ ). Este paso es fundamental, ya que el modelo VAR requiere series estacionarias; la conversión elimina tendencias de largo plazo y centra el análisis en las fluctuaciones semanales, facilitando la estimación de los cambios futuros en los precios.

Con los datos preparados y la variable exógena incorporada, el modelo VAR se empleó para pronosticar los cambios futuros en los precios. El ajuste del modelo incluyó tres rezagos, es decir, consideró las tres observaciones previas de cada serie para predecir el valor de la semana siguiente.

A continuación, las diferencias pronosticadas se convirtieron a niveles absolutos. Dado que el VAR genera pronósticos en términos de cambios semanales ( $\Delta$ ), se aplicó un proceso de acumulación en dos etapas: primero, se calcularon los cambios acumulados a lo largo de un horizonte de 12 semanas mediante la función `cumsum()`; luego, dichos cambios acumulados se sumaron al último valor observado de cada serie para obtener los niveles pronosticados finales.

### 0.13.3. Resultados del pronóstico

El pronóstico para las primeras cinco semanas del horizonte de 12 semanas mostró una ligera oscilación en la serie que hace alusión al precio promedio del pan en Chile, una caída moderada en la serie que hace alusión al precio del trigo argentino y una corrección a la baja en la serie que hace alusión al precio del trigo brasileño. Específicamente, el precio del pan se mantuvo relativamente estable, oscilando entre 2.48 y 2.49 USD/kg; el precio del trigo argentino descendió ligeramente, de 191 a 189 USD/t; y el precio del trigo brasileño mostró una tendencia a la baja, estabilizándose alrededor de 221 USD/t.

Los resultados pronosticados para las primeras doce semanas muestran una ligera oscilación en los precios del pan (PAN), una disminución moderada en el trigo argentino (ARG) y una corrección progresiva a la baja en el trigo brasileño (BRA). La Tabla 28 presenta los valores estimados semana a semana en el horizonte de pronóstico de doce semanas.

**Tabla 28**

*Pronóstico de los precios de PAN, ARG y BRA para las primeras 12 semanas*

Fecha	PAN (USD)	ARG (USD/t)	BRA (USD/t)
2024-12-30	2.484259	191.903859	224.973341
2025-01-06	2.489229	190.406583	222.163776
2025-01-13	2.492143	189.486774	221.753726
2025-01-20	2.489678	189.624566	221.383328
2025-01-27	2.486849	189.722808	221.064236
2025-02-03	2.487711	189.489097	220.694962
2025-02-10	2.488204	189.115806	220.418385
2025-02-17	2.488441	188.775267	220.247683
2025-02-24	2.488271	188.513047	220.056929
2025-03-03	2.488310	188.261817	219.849619
2025-03-10	2.488541	187.995092	219.636568
2025-03-17	2.488740	187.719341	219.436742

*Nota: Elaboración propia.*

## 0.14. Pronóstico y bandas de predicción: MLP vs modelo completo

En esta sección se describe el proceso de aplicación de un modelo de red neuronal MLP (*Multi-Layer Perceptron*) para el pronóstico de los precios de productos clave, comparándolo con un modelo completo de referencia. Se analizaron las series de tiempo de los siguientes precios:

- Precio del pan en la Región Metropolitana (*PAN*).
- Precio del trigo en Rosario, Argentina (*ARG*).
- Precio del trigo en Paraná, Brasil (*BRA*).
- Precio de la harina en Chile (*HARINA*).
- Precio de las pastas en Chile (*PASTA*).

### 0.14.1. Carga y preparación de los datos

Para preparar los datos, se empleó la librería *pandas* de Python para leer un archivo Excel. Las series consideradas fueron la serie que representa el precio del pan en Chile, el precio del trigo argentino y brasileño, junto con el precio de la harina y la pasta en Chile. Con el fin de garantizar la consistencia, se renombraron las columnas en mayúsculas y se configuró la columna de fechas como índice temporal, facilitando así el manejo de las series de tiempo.

A continuación, se aplicó la función `diff()` para calcular las diferencias semanales ( $\Delta$ ), es decir, los cambios de precio de una semana a la siguiente, con el objetivo de obtener series estacionarias aptas para el entrenamiento del modelo MLP y la comparación con el modelo completo.

### 0.14.2. Entrenamiento del modelo MLP

El modelo de red neuronal MLP se configuró con una capa oculta de ocho neuronas. Se entrenó con el 85 % de las observaciones disponibles, reservando el 15 % restante para validación. Durante el entrenamiento se aplicó *early stopping* para evitar sobreajuste, limitando el número de iteraciones a 2 000. Una vez ajustado, el MLP realizó pronósticos recursivos a 12 semanas ( $h = 12$ ), es decir, cada predicción semanal se utilizó como entrada para la siguiente.

### 0.14.3. Bootstrap clásico

Para obtener bandas de predicción alrededor de las estimaciones del MLP, se empleó la técnica de *bootstrap*. Se generaron  $B = 300$  réplicas del modelo entrenado mediante muestreo con reemplazo. Para cada réplica se calcularon los pronósticos de 12 semanas y luego se transformaron a niveles absolutos. A continuación, se determinaron las bandas de predicción utilizando los cuantiles 2.5 % (límite inferior), 50 % (mediana) y 97.5 % (límite superior).

### 0.14.4. Bandas de predicción

Las bandas de predicción generadas fueron:

- *Low*: cuantil 2.5 % (límite inferior de la banda de predicción).
- *Mid*: cuantil 50 % (mediana o pronóstico central).
- *High*: cuantil 97.5 % (límite superior de la banda de predicción).

Estas bandas reflejan la incertidumbre inherente a los pronósticos, mostrando el rango dentro del cual se espera que los valores reales se encuentren. Las bandas se calcularon para cada serie de tiempo y para cada semana del horizonte de pronóstico.

### 0.14.5. Resultados Obtenidos

A continuación se presentan los resultados obtenidos para ambos modelos: el modelo *completo* (incluye todas las variables) y el modelo *reducido* (considera únicamente PAN, ARG y BRA). Se muestran las predicciones centrales de cada modelo y sus bandas de predicción, con el objetivo de evaluar la precisión y la incertidumbre asociadas a cada enfoque.

**Tabla 29**

*Bandas medias del modelo completo (Full Model)*

Fecha	PAN	ARG	BRA	HARINA	PASTA
2024-12-30	2.448204	205.404376	224.285375	1.313237	1.020322
2025-01-06	2.422385	203.723111	224.560383	1.295944	1.017178
2025-01-13	2.392181	200.760380	225.124535	1.277991	1.012205
2025-01-20	2.368324	206.633508	223.699184	1.268996	1.017211
2025-01-27	2.343607	208.510635	223.350682	1.259123	1.018037

*Nota: Elaboración propia.*

**Tabla 30**

*Bandas medias del modelo reducido (Reduced Model)*

Fecha	PAN	ARG	BRA
2024-12-30	2.456676	185.207348	223.829643
2025-01-06	2.449493	181.332874	223.460447
2025-01-13	2.463873	175.941038	222.969290
2025-01-20	2.469813	175.043395	222.959152
2025-01-27	2.477862	175.918701	222.447978

*Nota: Elaboración propia.*

### 0.14.6. Comparación de resultados mediante MAE

Para evaluar el desempeño de los modelos de pronóstico se utilizó el *Error Medio Absoluto* (MAE), que mide la diferencia promedio entre los valores reales y los predichos por el modelo, sin considerar la dirección del error. Esta métrica es especialmente útil para comparar la precisión de los modelos cuando se busca minimizar el tamaño de los errores absolutos.

En esta sección se contrastan los resultados de los modelos *completo* (full) y *reducido* (reduced) para las series de tiempo de los precios del pan en Chile (PAN), trigo argentino (ARG) y trigo brasileño (BRA). A continuación se presentan los valores de MAE obtenidos, lo que permite determinar cuál de los dos enfoques fue más preciso en sus pronósticos.

**Tabla 31**

*Comparación del MAE entre el modelo VAR y las redes neuronales*

<b>Serie</b>	<b>VAR</b>	<b>Red neuronal completa</b>	<b>Red neuronal reducida</b>
ARG	11.9602	8.1969	22.3648
BRA	24.9818	21.4352	23.2512
PAN	0.1560	0.3267	0.1704

*Nota: Elaboración propia.*

## 0.15. Conclusión

El análisis realizado refleja un claro impacto del conflicto Ucrania–Rusia en el mercado global del trigo, fenómeno visible en las series de tiempo internacionales. Durante el periodo del conflicto (2022–2023), se observó un aumento significativo en los precios de las exportaciones de trigo. Los precios promedio del trigo aumentaron en comparación con los años previos. Este comportamiento fue especialmente evidente durante los meses de marzo a junio de 2022, con incrementos en algunos mercados internacionales. Este patrón está relacionado con la interrupción de la oferta y la incertidumbre generada por el conflicto.

En el análisis de las variables climáticas, el estudio se centró en las provincias del Cono Norte, criterio sustentado en su mayor participación en la producción de trigo en América. Se identificaron dos clústeres y, para cada uno, se determinó un *driver* mediante un análisis de componentes principales (PCA). Al evaluar las precipitaciones acumuladas con ventanas fijas de 15 días —considerando intervalos entre 15 mm y 70 mm— no se observó un comportamiento homogéneo entre las provincias productoras del Cono Norte. Aunque se registraron episodios de déficit y de exceso hídrico, estos no fueron lo suficientemente extremos como para afectar de manera determinante las condiciones del cultivo de trigo.

Si bien el clima es relevante, no se estableció una relación directa con las series de precios internacionales del trigo durante el período analizado, lo que evidencia la complejidad de modelar la influencia climática en los precios agrícolas globales.

Respecto a las variables internacionales WTI, TTF y ZW, el análisis econométrico de los modelos estimados no cumplió con los supuestos de homocedasticidad y ausencia de autocorrelación. Para mejorar el ajuste, se introdujeron variables *dummy* que cubren el período del conflicto bélico, lo cual mejoró parcialmente la especificación. Aun así, no se alcanzó una robustez plena, lo que indica la necesidad de ajustes adicionales.

En cuanto al comportamiento de los precios del trigo, dado que no existía una variable con frecuencia semanal o diaria que midiera directamente este impacto, se utilizaron precios de productos derivados, como el pan. Se ajustaron modelos que integraron series de trigo de Argentina y Brasil, lo que permitió un análisis robusto de precios. El error medio absoluto (MAE) para el precio del trigo argentino fue 11.9602 en el modelo VAR, 8.1969 en la red neuronal completa y 22.3648 en el modelo reducido. Para el trigo brasileño, los MAE fueron 24.9818 (VAR), 21.4352 (red completa) y 23.2512 (red reducida). Finalmente, para el precio del pan, los MAE fueron 0.156 (VAR), 0.3267 (red completa) y 0.1704 (red reducida).

# Bibliografía

- Abis, S. (2012). Wheat in the Mediterranean region: Societies, trade and strategies. En *IEMed Mediterranean Yearbook 2012* (pp. 218-224). European Institute of the Mediterranean. Consultado el 29 de junio de 2025, desde <https://www.iemed.org/wp-content/uploads/2021/02/Wheat-in-the-Mediterranean-Region-Societies-Trade-and-Strategies.pdf>
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). *Crop evapotranspiration: Guidelines for computing crop water requirements*. Food; Agriculture Organization of the United Nations. <https://www.fao.org/3/x0490e/x0490e00.htm>
- Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, 191, 192-213. <https://doi.org/10.1016/j.ins.2011.12.028>
- Bolsa de Comercio de Rosario. (2025). *Cotizaciones locales – trigo FOB Up River* (Dataset) [Daily FOB prices in USD/t]. Dataset. BCR. Consultado el 26 de junio de 2025, desde <https://www.bcr.com.ar/es/mercados/mercado-de-granos/cotizaciones/cotizaciones-locales-0>
- Box, G. E. P., & Jenkins, G. M. (1976). *Time series analysis: Forecasting and control* (2.<sup>a</sup> ed.). Holden–Day. [https://books.google.com/books/about/Time\\_Series\\_Analysis.html?id=1WVHAAAAMAAJ](https://books.google.com/books/about/Time_Series_Analysis.html?id=1WVHAAAAMAAJ)
- Centro de Estudos Avançados em Economia Aplicada (CEPEA), ESALQ–USP. (2025). *Banco de dados de precios – indicadores de trigo (Paraná y Río Grande do Sul)* (Dataset) [Daily spot prices in BRL/t]. Dataset. CEPEA/ESALQ-USP. Consultado el 26 de junio de 2025, desde <https://www.cepea.org.br/br/consultas-ao-banco-de-dados-do-site.aspx>

- Chatfield, C. (2003). *The analysis of time series: An introduction* (6.<sup>a</sup> ed.). Chapman & Hall/CRC. [https://books.google.com/books/about/The\\_Analysis\\_of\\_Time\\_Series.html?id=qKzyAbdaDFAC](https://books.google.com/books/about/The_Analysis_of_Time_Series.html?id=qKzyAbdaDFAC)
- Cleveland, W. S. (1979). Robust Locally Weighted Regression and Smoothing Scatterplots. *Journal of the American Statistical Association*, 74(368), 829-836. <https://doi.org/10.2307/2286407>
- Convención de las Naciones Unidas de Lucha contra la Desertificación. (2023, diciembre). *Global drought snapshot 2023* (Informe especial). UNCCD. Bonn. Consultado el 29 de junio de 2025, desde <https://www.unccd.int/sites/default/files/2023-12/Global%20drought%20snapshot%202023.pdf>
- Devitt, P., & Polityuk, P. (2022, 6 de enero). *Russian wheat stable in thin trade, market eyes Kazakh unrest* [IKAR consultancy comment]. Consultado el 26 de junio de 2025, desde <https://www.reuters.com/markets/asia/russian-wheat-stable-thin-trade-market-eyes-kazakh-unrest-2022-01-06/>
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, 74(366), 427-431. <https://doi.org/10.1080/01621459.1979.10482531>
- Enders, W. (2009). *Applied econometric time series* (3.<sup>a</sup> ed.). John Wiley & Sons. [https://books.google.com/books/about/Applied\\_Econometric\\_Time\\_Series\\_3rd\\_Edi.html?id=56lNzQEACAAJ](https://books.google.com/books/about/Applied_Econometric_Time_Series_3rd_Edi.html?id=56lNzQEACAAJ)
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987-1007. <https://doi.org/10.2307/1912773>
- Erenstein, O., Jaleta, M., Mottaleb, K. A., Sonder, K., Donovan, J., & Braun, H.-J. (2022, junio). Global trends in wheat production, consumption and trade. En *Wheat Improvement* (pp. 47-66). Springer. [https://doi.org/10.1007/978-3-030-90673-3\\_4](https://doi.org/10.1007/978-3-030-90673-3_4)
- European Commission. (2022, 7 de abril). *Short-term outlook for EU agricultural markets in 2022: Spring 2022* (Quarterly report). Directorate-General for Agriculture y Rural Development. Brussels. Consultado el 29 de junio de 2025, desde [https://agriculture.ec.europa.eu/system/files/2022-04/short-term-outlook-spring-2022\\_en\\_0.pdf](https://agriculture.ec.europa.eu/system/files/2022-04/short-term-outlook-spring-2022_en_0.pdf)

- Food and Agriculture Organization of the United Nations. (2023, junio). Wheat market. En *Food Outlook – Biannual Report on Global Food Markets: June 2023*. FAO. Consultado el 29 de junio de 2025, desde <https://openknowledge.fao.org/server/api/core/bitstreams/887adc82-a132-4e17-95b3-98151bed837f/content>
- Food and Agriculture Organization of the United Nations. (2025). *FAOSTAT – trade domain (TCL): Crops and livestock products* (Dataset) [Annual series]. Dataset. FAO. Consultado el 26 de junio de 2025, desde <https://www.fao.org/faostat/en/#data/TCL>
- Glauber, J. (2023, 14 de marzo). *Assessing tight global wheat stocks and their role in price volatility* [Serie “Conflicts and Shocks Impacting Food Systems”]. Consultado el 29 de junio de 2025, desde <https://www.ifpri.org/blog/assessing-tight-global-wheat-stocks-and-their-role-price-volatility>
- Global Network Against Food Crises. (2024, abril). *Global report on food crises 2024* (Informe anual). Food Security Information Network (FSIN). Roma. Consultado el 29 de junio de 2025, desde <https://www.fsinplatform.org/sites/default/files/resources/files/GRFC2024-full.pdf>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. <http://www.deeplearningbook.org>
- Government of Alberta. (2025). *Wheat price dashboard – monthly farm prices by province* (Dataset) [Monthly average prices in CAD/t]. Dataset. Consultado el 26 de junio de 2025, desde <https://economicdashboard.alberta.ca/dashboard/wheat-price/>
- Granger, C. W. J. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3), 424-438. <https://doi.org/10.2307/1912791>
- Hamilton, J. D. (1994). *Time series analysis*. Princeton University Press. <https://doi.org/10.1515/9780691218632>
- Hansen, J., Ruedy, R., Sato, M., & Lo, K. (2010). Global surface temperature change. *Reviews of Geophysics*, 48(4). <https://doi.org/10.1029/2010RG000345>

- 
- International Food Policy Research Institute (IFPRI). (2025). *Global spatially disaggregated crop production statistics data for 2020 (version 2.0.0)* (Dataset; Ver. 2). Dataset. Harvard Dataverse. <https://doi.org/10.7910/DVN/SWPENT>
- Investing.com. (2025a). *Dutch TTF natural gas futures – historical price data* (Dataset) [Daily settlement prices]. Dataset. Consultado el 26 de junio de 2025, desde <https://es.investing.com/commodities/natural-gas-historical-data?cid=1057002>
- Investing.com. (2025b). *GBP/USD exchange rate – historical data* (Dataset) [Daily spot exchange rates]. Dataset. Consultado el 26 de junio de 2025, desde <https://es.investing.com/currencies/gbp-usd-historical-data>
- Investing.com. (2025c). *U.S. wheat futures (ZW) – historical price data* (Dataset) [Daily settlement prices]. Dataset. Consultado el 26 de junio de 2025, desde <https://es.investing.com/commodities/us-wheat>
- Investing.com. (2025d). *USD/ARS exchange rate – historical data* (Dataset) [Daily spot exchange rates]. Dataset. Consultado el 26 de junio de 2025, desde <https://es.investing.com/currencies/usd-ars>
- Investing.com. (2025e). *USD/CLP exchange rate – historical data* (Dataset) [Daily spot exchange rates]. Dataset. Consultado el 26 de junio de 2025, desde <https://es.investing.com/currencies/usd-clp>
- Investing.com. (2025f). *WTI crude oil futures – historical price data* (Dataset) [Daily settlement prices]. Dataset. Consultado el 26 de junio de 2025, desde <https://es.investing.com/commodities/crude-oil>
- Joanes, D. N., & Gill, C. (1998). Comparing Measures of Sample Skewness and Kurtosis. *The American Statistician*, 52(2), 122-126. <https://doi.org/10.1080/00031305.1998.10480547>
- Johansen, S. (1991). Estimation and hypothesis testing of cointegration vectors in Gaussian vector autoregressive models. *Econometrica*, 59(6), 1551-1580. <https://doi.org/10.2307/2938278>

- Köbrich Grüebler, A. (2024, 10 de septiembre). *Boletín de cereales n.º 1 septiembre 2024* (Boletín técnico N.º 1). Sociedad Nacional de Agricultura. Santiago. Consultado el 29 de junio de 2025, desde [https://www.sna.cl/wp-content/uploads/2024/09/2024-09-10-Cereales\\_1.pdf](https://www.sna.cl/wp-content/uploads/2024/09/2024-09-10-Cereales_1.pdf)
- Lütkepohl, H. (2005). *New introduction to multiple time series analysis* (Reprint). Springer Science & Business Media. [https://books.google.com/books/about/New\\_Introduction\\_to\\_Multiple\\_Time\\_Series.html?id=muorJ6FHIEC](https://books.google.com/books/about/New_Introduction_to_Multiple_Time_Series.html?id=muorJ6FHIEC)
- MacKinnon, J. G., Haug, A. A., & Michelis, L. (1999). Numerical Distribution Functions of Likelihood Ratio Tests for Cointegration. *Journal of Applied Econometrics*, 14(5), 563-577. [https://doi.org/10.1002/\(SICI\)1099-1255\(199909/10\)14:5<563::AID-JAE530>3.0.CO;2-R](https://doi.org/10.1002/(SICI)1099-1255(199909/10)14:5<563::AID-JAE530>3.0.CO;2-R)
- Media Cloud Project, MIT Center for Civic Media and Berkman Klein Center. (2025). *Global South corpus – story-level word frequencies* (Dataset) [Daily keyword counts]. Dataset. Media Cloud. Consultado el 26 de junio de 2025, desde <https://search.mediacloud.org/>
- Monahan, A. H., Fyfe, J. C., Ambaum, M. H. P., Stephenson, D. B., & North, G. R. (2009). Empirical orthogonal functions: The medium is the message. *Journal of Climate*, 22(24), 6501-6514. <https://doi.org/10.1175/2009JCLI3062.1>
- Nagurney, A. (2023, 25 de julio). *Why Russia pulled out of its grain deal with Ukraine, and what that means for the global food system*. Consultado el 29 de junio de 2025, desde <https://modernfarmer.com/2023/07/grain-deal-ukraine/>
- NASA POWER Project Team. (2025). *Prediction of worldwide energy resources (POWER) – climate data API, hourly 2.x.x* (Dataset) [Satellite-derived parameters]. Dataset. NASA Langley Research Center. Consultado el 26 de junio de 2025, desde <https://power.larc.nasa.gov/>
- National Centers for Environmental Information. (2025). *Why use temperature anomalies (departure from average) and not absolute temperature measurements?* [Consultado el 18 de julio de 2025]. <https://www.ncei.noaa.gov/access/monitoring/climate-at-a-glance/global/mapping>
- Oficina de Estudios y Políticas Agrarias. (2024, junio). *Boletín de cereales: Trigo, maíz y arroz. Edición junio 2024* (Boletín mensual). Ministerio de Agricultura, Gobierno de Chile.

- Santiago. Consultado el 29 de junio de 2025, desde <https://bibliotecadigital.odepa.gob.cl/bitstream/handle/20.500.12650/73421/Bolet%C3%ADnCereales062024.pdf>
- Organisation for Economic Co-operation and Development & Food and Agriculture Organization of the United Nations. (2021, 5 de julio). *OECD–FAO agricultural outlook 2021–2030* (Annual report). OECD Publishing. Paris. <https://doi.org/10.1787/19428846-en>
- Organisation for Economic Co-operation and Development & Food and Agriculture Organization of the United Nations. (2025). *OECD–FAO Agricultural Outlook 2025–2034*. OECD Publishing; FAO. <https://doi.org/10.1787/601276cd-en>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830. <https://jmlr.org/papers/v12/pedregosa11a.html>
- Rodgers, J. L., & Nicewander, A. W. (1988). Thirteen Ways to Look at the Correlation Coefficient. *The American Statistician*, 42(1), 59–66. <https://doi.org/10.1080/00031305.1988.10475524>
- Shiferaw, B., Smale, M., Braun, H.-J., Duveiller, E., Reynolds, M., & Muricho, G. (2013). Crops that feed the world 10: Past successes and future challenges to the role played by wheat in global food security. *Food Security*, 5(3), 291–317. <https://doi.org/10.1007/s12571-013-0263-y>
- Shumway, R. H., & Stoffer, D. S. (2017). *Time Series Analysis and Its Applications: With R Examples* (4.<sup>a</sup> ed.). Springer. <https://doi.org/10.1007/978-3-319-52452-8>
- Toda, H. Y., & Yamamoto, T. (1995). Statistical inference in vector autoregressions with possibly integrated processes. *Journal of Econometrics*, 66(1–2), 225–250. [https://doi.org/10.1016/0304-4076\(94\)01616-8](https://doi.org/10.1016/0304-4076(94)01616-8)
- United Nations, Department of Economic and Social Affairs, Population Division. (2022). *World population prospects 2022: Online edition (Rev. 1)* (Dataset) [Demographic estimates]. Dataset. United Nations. Consultado el 26 de junio de 2025, desde <https://population.un.org/wpp/>

- 
- United States Department of Agriculture, Foreign Agricultural Service. (2025). *Global Agricultural Trade System (GATS)* (Dataset) [HS 1001 trade statistics]. Dataset. USDA FAS. Consultado el 23 de junio de 2025, desde <https://apps.fas.usda.gov/gats/>
- USDA Foreign Agricultural Service. (2025, 14 de febrero). *Grain and feed annual: Serbia 2025* (Informe anual). United States Department of Agriculture, Foreign Agricultural Service. Washington, DC. Consultado el 29 de junio de 2025, desde [https://apps.fas.usda.gov/newgainapi/api/Report/DownloadReportByFileName?fileName=Grain+and+Feed+Annual\\_Belgrade\\_Serbia\\_RB2025-0002.pdf](https://apps.fas.usda.gov/newgainapi/api/Report/DownloadReportByFileName?fileName=Grain+and+Feed+Annual_Belgrade_Serbia_RB2025-0002.pdf)
- van Huellen, S. (2013). *Price non-convergence in commodities: A case study of the wheat conundrum* (Documento de trabajo N.º 185). SOAS University of London, Department of Economics. Londres. Consultado el 29 de junio de 2025, desde <https://www.soas.ac.uk/sites/default/files/2022-10/economics-wp185.pdf>
- White, H. (1980). A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. *Econometrica*, 48(4), 817-838. <https://doi.org/10.2307/1912934>
- World Bank. (2021, marzo). *Analysis of regional dynamics of wheat and flour sectors in Central Asia and their impact on Uzbekistan* (Informe técnico). World Bank. Washington, DC. Consultado el 29 de junio de 2025, desde <https://documents1.worldbank.org/curated/en/918481601271619467/pdf/Policy-Dialogue-on-Agriculture-Modernization-Analysis-of-Regional-Dynamics-of-Wheat-and-Flour-Sectors-in-Central-Asia-and-their-Impact-on-Uzbekistan.pdf>

## Anexo A

*Código fuente en Python: Mapa binario de producción de trigo (SPAM 2020)*

El siguiente código, escrito en lenguaje Python, utiliza datos geoestadísticos del conjunto SPAM 2020 para generar un mapa binario del continente americano, mostrando únicamente las celdas cuya producción estimada de trigo supera las 100 toneladas. El procedimiento incluye la carga de datos ráster, el recorte geográfico, el enmascaramiento y la visualización, utilizando las bibliotecas `rioxarray`, `geopandas` y `matplotlib`.

```
1 ### MAPA PRODUCCION DE TRIGO EN AMERICA
2 """
3 MAPA BINARIO DE ZONAS TRIGUERAS EN AMERICA (SPAM 2020 v2.0)
4 -----
5 Objetivo : Mostrar *donde* se cultiva trigo (celdas >= 100 t),
6            sin importar la magnitud exacta de produccion.
7 Fuente   : GeoTIFF SPAM 2020 - produccion total de trigo.
8 Librerias: rioxarray, geopandas, matplotlib.
9 """
10
11 # -----
12 # 0. CARGA DE LIBRERIAS Y CONFIGURACION
13 # -----
14 import warnings
15 import rioxarray as rxr          # lee y maneja rasters GeoTIFF
16 import geopandas as gpd        # limites de paises / geometria
    vectorial
17 import matplotlib.pyplot as plt # plot estatico
18
19 # Silenciar warnings irrelevantes (de paramiko, cryptography, etc.)
```

```

20 warnings.filterwarnings("ignore", category=UserWarning)
21
22 # -----
23 # 1. CARGAR EL RASTER DE PRODUCCION DE TRIGO (GeoTIFF, SPAM 2020)
24 # -----
25 tif = (
26     r"C:\Users\sebad\Documents\2025\TESIS
27     RE\MAPA\DATOS_RUN_MAPA_PRODUCCION"
28     r"\Global_Geotiff\spam2020V2r0_global_production"
29     r"\spam2020_V2r0_global_P_WHEA_A.tif"
30 )
31 # open_rasterio -> Xarray DataArray; squeeze() quita la dimension
32     "band"
33 da = rxr.open_rasterio(tif, masked=True).squeeze()
34 # -----
35 # 2. RECORTAR EL RASTER A LA REGION DE AMERICA (bounding box)
36 #     latitud: 80N (Canada artico) a -60S (Tierra del Fuego)
37 #     longitud: -170W (Alaska) a -30W (Atlantico)
38 # -----
39 da_ame = da.sel(x=slice(-170, -30), # longitudes
40                y=slice(80, -60)) # latitudes (norte -> sur)
41 # -----
42 # 3. CREAR UNA MASCARA BINARIA
43 #     - Si la celda tiene produccion >= 100 toneladas -> 1 (verde)
44 #     - Si tiene < 100 t (o NaN) -> 0 (blanco)
45 # -----
46 # -----

```

```

47 mask = (da_ame >= 100).astype(int)
48
49 # -----
50 # 4. CARGAR FRONTERAS DE PAISES PARA CONTEXTO
51 # Intentamos primero con "geodatasets".
52 # Si falla (no instalado), descargamos GeoJSON directo de GitHub.
53 # -----
54 try:
55     from geodatasets import get_path
56     world = gpd.read_file(get_path("naturalearth_countries"))
57 except Exception:
58     url = (
59         "https://raw.githubusercontent.com/nvkelso/"
60         "natural-earth-vector/master/geojson/"
61         "ne_50m_admin_0_countries.geojson"
62     )
63     world = gpd.read_file(url)
64
65 # Asegurarnos de que el shapefile y el raster comparten el mismo CRS
66 world = world.to_crs(mask.rio.crs)
67
68 # -----
69 # 5. PLOT: MAPA BINARIO DE ZONAS CON TRIGO
70 # -----
71 plt.figure(figsize=(14, 9), dpi=150)
72
73 # Dibujamos la mascara: cmap con un solo tono ("Greens") y sin barra
74 mask.plot(cmap="Greens", add_colorbar=False, vmin=0, vmax=1)
75

```

```
76 # Anhadimos contornos de paises en gris
77 world.boundary.plot(ax=plt.gca(), color="grey", linewidth=0.5)
78
79 # Etiquetas y titulo
80 plt.title("Zonas con cultivo de trigo (>= 100 t) - America    SPAM
      2020")
81 plt.xlabel("Longitud")
82 plt.ylabel("Latitud")
83 plt.grid(True)
84
85 plt.show()
```

Listing 1: Código Python para generar el mapa binario SPAM 2020

## Anexo B

*Código fuente Python: Porcentaje de producción de trigo por provincias en América*

Este script analiza el archivo `spam2020V2r0_global_P_TA.csv`, correspondiente a los datos globales del conjunto SPAM 2020, para identificar las diez provincias o estados con mayor producción de trigo en América. El código filtra únicamente los registros de producción (`rec_type = 'P'`) y tecnología agregada (`tech_type = 'A'`), suma la producción por unidad administrativa y calcula su contribución relativa respecto al total combinado de Argentina, Brasil, Canadá y Estados Unidos.

```
1 ### PORCENTAJE EN AMERICA POR LOS MAYORES PRODUCTORES
2 """
3 TOP-10 PROVINCIAS / ESTADOS EN PRODUCCION DE TRIGO - SPAM 2020 V2r0
4 -----
5 Lee el CSV global _P_TA (A = All technologies)
6 Filtra rec_type == 'P' -> produccion de trigo
7 Suma toneladas por provincia / estado
8 Calcula el % que aporta cada provincia respecto del TOTAL de los 4
9 países
10 """
11 # ----- 0 LIBRERIAS -----
12 import pandas as pd
13 from pathlib import Path
14
15 # ----- 1 RUTA AL CSV -----
16 csv_path = Path(
17     r"C:\Users\sebad\Documents\2025\TESIS
18     RE\MAPA\DATOS_RUN_MAPA_PRODUCCION"
19     r"\spam2020V2r0_global_production\spam2020V2r0_global_P_TA.csv"
```

```

19 )
20 compression = "zip" if csv_path.suffix == ".zip" else None
21
22 # ----- 2     PARAMETROS -----
23 top_n          = 10
24 target_countries = ["United States of America", "Canada", "Brazil",
25                    "Argentina"]
26
27 # ----- 3     LEER Y FILTRAR -----
28 cols = ["ADM0_NAME", "ADM1_NAME", "rec_type", "tech_type", "WHEA_A"]
29 df = pd.read_csv(csv_path, usecols=cols, compression=compression)
30
31 df = df[
32     (df["ADM0_NAME"].isin(target_countries)) &
33     (df["rec_type"] == "P") &          # produccion
34     (df["tech_type"] == "A")          # All technologies
35 ].drop(columns=["rec_type", "tech_type"])
36
37 # ----- 4     PRODUCCION POR PROVINCIA -----
38 prov_sum = (df.groupby(["ADM0_NAME", "ADM1_NAME"], as_index=False)
39             .agg(prod_ton=("WHEA_A", "sum"))
40             .sort_values("prod_ton", ascending=False))
41
42 # ----- 5     % DE CADA PROVINCIA EN EL TOTAL -----
43 total_4pais = prov_sum["prod_ton"].sum()
44 prov_sum["pct_total"] = prov_sum["prod_ton"] / total_4pais * 100
45
46 # ----- 6     TOP-N GLOBAL Y SALIDA -----
47 topN = prov_sum.head(top_n)

```

```

47
48 print(f"\n=== TOP {top_n} PROVINCIAS / ESTADOS (4 paises) - Trigo 2020
    ===")
49 print(topN[["ADM0_NAME", "ADM1_NAME", "prod_ton", "pct_total"]]
50         .to_string(index=False,
51                    formatters={"prod_ton": "{:,.0f}".format,
52                                "pct_total": "{:.2f}%".format}))

```

Listing 2: Calculo del top-10 de provincias productoras de trigo en America (SPAM 2020)

## Anexo C

*Código fuente en Python: Comparación de área total versus área optimizada al 90 % de producción de trigo — Saskatchewan (SPAM 2020)*

Este script utiliza datos ráster del conjunto SPAM 2020 para estimar el área productiva de trigo en la provincia de Saskatchewan (Canadá), comparando el *bounding box* completo de celdas productoras con un recorte optimizado que cubre solo el 90 % de la producción total. Se calcula el porcentaje de reducción de superficie mediante máscaras y operaciones geoespaciales.

```
1 # =====
2 # AREA BOUNDING-BOX COMPLETO vs. TOP-90 % PRODUCCION - SPAM 2020 CANADA
3 # Provincia: Saskatchewan (Canada)
4 # =====
5
6 from pathlib import Path
7 import rioxarray as rxr
8 import geopandas as gpd
9 import numpy as np
10 import pandas as pd
11 from shapely.geometry import box
12
13 # ----- 1. Abrir el GeoTIFF de trigo -----
14 root = Path(r"C:\Users\sebad\Documents\2025\TESIS
15 RE\MAPA\DATOS_RUN_MAPA_PRODUCCION\Global_Geotiff")
16 tif = next(root.rglob("*_P_WHEA_A.tif")) # primer archivo
17 que coincida
18 wheat = rxr.open_rasterio(tif, masked=True).squeeze()
19
20 # ----- 2. Descargar la silueta de Saskatchewan -----
```

```

19 url = ("https://raw.githubusercontent.com/nvkelso/"
20        "natural-earth-vector/master/geojson/"
21        "ne_50m_admin_1_states_provinces.geojson")
22 sask = (gpd.read_file(url)
23         .query("admin=='Canada' and name=='Saskatchewan'")
24         .to_crs(wheat.rio.crs))
25
26 # ----- 3. Recortar raster a la provincia -----
27 wheat_sask = wheat.rio.clip(sask.geometry, sask.crs, drop=True)
28
29 # ----- 4. Matriz de toneladas y mascara completa -----
30 vals = wheat_sask.data
31 mask_all = (~np.isnan(vals)) & (vals > 0)           # celdas con trigo
32
33 # ----- 5. Seleccionar pixeles hasta cubrir 90 % +-1 % ----
34 flat_vals = vals[mask_all].flatten()
35 order      = np.argsort(-flat_vals)                # indices ordenados
36             desc
37 cum        = np.cumsum(flat_vals[order])
38 total      = cum[-1]
39 lo, hi     = 0.90 * total, 0.91 * total
40
41 idx90 = np.searchsorted(cum, lo, side="right") - 1
42 while cum[idx90] > hi:           # asegura no pasarse del +1 %
43     idx90 -= 1
44
45 # Crear mascara TOP-90 %
46 mask_top = np.zeros_like(vals, dtype=bool)
47 valid_lin = np.flatnonzero(mask_all)                # indices lineales

```

```

    validos
47 sel_lin    = valid_lin[order[:idx90+1]]           # primeros N indices
48 rows, cols = np.unravel_index(sel_lin, vals.shape)
49 mask_top[rows, cols] = True
50
51 covered_pct = cum[idx90] / total * 100
52 print(f"Celdas TOP-90 %: {mask_top.sum()} "
53       f"-> cubren {covered_pct:.2f}% de la produccion")
54
55 # ----- 6. Bounding-boxes y areas -----
56 def bbox_from_mask(mask, da):
57     r, c = np.where(mask)
58     xs, ys = da.x[c], da.y[r]
59     return box(xs.min(), ys.min(), xs.max(), ys.max())
60
61 bbox_all    = bbox_from_mask(mask_all, wheat_sask)
62 bbox_opt90 = bbox_from_mask(mask_top, wheat_sask)
63
64 def area_km2(bbx):
65     xmin, ymin, xmax, ymax = bbx.bounds
66     mean_lat = (ymin + ymax) / 2
67     dx = (xmax - xmin) * 111.32 * np.cos(np.deg2rad(mean_lat))
68     dy = (ymax - ymin) * 111.32
69     return dx * dy
70
71 area_all = area_km2(bbox_all)
72 area_opt = area_km2(bbox_opt90)
73 reduc    = (1 - area_opt / area_all) * 100
74

```

```

75 # ----- 7. Resultados -----
76 print("\n--- AREAS COMPARADAS ---")
77 print(f"Bounding-box completo : {area_all:,.0f} km ")
78 print(f"Bounding-box TOP-90 % : {area_opt:,.0f} km ")
79 print(f"Reduccion de superficie : {reduc:.1f} %")
80
81 print("\nCoords bbox TOP-90 % (xmin, ymin, xmax, ymax):")
82 print(bbox_opt90.bounds)

```

Listing 3: Comparacion de bounding-box completo vs. bounding-box TOP-90 % en Saskatchewan (SPAM 2020)