

Escuela de Negocios
Tipo de documento: Tesis de maestría



Master in Management + Analytics

Mix óptimo de cultivos según la fase del fenómeno climático ENSO en dos departamentos de la región pampeana argentina

Autoría: Forzani, Mariana

Año: 2025

¿Cómo citar este trabajo?

Forzani, M. (2025) "*Mix óptimo de cultivos según la fase del fenómeno climático ENSO en dos departamentos de la región pampeana argentina*". [Tesis de maestría. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella
<https://repositorio.utdt.edu/handle/20.500.13098/13675>

El presente documento se encuentra alojado en el **Repositorio Digital de la Universidad Torcuato Di Tella** bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Internacional
Dirección: <https://repositorio.utdt.edu>



**UNIVERSIDAD
TORCUATO DI TELLA**

Master in Management + Analytics

**“Mix óptimo de cultivos según la fase
del fenómeno climático ENSO en dos
departamentos de la región pampeana
argentina”**

Mariana Forzani

Tutor: Javier Marengo

Junio 2025

Resumen

El fenómeno El Niño-Oscilación Sur (ENSO) es un factor clave en la variabilidad climática que afecta la producción agrícola de la región pampeana argentina. La capacidad de predecir sus fases permite ajustar las estrategias productivas, mitigando los efectos adversos de eventos climáticos extremos o aprovechando las condiciones favorables para maximizar el rendimiento. Este estudio desarrolla tres modelos de optimización para la asignación de tierras entre cultivos, con el objetivo de maximizar el beneficio esperado del productor. Los modelos incorporan diferentes niveles de aversión al riesgo y consideran los costos de producción y los precios internacionales de los cultivos como variables externas. La principal diferencia entre los enfoques radica en el tratamiento del riesgo, lo que permite identificar el mix de cultivos que optimiza la rentabilidad ajustada por riesgo ante los diferentes escenarios climáticos.

Los resultados indican que la asignación de tierras varía de manera significativa según la fase del ENSO. Durante la fase de Niña, se observa un aumento en la superficie dedicada al girasol, mientras que, en la fase de Niño, la mayor disponibilidad de agua resulta en una diversificación más amplia de cultivos. Estos resultados reflejan la influencia directa del fenómeno en las condiciones climáticas y, en consecuencia, sobre la estrategia productiva óptima. Además, cuando se incorpora un mayor grado de aversión al riesgo en el modelo, se intensifica la diversificación del mix de cultivos, lo que permite reducir la variabilidad en los ingresos agrícolas frente a escenarios climáticos inciertos. De este modo, los modelos confirman que tanto la fase del ENSO como el perfil de riesgo del productor son factores clave para tomar decisiones óptimas en términos de producción y rentabilidad.

Abstract

The El Niño–Southern Oscillation (ENSO) is a key factor in climate variability that affects agricultural production in Argentina's Pampas region. The ability to predict its phases allows for the adjustment of production strategies, mitigating the adverse effects of extreme weather events or taking advantage of favorable conditions to maximize yield. This study develops three optimization models for land allocation among crops, with the objective of maximizing the producer's expected profit. The models incorporate different levels of risk aversion and consider production costs and international crop prices as external variables. The main difference between the approaches lies in the treatment of risk, which enables the identification of the crop mix that optimizes risk-adjusted profitability under different climatic scenarios.

The results indicate that land allocation varies significantly according to the ENSO phase. During the La Niña phase, there is an increase in the area allocated to sunflower, while in the El Niño phase, the greater availability of water leads to broader crop diversification. These results reflect the direct influence of the phenomenon on climatic conditions and, consequently, on the optimal production strategy. Furthermore, when a higher degree of risk aversion is incorporated into the model, crop diversification increases, helping reduce income variability under uncertain climatic scenarios. In this way, the models confirm that both the ENSO phase and the producer's risk profile are key factors for making optimal decisions in terms of production and profitability.

Índice

1. Capítulo 1: Introducción.....	5
1.1. Contexto	5
1.2. Problema	6
1.3. Revisión bibliográfica.....	7
1.4. Objetivo	9
2. Capítulo 2: Datos	10
2.1. Fuente de datos.....	10
2.2. Participación de los cultivos en la superficie sembrada	10
2.3. Análisis del impacto de las precipitaciones en los rendimientos de los cultivos en la región pampeana	12
2.3.1. Consideraciones metodológicas sobre el cálculo de rendimientos	12
2.3.2. Identificación de períodos críticos por cultivo	12
2.3.3. Análisis del rendimiento promedio en función de rangos de precipitaciones .	14
2.3.4. Evolución histórica del rendimiento y precipitaciones por campaña	18
2.4. Costos de producción de los cultivos	24
2.5. Precios internacionales de los cultivos.....	26
3. Capítulo 3: Metodología	29
4. Capítulo 4: Enfoque	33
4.1. Clasificación de escenarios ENSO	33
4.2. Construcción de los parámetros del modelo	33
4.3. Resolución del modelo	33
4.4. Análisis de sensibilidad.....	34
4.4.1. Preferencias de riesgo	34
4.4.2. Relación entre rentabilidad y riesgo	34
4.4.3. Sensibilidad al cultivo de segunda	35
5. Resultados	36
5.1. Asignación óptima de tierras condicionada a la fase del ENSO.....	36
5.1.1. Modelo 1: Penalización basada en el desvío estándar del rendimiento	36
5.1.2. Modelo 2: Penalización basada en la varianza del ingreso.....	38
5.1.3. Modelo 3: Penalización sobre la variabilidad del beneficio neto	40
5.1.4. Comparativa de resultados entre modelos.....	42

5.2. Análisis de resultados: sensibilidad al cultivo de segunda.....	43
6. Capítulo 6: Conclusiones	47
Referencias Bibliográficas.....	49
Apéndice A	50
Apéndice B	51

1. Capítulo 1: Introducción

1.1. Contexto

La agricultura es uno de los pilares fundamentales de la economía argentina. Si bien su contribución al Producto Bruto Interno (PBI) es significativa, su relevancia radica en el rol central que desempeña en el comercio exterior. En el año 2024, Argentina registró exportaciones por U\$S 79.721 millones, de los cuales U\$S 47.964 millones correspondieron al sector agropecuario y agroindustrial, lo que equivale al 60% de las exportaciones totales del país. En este contexto, la capacidad de maximizar la rentabilidad del sector agrícola frente a las variaciones climáticas resulta esencial para garantizar su competitividad y sostener su impacto en la economía nacional.

Entre los factores climáticos que condicionan el rendimiento de los cultivos, uno de los más relevantes es el fenómeno ENSO (El Niño-Oscilación Sur), que influye significativamente sobre los patrones de temperatura y precipitaciones en distintas regiones del mundo, incluida la región pampeana argentina. El fenómeno ENSO involucra dos fases extremas caracterizadas por la presencia de aguas superficiales anómalamente cálidas (El Niño) o frías (La Niña) en el Pacífico tropical oriental y presenta una periodicidad irregular, con una frecuencia de ocurrencia que varía, usualmente, entre dos y siete años.

Las fases El Niño/La Niña se declaran cuando las temperaturas del mar en el Pacífico oriental tropical aumentan/disminuyen 0,5°C por encima/por debajo del promedio durante varios meses consecutivos (habitualmente cinco meses consecutivos). El Niño, que constituye la fase cálida del fenómeno, suele provocar un incremento de las precipitaciones, lo que puede derivar en excesos hídricos e inundaciones en zonas agrícolas. En contraste, La Niña, asociada a un enfriamiento a gran escala de las aguas superficiales del Pacífico ecuatorial central y oriental, tiende a reducir las precipitaciones, incrementando el riesgo de sequías y afectando la disponibilidad de agua para los cultivos. Estas alteraciones climáticas impactan directamente en los rendimientos agrícolas, influyendo tanto en la cantidad como en la calidad de la producción. La variabilidad climática genera riesgos económicos y para la seguridad alimentaria a nivel mundial, debido a su significativa influencia en la agricultura. Pronósticos climáticos precisos con una anticipación de 3 a 6 meses pueden permitir que los agricultores y otros actores del sector tomen decisiones para reducir impactos negativos o aprovechar condiciones climáticas favorables esperadas (Jones et al., 2000). En consecuencia, la posibilidad de anticipar la variabilidad climática y sus efectos sobre los rendimientos, en función de la fase del ENSO, abre oportunidades para ajustar las decisiones productivas con el fin de reducir riesgos y maximizar beneficios.

El objetivo de este estudio es analizar el potencial de gestión del riesgo climático a través de la adaptación en la asignación de tierras entre cultivos según las fases del fenómeno ENSO, en la región pampeana de Argentina. El análisis se enfoca en dos departamentos pertenecientes a las provincias de Córdoba y Santa Fe, las cuales ocupan el segundo y tercer lugar, respectivamente, en el ranking nacional de superficie sembrada. En conjunto, ambas provincias representan aproximadamente el 40 % de la superficie cultivada del país. Para estudiar la dinámica agrícola en estas áreas, se utilizarán datos históricos correspondientes al período 2000-2024 sobre superficie sembrada, superficie cosechada, producción y

rendimientos de los cinco cultivos más representativos de la región: trigo, girasol, maíz, soja de primera y soja de segunda. El año 2000 se considera punto de partida, dado que a partir de entonces se dispone de registros sistemáticos de datos para la soja, actualmente el cultivo más relevante en estas zonas productivas.

1.2. Problema

En la actualidad, existen múltiples modelos que estudian la asignación óptima de tierras en función de recursos como mano de obra, capital y agua, así como en relación con precios y costos. Sin embargo, los enfoques que incorporan explícitamente la variabilidad climática vinculada al fenómeno ENSO (El Niño–Oscilación Sur) siguen siendo escasos. En general, los modelos disponibles se enmarcan en esquemas probabilísticos que buscan optimizar la asignación de cultivos frente a la incertidumbre sobre la fase ENSO que se presentará en la campaña agrícola.

Aunque existen antecedentes que abordan la relación entre ENSO y decisiones de siembra — como el trabajo de Messina et al. (1999), que analiza la asignación de tierras condicionada a las fases ENSO en la región pampeana para el período de 1931-1999—, este tipo de enfoques continúa siendo limitado dentro de la literatura académica y requiere de un desarrollo más sistemático desde una perspectiva de optimización cuantitativa.

Cada campaña, los productores agropecuarios deben tomar decisiones estratégicas sobre qué cultivos sembrar, enfrentando variabilidad en los rendimientos debido a factores climáticos como precipitaciones, temperaturas e irradiación solar. Si bien los costos de producción y los precios de mercado son, en general, parámetros externos sobre los cuales un productor no puede inferir, los rendimientos de los distintos cultivos varían significativamente en función de la fase del ENSO. Estudios previos han mostrado que cultivos como el maíz, la soja y el sorgo presentan una disminución en sus rendimientos durante los eventos fríos del ENSO, mientras que el girasol tiende a mostrar una respuesta más atenuada e incluso contraria. En particular, el maíz se destaca por su alta sensibilidad a los incrementos de precipitaciones durante los eventos de El Niño (Podestá et al., 1999).

Esta disparidad en la respuesta productiva refuerza la importancia de desarrollar modelos que contemplen escenarios climáticos específicos. La posibilidad de contar con pronósticos estacionales permite anticipar, con cierto grado de confianza, la fase ENSO predominante, abriendo así una oportunidad para diseñar estrategias de siembra más eficientes bajo el supuesto de conocimiento previo de dicha fase.

Dada la disponibilidad de información histórica sobre rendimientos y condiciones climáticas, existe una oportunidad para avanzar en el desarrollo de modelos de optimización que determinen, de manera diferenciada para cada escenario ENSO, la estrategia de asignación de cultivos más eficiente. En este sentido, el presente trabajo busca contribuir mediante el desarrollo de un modelo de optimización que, ante el conocimiento previo de la fase ENSO, determine la combinación óptima de cultivos que maximice la rentabilidad esperada y minimice el riesgo productivo, proporcionando así una herramienta más precisa para la toma de decisiones estratégicas en el sector agrícola.

1.3. Revisión bibliográfica

En las últimas décadas, la toma de decisiones en el sector agropecuario ha evolucionado hacia enfoques más analíticos, incorporando herramientas cuantitativas que permiten optimizar el uso de recursos escasos en un entorno caracterizado por alta incertidumbre, especialmente climática. En este contexto, la programación lineal (PL) ha sido una de las herramientas más utilizadas para mejorar la eficiencia productiva, facilitar la planificación estratégica y apoyar la toma de decisiones a nivel local y regional. Sin embargo, existen otros enfoques que complementan la programación lineal, como los modelos estocásticos, que también abordan la incertidumbre de manera efectiva, y que se consideran relevantes para la optimización de recursos en el ámbito agropecuario.

En este sentido, Alotaibi y Nadeem (2021) subrayan la importancia de la programación lineal dentro de la denominada Agricultura 4.0. En su trabajo *A Review of Applications of Linear Programming to Optimize Agricultural Solutions*, los autores realizan una revisión exhaustiva de las aplicaciones de la PL en diversas áreas del sector agrícola. Los autores sostienen que la PL es particularmente útil cuando el objetivo principal es alcanzar una mayor eficiencia, permitiendo a los agricultores optimizar la asignación de recursos y mejorar la toma de decisiones, evitando el método de prueba y error. Entre las aplicaciones más destacadas, mencionan la formulación de mezclas alimenticias para ganado, la determinación de patrones de cultivo y la selección de combinaciones óptimas bajo restricciones de recursos, así como la planificación eficiente de rotaciones de cultivos para preservar la fertilidad del suelo. Asimismo, la PL ha sido empleada para asignar de manera eficiente la tierra entre distintos cultivos, distribuir el agua de riego bajo criterios de sostenibilidad y minimizar los costos logísticos en la transformación y transporte de productos agrícolas. Finalmente, destacan que una de las técnicas más empleadas para resolver problemas de programación lineal es el algoritmo Simplex, que permite encontrar el valor óptimo de la función objetivo dentro de un conjunto de restricciones.

Un aporte temprano y relevante en esta línea es el de Villavicencio (2012), quien desarrolla un modelo matemático de programación lineal con el objetivo de optimizar el uso de los recursos prediales disponibles (agua, mano de obra, suelo y capital) en la Región de Arica y Parinacota, Chile. El modelo busca maximizar el margen bruto por hectárea, brindando una herramienta de apoyo para tomar decisiones más racionales sobre qué cultivos sembrar, en qué proporción y en qué combinación, con el fin de utilizar los recursos de manera eficiente. Este enfoque es consistente con el planteo de este trabajo, que también busca determinar un mix óptimo de cultivos, aunque incorporando como variable central las condiciones climáticas predominantes.

De manera similar, Bhatia y Rana (2020) proponen un modelo de programación lineal para analizar el patrón de cultivos en distintos distritos del estado de Rajasthan, India. En su artículo *A Mathematical Approach to Optimize Crop Allocation – A Linear Programming Model*, los autores utilizan el software LINGO (software de optimización matemática) para identificar combinaciones de cultivos que maximicen los ingresos agrícolas. Destacan que la rotación de cultivos y la sinergia entre cultivos y ganadería son estrategias claves para mejorar la fertilidad

del suelo y reducir costos operativos. Este trabajo resalta la importancia de una planificación agrícola integrada y la optimización de los recursos disponibles.

En relación con la incertidumbre climática, Liu et al. (2007) desarrollan un modelo estocástico para optimizar la selección de seguros agrícolas bajo variabilidad climática y precios inciertos. En su trabajo *Optimizing Crop Insurance under Climate Variability* ponen de manifiesto el impacto de las fases ENSO y de los precios inciertos en las decisiones de contratación de seguros agrícolas. A través de un modelo basado en la función CVaR (Valor en Riesgo Condicional), los autores buscan ayudar a los agricultores a seleccionar seguros agrícolas de manera óptima, teniendo en cuenta su aversión al riesgo. Este modelo también permite asignar tierras a diferentes fechas de siembra, ajustando las decisiones con base en los pronósticos climáticos y la fase ENSO que se prevé para la campaña siguiente. El trabajo de Liu et al. es relevante para este estudio, dado que también considera la aversión al riesgo como un factor crucial para la toma de decisiones en un contexto de incertidumbre climática. Además, ambos estudios asumen que es posible conocer con anticipación la fase ENSO que predominará en la campaña siguiente, lo que permite realizar una planificación más informada.

Finalmente, una contribución relevante es la de Messina et al. (1999), quienes analizan la asignación de tierras en función de las fases del fenómeno ENSO en la región pampeana, específicamente en las localidades de Pergamino (Buenos Aires) y Santa Rosa (La Pampa), entre 1931 y 1999, período que precede al del presente trabajo. Si bien comparten con este estudio el interés por la asignación de tierras de acuerdo con las fases climáticas, existen diferencias claves en el enfoque metodológico. El modelo de Messina et al. (1999) maximiza una función de utilidad cóncava, que incorpora la riqueza inicial del productor y refleja su aversión al riesgo a través de una estructura intertemporal, esto último se explica en que ellos trabajan con funciones de utilidad que dependen de la riqueza y no exclusivamente del beneficio de un período aislado. En contraste, el modelo propuesto en este trabajo se basa en una función objetivo que maximiza el beneficio neto esperado del período, incorporando un componente de penalización por riesgo a través de un coeficiente de aversión (λ). Esta formulación, más sencilla y enfocada en el resultado económico directo, busca ofrecer una herramienta práctica de planificación adaptada a las condiciones específicas de cada fase ENSO, manteniendo la sensibilidad al riesgo sin requerir supuestos complejos sobre la riqueza inicial del productor.

1.4. Objetivo

El objetivo de esta tesis es desarrollar un modelo de optimización que determine la asignación óptima de cultivos en la región pampeana de Argentina para las fases del fenómeno ENSO, Niño y Niña, de manera independiente, con el fin de maximizar la rentabilidad y minimizar el riesgo en la producción agrícola.

El modelo propuesto en este trabajo tiene como objetivo maximizar el beneficio económico de los productores mediante la selección óptima de cultivos para cada fase climática, utilizando datos históricos de rendimientos agrícolas, costos de producción y precios internacionales de los cultivos más relevantes en la zona: maíz, soja (de primera y de segunda), trigo y girasol. Con el fin de contemplar la incertidumbre asociada a eventos climáticos extremos, el modelo incorpora un coeficiente de aversión al riesgo que incentiva la diversificación en la asignación de cultivos y reduce la volatilidad de los resultados económicos ante fluctuaciones climáticas.

La implementación de este modelo proporcionará a los agricultores una herramienta para tomar decisiones estratégicas más informadas y adaptadas al contexto climático esperado, maximizando la rentabilidad esperada y minimizando los riesgos asociados a las variaciones climáticas.

El trabajo se organiza de la siguiente manera: en la Sección 2 se presentan las fuentes de datos utilizadas, se analiza la participación de los cultivos en la superficie sembrada para seleccionar aquellos más representativos y se examina el impacto de las precipitaciones en los rendimientos de los cultivos en la región pampeana. Este análisis permite entender cómo varían los rendimientos de los diferentes cultivos en función de las precipitaciones, y subraya la importancia de anticipar la variabilidad climática para elegir los cultivos más adecuados según el fenómeno climático predominante en cada campaña. Finalmente, en esta sección se detallan los componentes de los costos y los precios de los cultivos.

En la Sección 3 se proporciona una descripción formal del problema propuesto, introduciendo la notación utilizada y presentando tres alternativas de modelado de riesgo, que darán lugar a tres modelos distintos. En la Sección 4 se expone el enfoque metodológico, detallando la construcción de los parámetros, el proceso de resolución y los diferentes análisis de sensibilidad realizados.

En la Sección 5 se presentan los resultados de los tres modelos para cada región y escenario climático, mostrando cómo varía la asignación óptima de cultivos en función de la aversión al riesgo. Además, se muestra la relación entre los objetivos de rentabilidad y riesgo a través de gráficos del Frente de Pareto. Por último, en esta sección, se comparan los resultados de los tres modelos, y se analiza la sensibilidad de excluir el cultivo de segunda (en este caso, soja de segunda), observando cómo afecta los resultados de la versión inicial.

Finalmente, en la Sección 6 se presentan las conclusiones del trabajo y se discuten posibles desarrollos futuros.

2. Capítulo 2: Datos

2.1. Fuente de datos

Los datos utilizados en este estudio provienen de diversas fuentes oficiales y del sector privado agropecuario.

La información sobre superficie sembrada, cosechada y producción de los cultivos analizados en este estudio (soja de primera, soja de segunda, trigo, maíz y girasol) fue obtenida del Ministerio de Agricultura, Ganadería y Pesca de Argentina (MAGyP). Estos registros abarcan desde la campaña 1969/70 hasta la campaña 2023/24 y están disponibles a nivel departamental y provincial, con un total de 41 cultivos relevados.

Los registros históricos de precipitaciones provienen del Servicio Meteorológico Nacional (SMN), que proporciona registros diarios de precipitaciones desde el año 2000, también organizados por departamento. El índice ONI (Oceanic Niño Index), proporcionado por la NOAA (National Oceanic and Atmospheric Administration), es fundamental para clasificar las campañas según la fase del fenómeno ENSO (Niño o Niña).


Por último, los precios internacionales de los cultivos fueron extraídos del Ministerio de Agricultura, Ganadería y Pesca de Argentina (MAGyP), mientras que los costos de producción fueron proporcionados por una empresa agropecuaria privada.

2.2. Participación de los cultivos en la superficie sembrada

En primera instancia, se analizó la participación de cada cultivo en la superficie total sembrada de Argentina durante las últimas diez campañas agrícolas (2014/15 - 2023/24). Este análisis se replicó para las provincias de Córdoba y Santa Fe, con el objetivo de comprender la distribución de cultivos en las regiones de interés.


Las Figuras 1, 2 y 3 ilustran la participación relativa de los principales cultivos en la superficie sembrada durante el período mencionado, para Argentina, Córdoba y Santa Fe, respectivamente.

Figura 1. Participación de los cultivos en la superficie sembrada en Argentina para el período que comprende las campañas 2014/15 al 2023/24




Fuente: elaboración propia en base a MAGyP.

Figura 2. Participación de los cultivos en la superficie sembrada en la provincia de Córdoba para el período que comprende las campañas 2014/15 al 2023/24



Fuente: elaboración propia en base a MAGyP.

Figura 3. Participación de los cultivos en la superficie sembrada en la provincia de Santa Fe para el período que comprende las campañas 2014/15 al 2023/24



Fuente: elaboración propia en base a MAGyP.

A partir del análisis, se identificó que cuatro cultivos predominan en la superficie sembrada tanto a nivel nacional como en Córdoba y Santa Fe: soja de primera, soja de segunda, trigo y maíz. Sin embargo, mientras que en Argentina y en Santa Fe el quinto cultivo en importancia es el girasol, en Córdoba este lugar lo ocupa el maní. En consecuencia, este estudio se enfocará en la optimización del mix de siembra de soja de primera, soja de segunda, maíz, trigo y girasol, con el objetivo de determinar la combinación óptima para un productor en función del fenómeno ENSO predominante (Niño o Niña).

Considerando que las precipitaciones y los rendimientos pueden variar dentro de una misma provincia, se decidió profundizar el análisis seleccionando departamentos representativos que, además, cuenten con registros históricos de lluvias.

En Córdoba se eligió el departamento de Río Cuarto, que lidera la superficie sembrada de la provincia, representando el 15% del total en las últimas diez campañas. En Santa Fe, se seleccionó el departamento de San Martín, el único dentro del top tres de superficie sembrada que, además, cuenta con registros de lluvias proporcionados por el Servicio Meteorológico Nacional (SMN).

2.3. Análisis del impacto de las precipitaciones en los rendimientos de los cultivos en la región pampeana

En esta sección se analiza la evolución de los rendimientos de los cultivos en función de las precipitaciones registradas y del fenómeno climático asociado (Niño, Niña o Neutro), para el período comprendido entre las campañas 2000/01 y 2023/24.

2.3.1. Consideraciones metodológicas sobre el cálculo de rendimientos

Existen dos métodos principales para estimar el rendimiento agrícola:

Producción sobre superficie cosechada: El rendimiento se calcula dividiendo la producción total de un cultivo entre la superficie efectivamente cosechada. Es la métrica más utilizada en estadísticas agrícolas, ya que refleja la productividad de las hectáreas que lograron completar su ciclo y llegar a la cosecha. Su ventaja radica en que proporciona un indicador directo de la eficiencia de la producción en las hectáreas exitosamente explotadas. Sin embargo, no contempla la superficie perdida por factores climáticos, plagas u otras adversidades que impiden la cosecha, lo cual puede subestimar el impacto real de estos eventos sobre la producción.

Producción sobre superficie sembrada: Este enfoque calcula el rendimiento dividiendo la producción total entre la superficie originalmente sembrada, incluyendo aquellas hectáreas que no lograron ser cosechadas. Este método proporciona una perspectiva más integral de la eficiencia productiva del cultivo, al incluir las pérdidas debidas a fenómenos climáticos adversos o plagas.

Dado que el objetivo de este estudio es la optimización del mix de cultivos en función del fenómeno climático (Niño o Niña), se optó por utilizar la métrica de rendimiento basada en superficie sembrada. Esta elección se fundamenta principalmente en poder incluir aquellas hectáreas sembradas que se perdieron antes de la cosecha debido a condiciones climáticas adversas. De esta manera, se tiene una estimación más realista del impacto de los fenómenos climáticos en la producción agrícola, a la vez que nos permite identificar aquellos cultivos que presentan una menor tasa de pérdida en escenarios de Niño o Niña.

2.3.2. Identificación de períodos críticos por cultivo

El análisis de rendimientos se realizó por cultivo y por departamento, iniciando con la identificación de los meses críticos en los que las precipitaciones tienen impacto determinante en el rendimiento. A continuación, se detallan los períodos claves de cada cultivo:

Girasol:

- *Siembra: Agosto – Octubre.* En este período se necesita humedad en el suelo para una buena germinación.
- *Crecimiento vegetativo: Septiembre – Noviembre.* La planta desarrolla hojas y raíces, el agua ayuda a establecer un buen cultivo.

- *Floración y polinización: Noviembre – Diciembre.* Es la etapa crítica, y es la que necesita más del agua. La falta de agua reduce la cantidad de flores fecundadas y, por lo tanto, el número de granos en la flor.
- *Llenado de granos: Diciembre – Febrero.* De gran relevancia al igual que la etapa anterior. El estrés hídrico en esta etapa afecta el tamaño y peso de los granos, reduciendo el rendimiento final.

Por tanto, los meses claves para este cultivo son entre *noviembre y enero*, durante la floración y llenado de granos.

Maíz

- *Siembra: Septiembre – Octubre.* Se necesita buena humedad para la germinación.
- *Floración y polinización: Diciembre – Enero.* Este período es el más crítico, si falta agua en esta etapa, se reduce la cantidad de granos por mazorca.
- *Llenado de granos: Enero – Febrero.* Relevante también, el estrés hídrico reduce el tamaño y peso de los granos.

Por tanto, las lluvias más importantes son de *diciembre a febrero*.

Soja de Primera

- *Siembra: Octubre – Noviembre.* Se necesita humedad en el suelo para una correcta implantación.
- *Floración: Diciembre – Enero.* Es el inicio del desarrollo reproductivo, la falta de agua puede reducir la cantidad de flores y afectar el rendimiento.
- *Llenado de granos: Enero – Marzo.* Es el período más crítico. Si hay sequía en esta etapa, afecta el peso y tamaño de los granos, bajando el rendimiento.

En resumen, *diciembre a febrero* es la etapa que la soja de primera requiere más lluvias. Si hay sequía en esos meses, el impacto en el rendimiento puede ser fuerte.

Soja de Segunda

La soja de segunda se llama así porque se siembra de manera tardía, luego de la cosecha de otro cultivo. En la región pampeana de Argentina, generalmente se siembra tras el trigo.

- *Siembra: Diciembre – Enero.* Se necesita humedad para una buena implantación.
- *Floración: Febrero – Marzo.* Es una etapa sensible; el estrés hídrico puede reducir la cantidad de flores y comprometer el desarrollo de las vainas.
- *Llenado de granos: Marzo – Mayo.* Es el período más crítico. Si hay sequía, los granos tienen menor tamaño y el rendimiento baja.

Por tanto, para la soja de segunda, las lluvias son clave entre *febrero y abril*. Si hay déficit hídrico en esta etapa, el rendimiento puede verse muy afectado. Además, al sembrarse más tarde, este cultivo enfrenta un mayor riesgo climático, como menor disponibilidad de agua en el otoño o posibles heladas tempranas.

Trigo

- *Siembra: Mayo – Julio.* Se necesita humedad en el suelo para una buena implantación.
- *Macollaje y encañazón: Julio – Septiembre.* Fase de crecimiento vegetativo, el trigo necesita agua para desarrollar un buen número de tallos y hojas.
- *Floración y llenado de granos: Octubre – Noviembre.* Período más crítico. Si falta agua en esta etapa, se reduce la cantidad de granos por espiga y el peso final del grano, afectando el rendimiento.

Las lluvias más importantes son entre *agosto y octubre*, especialmente durante la floración y llenado de granos.

A partir de la identificación de los períodos críticos para cada cultivo, se procedió a relacionar dichos intervalos con los registros históricos de precipitaciones correspondientes a esos mismos meses en cada campaña. Esta asociación permitió construir una variable representativa del nivel de lluvias durante las etapas más sensibles de cada cultivo en cada región analizada. Dicha variable no solo fue utilizada para analizar su relación con los rendimientos, sino también para caracterizar climáticamente cada campaña a nivel local.

Si bien el índice ONI (Oceanic Niño Index) es una referencia internacional ampliamente utilizada para clasificar los años como Niño, Niña o Neutro, su cálculo se basa en anomalías de temperatura del océano Pacífico central y no necesariamente refleja con precisión las condiciones climáticas específicas de la región pampeana argentina. En los datos analizados se observaron campañas en las que una misma fase ENSO tuvo efectos disímiles entre departamentos: por ejemplo, años definidos como “Niña” según el ONI presentaron niveles de precipitación compatibles con un año “Neutro” o incluso “Niño” en determinadas zonas, y viceversa.

Por esta razón, se complementó la clasificación ONI con una caracterización climática local, basada en los registros históricos de precipitaciones en los meses clave para cada cultivo. Esta clasificación se realizó comparando la precipitación acumulada en dichos períodos con el promedio histórico para cada cultivo y región. De esta manera, se definieron umbrales específicos para cada cultivo, con base en el análisis empírico de los rendimientos observados bajo distintos niveles de precipitación.

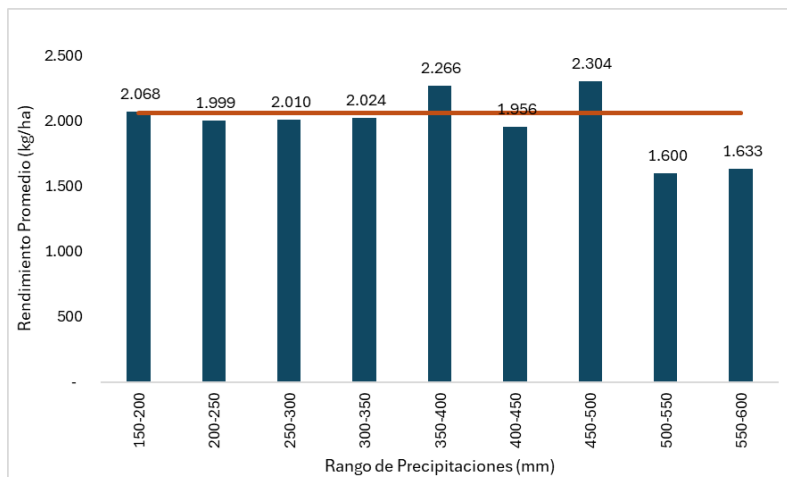
Estos umbrales y la metodología de clasificación climática local se presentan en la siguiente sección.

2.3.3. Análisis del rendimiento promedio en función de rangos de precipitaciones

Como primer paso del análisis, se evaluó el rendimiento promedio de cada cultivo en función de distintos rangos de precipitaciones, con el objetivo de identificar los niveles de precipitaciones asociados a mejores y peores rendimientos productivos. Para ello, se agruparon las campañas según intervalos de precipitaciones acumuladas durante el período crítico de cada cultivo, y se calculó el rendimiento medio correspondiente a cada rango. Esta información se representa en los gráficos a continuación, donde el eje horizontal indica los rangos de precipitaciones y el eje vertical el rendimiento promedio (en kg/ha).

Girasol: Los rendimientos del girasol se mantienen estables, en torno a los 2.000 kg/ha, cuando las precipitaciones se encuentran en un rango intermedio de entre 150 y 450 mm, lo cual sugiere que este cultivo presenta buen desempeño bajo condiciones hídricas moderadas. Sin embargo, cuando las precipitaciones superan los 500 mm, se observa una caída significativa en los rendimientos, que descienden hasta 1.600 kg/ha. Este patrón indicaría que el exceso de agua puede afectar negativamente el rendimiento del cultivo (véase Figura 4).


Figura 4. Rendimiento Promedio Girasol para los departamentos de Río Cuarto y San Martín en función de los rangos de precipitaciones



Fuente: elaboración propia en base a MAGyP y SMN.

Maíz: En el caso del maíz, los rendimientos son considerablemente inferiores al promedio en rangos bajos de precipitaciones, cuando no alcanzan los 350 mm. Los rendimientos mejoran notablemente y superan el promedio cuando los niveles de lluvia aumentan, alcanzando los mejores rendimientos en el rango de 400-600 mm. Esto sugiere que, a diferencia del girasol, el maíz se beneficia de niveles elevados de precipitaciones, tal como se evidencia en la Figura 5.

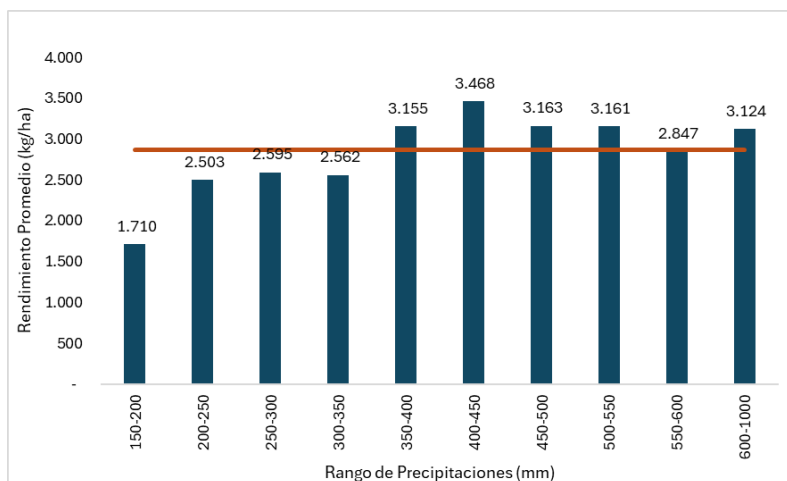
Figura 5. Rendimiento Promedio Maíz para los departamentos de Río Cuarto y San Martín en función de los rangos de precipitaciones



Fuente: elaboración propia en base a MAGyP y SMN.

Soja de Primera: Para la soja de primera, los menores rendimientos se registran con precipitaciones inferiores a 200 mm. En rangos intermedios (200–350 mm), el rendimiento mejora levemente, aunque aún se encuentra por debajo del promedio histórico. El mejor desempeño se observa con lluvias superiores a 350 mm, lo que indica que, al igual que el maíz, la soja de primera requiere un umbral hídrico elevado para alcanzar buenos rendimientos. Estos resultados se pueden observar en la Figura 6.

Figura 6. Rendimiento Promedio Soja de Primera para los departamentos de Río Cuarto y San Martín en función de los rangos de precipitaciones




Fuente: elaboración propia en base a MAGyP y SMN.

Soja 2da: La soja de segunda, generalmente sembrada luego de la cosecha del trigo, presenta un rendimiento promedio inferior al de la soja de primera. Esto se debe principalmente a que sus etapas de siembra, floración y llenado de granos ocurren más tarde en la temporada, cuando las lluvias y la humedad del suelo suelen ser menores.

En cuanto a la relación entre precipitaciones y rendimiento, se observa que niveles bajos de lluvia (100-200 mm) afectan negativamente su productividad. Sin embargo, cuando las precipitaciones superan los 200 mm, el rendimiento mejora y se sitúa por encima del promedio. A diferencia de la soja de primera, cuyo rendimiento óptimo se alcanza con más de 350 mm de lluvia, la soja de segunda muestra mejoras con menores cantidades de agua (véase Figura 7).


Figura 7. Rendimiento Promedio Soja de Segunda para los departamentos de Río Cuarto y San Martín en función de los rangos de precipitaciones



Fuente: elaboración propia en base a MAGyP y SMN.

Trigo: El desarrollo del trigo requiere las lluvias más importantes entre agosto y octubre, meses caracterizados por menores temperaturas y lluvias más escasas. En consecuencia, y tal como se observa en la Figura 8, se alcanzan buenos rendimientos, superiores al promedio, con precipitaciones comprendidas entre 100 y 250 mm. Las lluvias por debajo de los 100 mm, así como las que superan los 350 mm, afectan negativamente su rendimiento.

Figura 8. Rendimiento Promedio Trigo para los departamentos de Río Cuarto y San Martín en función de los rangos de precipitaciones



Fuente: elaboración propia en base a MAGyP y SMN.

Aunque el análisis inicial sugiere que precipitaciones superiores a 350 mm afectan negativamente el rendimiento del trigo, en nuestro estudio se observa que en el rango de 500 a 600 mm el rendimiento promedio supera al promedio general. Esta aparente contradicción podría explicarse por factores adicionales no considerados en el análisis de precipitación total, tales como la distribución temporal de las lluvias, la calidad del suelo y su capacidad de drenaje.

La relación entre precipitaciones y rendimiento presenta diferencias significativas según el cultivo analizado. Mientras que el maíz y la soja de primera muestran mejoras notables en sus rendimientos frente a lluvias abundantes, el girasol y el trigo alcanzan su rendimiento óptimo bajo condiciones hídricas moderadas, viéndose afectados por el exceso de precipitaciones. Por su parte, la soja de segunda presenta un umbral más bajo, mejorando su desempeño con lluvias superiores a 200 mm, aunque sin llegar a niveles productivos comparables a los de la soja de primera.

De este análisis se desprende la metodología utilizada para clasificar las campañas como *Niña*, *Neutro* o *Niño*. El trabajo consistió en analizar el rendimiento promedio y la precipitación media registrada para cada cultivo y para cada una de las dos regiones estudiadas (Río Cuarto y San Martín). A partir de estos valores históricos, se definieron umbrales específicos de precipitación para identificar desvíos significativos respecto de lo esperado, considerando la sensibilidad particular de cada cultivo a las condiciones hídricas.

Los coeficientes aplicados para calcular estos umbrales fueron definidos en función de la sensibilidad hídrica de cada cultivo:

- **Girasol y trigo:**
 - Año *Niña*: precipitación < promedio \times 0,8
 - Año *Niño*: precipitación > promedio \times 1,2
- **Maíz y soja de primera:**
 - Año *Niña*: precipitación < promedio \times 0,85
 - Año *Niño*: precipitación > promedio \times 1,15
- **Soja de segunda:**
 - Año *Niña*: precipitación < promedio \times 0,3
 - Año *Niño*: precipitación > promedio \times 1,3


Estos coeficientes se aplicaron a los promedios históricos calculados para cada cultivo y región, obteniendo umbrales específicos de precipitación acumulada para clasificar las campañas.

2.3.4. Evolución histórica del rendimiento y precipitaciones por campaña

Luego de analizar el comportamiento promedio del rendimiento de los cultivos en función de distintos niveles de precipitaciones, resulta pertinente observar cómo estas variables evolucionaron conjuntamente a lo largo del tiempo en los departamentos seleccionados. En esta sección se analizan las campañas agrícolas desde 2000/01 hasta 2023/24, con el objetivo de identificar patrones, años atípicos y posibles factores adicionales que hayan afectado los rendimientos.

Girasol


Figura 9. Rendimientos girasol y precipitaciones por campaña en departamento Río Cuarto (Córdoba) desde el 2000/01 al 2023/24



Fuente: elaboración propia en base a MAGyP y SMN.

En Río Cuarto, el rendimiento del girasol se mantuvo, a lo largo de las distintas campañas, relativamente cercano a la media, incluso ante variaciones importantes en las precipitaciones. El valor más alto se registró en la campaña 2007/08, cuando las precipitaciones superaron los 400 mm. En contraste, se observan dos caídas marcadas: una en 2005/06, con precipitaciones cercanas a 300 mm, podría haberse visto afectado por otros factores como plagas o piedras, ya que para precipitaciones similares se dieron rendimientos cercanos al promedio; y otra en 2022/23 que corresponde a la última gran sequía que atravesó el país (véase Figura 9).

Figura 10. Rendimientos girasol y precipitaciones por campaña en departamento San Martín (Santa Fe) desde el 2000/01 al 2023/24




Fuente: elaboración propia en base a MAGyP y SMN.

En el departamento San Martín, el rendimiento del girasol muestra una mayor variabilidad. Se identifican valles tanto en años con lluvias elevadas (2006/07 y 2016/17) como en campañas secas (2022/23). Para niveles moderados de precipitaciones, los rendimientos tienden a estabilizarse cerca de los 2.000 kg/ha, lo que sugiere un mejor desempeño del cultivo bajo condiciones hídricas intermedias (véase Figura 10).


Maíz

Figura 11. Rendimientos maíz y precipitaciones por campaña en departamento Río Cuarto (Córdoba) desde el 2000/01 al 2023/24



Fuente: elaboración propia en base a MAGyP y SMN.

Figura 12. Rendimientos maíz y precipitaciones por campaña en departamento San Martín (Santa Fe) desde el 2000/01 al 2023/24



Fuente: elaboración propia en base a MAGyP y SMN.


El maíz muestra una correlación positiva con el nivel de precipitaciones en ambos departamentos. Las campañas con menores niveles hídricos, como 2001/02, 2008/09 y especialmente 2022/23, presentan los valores de rendimiento más bajos. En contraposición,

los mejores resultados se registraron en campañas con precipitaciones acumuladas entre 400 y 600 mm, destacándose la sensibilidad del cultivo a condiciones de estrés hídrico.

Vale la pena resaltar que excesos hídricos como la campaña 2015/16 afectaron su rendimiento por debajo de la media, este comportamiento se observa en particular en el departamento San Martín (véanse Figuras 11 y 12).


Soja de Primera

Figura 13. Rendimientos soja de primera y precipitaciones por campaña en departamento Río Cuarto (Córdoba) desde el 2000/01 al 2023/24



Fuente: elaboración propia en base a MAGyP y SMN.

Figura 14. Rendimientos soja de primera y precipitaciones por campaña en departamento San Martín (Santa Fe) desde el 2000/01 al 2023/24



Fuente: elaboración propia en base a MAGyP y SMN.


En el caso de la soja de primera, al igual que el maíz, se observan valles en los rendimientos durante campañas con bajos niveles de precipitaciones, como en 2008/09, 2017/18 y especialmente en 2022/23. Sin embargo, como se observa en el departamento de San Martín,

lluvias excesivas, como las registradas en 2015/16, también afectan el rendimiento, reduciéndolo por debajo del promedio.

En términos generales, la soja de primera presenta un mejor desempeño en años con niveles de lluvias que oscilan entre intermedios y altos, aunque sin excesos prolongados (véanse Figuras 13 y 14).


Soja de Segunda

Figura 15. Rendimientos soja de segunda y precipitaciones por campaña en departamento Río Cuarto (Córdoba) desde el 2000/01 al 2023/24



Fuente: elaboración propia en base a MAGyP y SMN.

Figura 16. Rendimientos soja de segunda y precipitaciones por campaña en departamento San Martín (Santa Fe) desde el 2000/01 al 2023/24




Fuente: elaboración propia en base a MAGyP y SMN.

En ambos departamentos, la soja de segunda presenta rendimientos sistemáticamente inferiores a los de soja de primera. Se destacan dos campañas con valles muy marcados: 2017/18 y 2022/23, ambas afectadas por déficit hídrico. A diferencia de otros cultivos, en años

con precipitaciones algo más acotadas (por encima de 200 mm), los rendimientos pueden mantenerse cercanos al promedio, lo que sugiere una tolerancia relativa a condiciones menos favorables, tal como se observa en las Figuras 15 y 16.


Trigo

Figura 17. Rendimientos trigo y precipitaciones por campaña en departamento Río Cuarto (Córdoba) desde el 2000/01 al 2023/24



Fuente: elaboración propia en base a MAGyP y SMN.

Figura 18. Rendimientos trigo y precipitaciones por campaña en departamento San Martín (Santa Fe) desde el 2000/01 al 2023/24



Fuente: elaboración propia en base a MAGyP y SMN.

En ambos departamentos, como muestran las Figuras 17 y 18, los rendimientos del trigo son muy variables alrededor del promedio, con picos y valles marcados. En general, los valles tienden a coincidir con campañas en las que las precipitaciones durante el período crítico de primavera estuvieron por debajo de los 100 mm.

2.4. Costos de producción de los cultivos

Los costos de producción utilizados en este modelo fueron proporcionados por una empresa agropecuaria y corresponden exclusivamente a los insumos y servicios directamente asociados al cultivo. Se asume que tanto la tierra como la maquinaria son propiedad de la empresa, y que los gastos de personal constituyen costos hundidos, por lo que no se incluyen en el análisis.

El desglose de costos por hectárea incluye insumos como herbicidas, fertilizantes, semillas y fumigación, así como los costos de "siembra y cosecha", que en este caso refieren al gasto en combustible.

Tabla 1. Costos de producción girasol en USD/ha

Producto	Cantidad	Precio por unidad (UDS)	Costo Total (USD)
Glifosato	3,2	6,5	20,8
Gramini	1,5	11,4	17,1
Dedalo	1,2	6,5	7,8
Mesulfuron	0,0	44,0	0,4
Flurocloridona	1,1	27,3	30,0
Smetaloclor	1,1	11,8	13,0
Cowoy Elite	0,2	10,8	1,6
Sulfato de amonio	0,9	1,5	1,4
Epsilon	0,2	53,0	10,3
Fumigación	3,0	2,0	6,0
Semillas	0,3	330,0	110,0
Siembra y cosecha (combustible)	20,0	1,2	24,0
Costo total por hectárea		USD	242,49

En el caso del Girasol, como se observa en la Tabla 1, el insumo más costoso en este cultivo es la semilla, que representa una parte significativa del total. Le siguen en importancia los herbicidas como Glifosato, Flurocloridona, Gramini, Smetaloclor y Epsilon.

Tabla 2. Costos de producción soja en USD/ha

Producto	Cantidad	Precio por unidad (UDS)	Costo Total (USD)
Glifosato	7,0	6,5	45,5
Gramini	3,2	11,4	36,4
Dédalo	3,5	6,5	22,9
Mesulfuron	0,0	44,0	0,4
Paraquat	3,0	3,5	10,5
Flumexacin	0,2	45,0	6,8
Cowoy elite	0,2	10,8	1,6
Sulfato de amonio	2,0	1,5	3,0
Insecticida	1,0	14,0	14,0
Fumigación	5,0	2,0	10,0
Semillas	65,0	1,0	65,0
Siembra y cosecha (combustible)	35,0	1,2	42,0
Costo total por hectárea		USD	258,08

El costo de producción es el mismo para soja de primera y de segunda, ya que los insumos y labores son similares. Sin embargo, la principal diferencia entre ambas radica en los ciclos de cultivo y el riesgo asociado. La soja de primera se siembra antes y tiene un ciclo más largo, lo

que le permite aprovechar mejor las lluvias del verano y obtener rendimientos más altos en condiciones climáticas favorables. En cambio, la soja de segunda se siembra luego de la cosecha del trigo, en un período más tardío, con un ciclo más corto y mayor riesgo de estrés hídrico en caso de lluvias insuficientes.

Como muestra la Tabla 2, la semilla es el insumo más caro, seguida por los costos de siembra y cosecha (combustible) y los herbicidas, que incluyen Glifosato, Gramini, Dédalo, Mesulfuron, Paraquat y Flumexacin.

Tabla 3. Costos de producción trigo en USD/ha

Producto	Cantidad	Precio por unidad (UDS)	Costo Total (USD)
Glifosato	1,5	6,5	9,8
Gramini	-	11,4	-
Dédalo	1,2	6,5	7,8
Mesulfuron	0,0	44,0	0,5
Flurocloridona	-	27,3	-
Smetaloclor	-	11,8	-
Cowoy elite	0,2	10,8	2,2
Sulfato de amonio	1,0	1,5	1,5
Fertilizante (urea)	110,0	0,7	77,0
Fumigación	1,0	2,0	2,0
Semillas	115,0	1,0	80,0
Siembra y cosecha (combustible)	20,0	1,2	24,0
Costo total por hectárea		USD	204,77

El trigo es el cultivo con menor costo por hectárea entre los analizados, debido a la menor cantidad de insumos utilizados. No requiere ciertos herbicidas aplicados en otros cultivos, lo que reduce significativamente los costos.

El insumo más costoso es el fertilizante, con un valor de 77 USD/ha, lo que representa el 37 % del costo total (véase Tabla 3). Este insumo es clave para garantizar buenos rendimientos, ya que el trigo es muy dependiente de la disponibilidad de nitrógeno en el suelo. En el presente estudio, el fertilizante empleado es urea granulada, con una concentración de nitrógeno del 46%, siendo este el fertilizante con la mayor concentración de N disponible (Profertil, s.f.).

Tabla 4. Costos de producción maíz en USD/ha

Producto	Cantidad	Precio por unidad (UDS)	Costo Total (USD)
Glifosato	4,0	6,5	26,0
Fertilizante (urea)	110,0	0,7	77,0
Dédalo	4,0	6,5	26,1
Mesulfuron	0,0	44,0	0,4
Atrazina	4,0	11,4	45,4
Smetaloclor	1,1	11,8	13,0
Cowoy elite	0,4	10,8	4,3
Sulfato de amonio	1,5	1,5	2,3
Glufosinato	3,0	6,0	18,0
Fumigación	3,0	2,0	6,0
Semillas	1,0	200,0	200,0
Siembra y cosecha (combustible)	30,0	1,2	36,0
Costo total por hectárea		USD	454,58

El maíz es el cultivo con mayor costo de producción por hectárea, alcanzando 454,58 USD/ha (véase Tabla 4). Su alto costo se debe principalmente al precio de la semilla y al uso intensivo de insumos, como fertilizantes y herbicidas.

Con 200 USD/ha, el maíz tiene el mayor costo de semillas entre los cultivos analizados. Esto se debe a que las semillas híbridas utilizadas en maíz poseen un alto valor tecnológico, ofreciendo resistencia a plagas y mayor potencial de rendimiento. Además, el maíz requiere una gran cantidad de fertilizante nitrogenado, como la urea, con un costo de 77 USD/ha, fundamental para alcanzar altos rendimientos. A diferencia del trigo y la soja, el maíz necesita una combinación de herbicidas (Glifosato, Atrazina, Smetaloclor) y desecantes como el Glufosinato, lo que incrementa el costo total del cultivo.

Si bien el maíz es el cultivo más costoso de implantar, también es el que puede ofrecer mayores rendimientos en condiciones favorables, logrando la mayor producción en toneladas por hectárea sembrada. En campañas con buena disponibilidad hídrica, su rentabilidad puede superar ampliamente a la de otros cultivos. Sin embargo, su alto costo implica también un mayor riesgo económico para el productor.

2.5. Precios internacionales de los cultivos


El análisis de los precios internacionales de cada uno de los cultivos incluidos en este estudio resulta fundamental para comprender las dinámicas del sector agropecuario y estimar el ingreso potencial de cada alternativa productiva.

En esta sección se realiza, en primer lugar, un repaso de la evolución de los precios promedios mensuales internacionales correspondientes al período 2000–2024 para los cultivos considerados en el estudio (soja, maíz, trigo y girasol). A continuación, se detalla el criterio seguido para la selección de los precios utilizados en el modelo.

Los precios de referencia fueron obtenidos de fuentes oficiales: en el caso del girasol, se utilizaron los valores FOB del mercado de Buenos Aires, mientras que para el resto de los cultivos se tomaron los precios del mercado de Chicago, todos expresados en dólares por tonelada (USD/tn).

Las Figuras 19 a 22 ilustran la evolución de los precios promedios mensuales de cada cultivo. En todos los casos se observa una tendencia creciente a lo largo del período, con variaciones estacionales y picos asociados a coyunturas internacionales. Un hito relevante se produjo en el año 2008, asociado a un fuerte incremento en la demanda global de alimentos, particularmente por parte de China, que comenzó a aumentar de manera sostenida sus importaciones de granos, en particular de soja. Este fenómeno marcó una etapa conocida como el *boom* de la soja, con precios internacionales en niveles históricamente elevados.

Figura 19. Precio Promedio Mensual Girasol en el Mercado de Buenos Aires (USD/tn)




Fuente: elaboración propia en base a MAGyP.

Figura 20. Precio Promedio Mensual Trigo en el Mercado de Chicago (USD/tn)




Fuente: elaboración propia en base a MAGyP.

Figura 21. Precio Promedio Mensual Soja en el Mercado de Chicago (USD/tn)



Fuente: elaboración propia en base a MAGyP.

Figura 22. Precio Promedio Mensual Maíz en el Mercado de Chicago (USD/tn)



Fuente: elaboración propia en base a MAGyP.

Para el presente estudio, se considera que el productor se encuentra en mayo de 2024, momento clave para planificar la campaña agrícola 2024/25. En este contexto, debe decidir qué cultivo sembrar, comenzando por el trigo, cuya siembra inicia en esta época del año.

Con el objetivo de estimar los ingresos potenciales de cada alternativa productiva, se tomaron como referencia los precios a futuro disponibles en los mercados internacionales en mayo de 2024. Esta práctica es habitual en el sector agrícola, donde los contratos a futuro permiten fijar precios de venta antes de la cosecha.

En particular, se utilizaron los siguientes precios futuros:

- Para girasol, maíz y soja, se tomaron los precios correspondientes a mayo de 2025, mes próximo a la cosecha de estos cultivos.
- Para trigo, se consideró el precio futuro de diciembre de 2024, ya que se ajusta mejor al período de cosecha. Utilizar el precio de mayo de 2025 podría resultar engañoso debido a la menor disponibilidad del producto en esa época, lo que tiende a elevar artificialmente su cotización.

Los precios internacionales, expresados en dólares por tonelada (USD/tn), fueron ajustados por los derechos de exportación vigentes al momento del análisis, con el objetivo de estimar el precio neto percibido por el productor argentino. Los valores considerados se resumen en la Tabla 5.

Tabla 5. Precio Neto percibido por el productor

Cultivo	Precio internacional	Retención	Precio Neto
TRIGO	251,6	9,5%	227,7
SOJA 1RA	446,7	26%	330,6
MAIZ	198,0	9,5%	179,2
GIRASOL	450,0	5,5%	425,3
SOJA 2DA	446,7	26%	330,6

3. Capítulo 3: Metodología

El presente trabajo tiene como objetivo determinar la asignación óptima de cultivos en función de la fase ENSO predominante durante la campaña, con el fin de maximizar el beneficio esperado del productor. Se incorpora el riesgo asociado a la variabilidad del rendimiento agrícola, de modo que el modelo proponga una estrategia de siembra que contemple tanto la rentabilidad esperada como la aversión al riesgo del productor.

Se parte de la premisa que los precios son conocidos ya que los agricultores tienen acceso a los precios internacionales futuros antes de sembrar y pueden fijar sus precios mediante contrato. Asimismo, se considera que los costos de producción son conocidos previamente. Este enfoque permite aislar el riesgo climático del riesgo de precios en nuestro análisis.

Dado un conjunto de cultivos C , la variable de decisión $x_c \forall c \in C$ representa la cantidad de hectáreas asignadas al cultivo c . Dado que el análisis se centra en la región pampeana argentina, se define el conjunto de cultivos como $C = \{\text{soja de primera, maíz, girasol, trigo, soja de segunda}\}$. Además, se supone que el productor dispone de 1.000 hectáreas sobre las cuales tiene que decidir que sembrar.

El beneficio neto agrícola (US\$) se calcula según la Ecuación (1):

$$\sum_{c \in C} (p_c r_c - c_c) x_c \quad (1)$$

Donde p_c es el precio internacional del cultivo c expresado en USD/tn, r_c es el rendimiento esperado del cultivo c expresado en tn/ha y c_c es el costo del cultivo c en USD/ha.

Si bien el modelo parte del supuesto de que se conoce con anticipación la fase ENSO predominante en la campaña, las condiciones climáticas continúan siendo inciertas. Por ello, la función objetivo del modelo no solo maximiza el beneficio esperado, sino que también incorpora un término de penalización asociado al riesgo derivado de la variabilidad en los rendimientos.

A continuación, se proponen tres alternativas de modelado del riesgo, todas con el mismo objetivo de maximizar el beneficio esperado neto del productor, penalizando la exposición al riesgo climático. Estas formulaciones se basan en los principios derivados del modelo de optimización de portafolios de Markowitz, el cual busca la cartera óptima de activos en términos de rentabilidad esperada y riesgo. En el contexto de la agricultura, la rentabilidad esperada se entiende como el beneficio neto agrícola, mientras que el riesgo está representado por la variabilidad de los rendimientos de cada cultivo.

El modelo de Markowitz, propuesto por Harry Markowitz en 1952, se fundamenta en la teoría de la media-varianza, donde el retorno esperado de un portafolio (o, en este caso, el beneficio agrícola) se maximiza, mientras que el riesgo, medido como la varianza de los retornos, se minimiza. Markowitz muestra que es posible reducir el riesgo global mediante la diversificación de los activos (cultivos en nuestro caso), seleccionando aquellos que no presentan una correlación perfecta entre sí. Este enfoque resulta esencial para los productores agrícolas,

quienes deben gestionar el riesgo inherente a la variabilidad climática y a las fluctuaciones en los rendimientos de los cultivos.

Siguiendo el enfoque de Markowitz, se proponen tres alternativas de modelado del riesgo, cada una incorpora una penalización por la variabilidad en los rendimientos de los cultivos. Estas penalizaciones están diseñadas para reflejar la aversión al riesgo del productor, quien busca no solo maximizar los beneficios esperados, sino también minimizar la exposición a fluctuaciones negativas en los rendimientos, especialmente aquellas derivadas de la variabilidad climática asociada a los fenómenos Niño y Niña. En cada una de las alternativas, el objetivo es encontrar la asignación óptima de hectáreas entre los diferentes cultivos de manera tal que maximice el beneficio esperado, mientras que minimiza el riesgo provocado por la incertidumbre en los rendimientos.

Alternativa 1: Esta formulación penaliza la incertidumbre en los rendimientos utilizando la desviación estándar ponderada por la superficie sembrada. La función objetivo queda expresada según la Ecuación (2):

$$\max \sum_{c \in C} (p_c r_c - c_c) x_c - \lambda \sum_{c \in C} \sigma_c x_c^2 \quad (2)$$

Donde λ es el coeficiente de aversión al riesgo, σ_c es la desviación estándar del rendimiento del cultivo c (medida de riesgo) y x_c^2 modela la penalización por riesgo de manera cuadrática, lo que implica que, a mayor superficie destinada a un cultivo, mayor será la penalización.

Alternativa 2: Esta formulación penaliza directamente la varianza del ingreso, incorporando tanto el precio como la variabilidad del rendimiento. La función objetivo queda expresada según la Ecuación (3):

$$\max \sum_{c \in C} (p_c r_c - c_c) x_c - \lambda \sum_{c \in C} (p_c \sigma_c x_c)^2 \quad (3)$$

Esta representación es especialmente útil para capturar la exposición al riesgo económico, dado que considera simultáneamente la incertidumbre en el rendimiento y la magnitud del precio. Esto significa que el modelo minimiza la volatilidad del ingreso, castigando más a cultivos con:

- Mayor precio (p_c): Porque una variación en el rendimiento tiene un impacto mayor en el ingreso total.
- Mayor variabilidad del rendimiento: Cultivos más inestables son más penalizados.
- Mayor superficie sembrada: Aumentar la cantidad de hectáreas de un cultivo amplifica el riesgo total.

Alternativa 3: Esta formulación penaliza la variabilidad del beneficio neto, cuya función objetivo se expresa en la Ecuación (4):

$$\max \sum_{c \in C} (p_c r_c - c_c) x_c - \lambda \sum_{c \in C} (p_c \sigma_c - c_c)^2 x_c^2 \quad (4)$$

El riesgo en este modelo sigue estando determinado solo por la variabilidad del rendimiento σ_c . Pero a diferencia del anterior que solo agregaba el precio, se incorporan los costos, aunque tanto precios como costos en este modelo únicamente escalan el efecto del riesgo sin constituir fuentes de riesgo por sí mismos.

En todas las alternativas de función objetivo, el primer término representa la rentabilidad esperada, mientras que el segundo introduce una penalización creciente por exposición al riesgo, la cual aumenta con la superficie asignada a cada cultivo. Las tres alternativas de modelado permiten explorar distintas formas de representar el riesgo climático en la toma de decisiones agrícolas. El coeficiente λ actúa como un parámetro de ajuste que refleja el nivel de aversión al riesgo del productor:

- Si $\lambda = 0$, el productor es neutral al riesgo y el modelo se enfoca exclusivamente en la maximización del beneficio esperado sin importar el riesgo.
- Si $\lambda > 0$, el productor es averso al riesgo, y el modelo tenderá a diversificar la asignación de superficie, evitando asignar grandes áreas a cultivos con alta variabilidad.

El modelo se encuentra sujeto a las siguientes restricciones:

Restricción de Superficie Total

La suma de las hectáreas asignadas a cada cultivo, excluyendo al cultivo de segunda (que se siembra luego de la cosecha de otro cultivo), debe ser exactamente igual a la superficie total disponible del productor, denotada por H, tal como se expresa en la Ecuación (5):

$$\sum_{c \in C, c \neq \text{cultivo_2da}} x_c = H \quad (5)$$

Para el modelo de este trabajo, esta restricción se especifica en la Ecuación (6) como:

$$\sum_{c \in C, c \neq \text{soja_2da}} x_c = 1000 \quad (6)$$

Restricción Cultivo de Segunda

La cantidad de hectáreas asignadas al cultivo de segunda no puede superar la superficie sembrada del cultivo que le precede, como se indica en la Ecuación (7):

$$x_{cultivo_2da} \leq x_{cultivo_1ra} \quad (7)$$

En el modelo en cuestión, esta restricción garantiza que la cantidad de hectáreas asignadas a soja de segunda no supere la superficie sembrada de trigo, ya que la soja de segunda se siembra luego de cosechar el trigo, tal como indica Ecuación (8):

$$x_{soja_2da} \leq x_{trigo} \quad (8)$$

Restricción de no negatividad

La restricción de no negatividad establece que no se puede asignar una superficie negativa a ningún cultivo, como se expresa en la Ecuación (9):

$$x_c \geq 0; \forall c \in C \quad (9)$$

4. Capítulo 4: Enfoque

Para la implementación del modelo propuesto, se consideran los escenarios climáticos Niño y Niña asociados al fenómeno ENSO. Se asume que el productor conoce cuál escenario es más probable que predomine la próxima campaña, lo cual permite realizar una optimización específica para cada uno de ellos. Bajo esta premisa, se resuelve un modelo independiente para cada escenario, con el objetivo de identificar el mix óptimo de cultivos para cada contexto climático.

El análisis se aplica a dos departamentos representativos de la región pampeana argentina: Río Cuarto, en la provincia de Córdoba, y San Martín, en la provincia de Santa Fe. La elección de estas regiones responde a su importancia agrícola y la disponibilidad de información histórica de rendimientos y precipitaciones, lo que permite una aplicación robusta del modelo.

4.1. Clasificación de escenarios ENSO

La asignación de cada campaña agrícola a una fase climática del ENSO se realiza en función del índice ONI (Oceanic Niño Index), que mide las anomalías de temperatura en el océano Pacífico ecuatorial. Los umbrales definidos para clasificar las campañas son los siguientes:

- **Niña:** $ONI < -0.5$
- **Neutro:** $-0.5 \leq ONI \leq 0.5$
- **Niño:** $ONI > 0.5$

Dado que el impacto del fenómeno ENSO puede variar localmente, se incorpora un criterio complementario basado en precipitaciones históricas para capturar mejor las condiciones agroclimáticas particulares de cada cultivo y región. En este enfoque, se define un rango de lluvias esperadas por cultivo y departamento, y se reclasifican los años como Niño o Niña si la precipitación se encuentra por encima o por debajo de ciertos umbrales, permitiendo así reflejar efectos más específicos del clima sobre el rendimiento agrícola.

4.2. Construcción de los parámetros del modelo

Los rendimientos esperados para cada cultivo bajo cada escenario ENSO se calculan como el promedio de los rendimientos históricos observados en los años clasificados bajo ese mismo escenario. La desviación estándar de los rendimientos, utilizada como medida del riesgo climático asociado a cada cultivo, se calcula de forma análoga.

Los costos de producción por hectárea de cada cultivo y los precios internacionales de referencia, ambos expresados en dólares por tonelada, se consideran constantes en todos los escenarios, con el fin de aislar el impacto específico del componente climático en la toma de decisiones.

4.3. Resolución del modelo

El proceso de resolución del modelo se inicia con el cálculo de los rendimientos esperados y sus respectivas desviaciones estándar para cada cultivo, región y escenario climático.

Luego, se procede al cálculo del beneficio neto por hectárea para cada combinación cultivo-escenario, utilizando los costos de producción por hectárea (proporcionados por una empresa local) y los precios internacionales futuros.

A continuación, se plantean tres formulaciones del modelo de optimización, cada una con un enfoque distinto respecto al tratamiento del riesgo. Cada formulación se resuelve de forma independiente para cada región y escenario, considerando una superficie total de 1.000 hectáreas a asignar entre cinco cultivos: soja de primera, maíz, girasol, trigo y soja de segunda.

El problema de optimización se resuelve utilizando el solver CPLEX a través de su API con el lenguaje Python. El objetivo en cada caso es maximizar el beneficio esperado del productor, entendido como el ingreso neto esperado ajustado por una penalización al riesgo, que se modela mediante un parámetro de aversión al riesgo (λ). Este parámetro se varía sistemáticamente en un rango de valores para simular distintos perfiles de productor (desde neutral al riesgo hasta altamente adverso) y observar cómo esta preferencia influye sobre la asignación óptima de cultivos.

El proceso completo se repite para cada uno de los escenarios climáticos y para las dos regiones de análisis, generando un conjunto de soluciones que permiten evaluar el valor potencial de considerar la información climática anticipada en la toma de decisiones estratégicas de siembra.

4.4. Análisis de sensibilidad

Con el objetivo de comprender cómo distintos supuestos afectan la solución del modelo, se llevaron a cabo diversos análisis de sensibilidad. Estos análisis permiten evaluar la estabilidad de los resultados y brindar recomendaciones para la toma de decisiones bajo incertidumbre climática.

4.4.1. Preferencias de riesgo

El problema de optimización se resolvió para los departamentos de Río Cuarto (Córdoba) y San Martín (Santa Fe), considerando múltiples niveles de aversión al riesgo. En particular, se evaluaron siete niveles de aversión al riesgo en la primera formulación del modelo, y seis niveles en la segunda y tercera, abarcando desde un productor neutral al riesgo hasta un productor con alta aversión.

El objetivo de este análisis es observar cómo cambia la asignación óptima de tierras entre cultivos en función del perfil de riesgo del tomador de decisiones. Para visualizar estos cambios, se elaboraron gráficos que muestran la evolución de la superficie destinada a cada cultivo a medida que aumenta la aversión al riesgo. Estos resultados no sólo permiten identificar los cultivos predominantes en cada escenario, sino también cultivos más estables, que tienden a mantener o aumentar su participación en el portafolio a medida que el productor se vuelve más adverso al riesgo.

4.4.2. Relación entre rentabilidad y riesgo

Se representó gráficamente el Frente de Pareto entre los dos objetivos del modelo: rentabilidad esperada y riesgo. Este análisis se realizó para cada una de las regiones y escenarios

climáticos. La rentabilidad esperada se ubicó en el eje vertical y el riesgo asociado en el eje horizontal, medido según la formulación empleada (desviación estándar, varianza del ingreso y varianza del beneficio neto).

Cada punto del Frente de Pareto representa una asignación de tierras asociada a un nivel particular de rentabilidad esperada y riesgo. Esta representación permite visualizar el trade-off entre riesgo y retorno al que se enfrenta el productor, y destaca la utilidad del modelo como herramienta de apoyo a la decisión estratégica, especialmente en contextos donde se dispone de información climática anticipada. El análisis del frente de Pareto facilita además la comparación entre estrategias productivas, permitiendo identificar aquellas que resultan eficientes en ambos objetivos.

4.4.3. Sensibilidad al cultivo de segunda

Se analizó la sensibilidad del modelo a la posibilidad de no contar con el cultivo de soja de segunda. Dado que este cultivo depende de una rotación con cultivos de invierno (principalmente trigo), se introdujo una restricción que impide su inclusión en el mix de cultivos, simulando un escenario donde esta opción no está disponible.

Este análisis se realizó para cada escenario climático (Niño y Niña) y región, manteniendo los distintos niveles de aversión al riesgo. Comparando los resultados con y sin la opción de soja de segunda, fue posible observar cómo su ausencia afecta las decisiones de siembra y la capacidad del productor para diversificar el riesgo, especialmente en contextos donde la soja de segunda representa una alternativa atractiva por su bajo costo relativo y complementariedad temporal con otros cultivos.

5. Capítulo 5: Resultados

En esta sección se presentan los resultados obtenidos a partir de la resolución de los tres modelos propuestos para distintos niveles de aversión al riesgo, escenarios climáticos (Niño y Niña) y regiones analizadas (Río Cuarto y San Martín). El análisis se enfoca en la asignación óptima de superficie a cada cultivo, la evolución del mix en función del nivel de aversión al riesgo, la relación entre rentabilidad y riesgo y, por último, en cómo afectan al resultado restricciones específicas como la exclusión del cultivo de segunda.

5.1. Asignación óptima de tierras condicionada a la fase del ENSO

La asignación óptima no sólo varía entre regiones y fase predominante, sino que también va a depender del modelado del riesgo que estemos asumiendo y del nivel de aversión al riesgo.

5.1.1. Modelo 1: Penalización basada en el desvío estándar del rendimiento

La Figura 23 muestra la asignación óptima de tierras entre cultivos en función del nivel de aversión al riesgo (λ), bajo los escenarios climáticos Niño y Niña, para los departamentos de San Martín y Río Cuarto.

Bajo el supuesto de neutralidad al riesgo ($\lambda = 0$), toda la superficie se asigna al cultivo o combinación de cultivos con mayor retorno esperado. En el departamento San Martín, un productor neutral al riesgo asigna todas sus hectáreas a la combinación de trigo con soja de segunda, independientemente del escenario ENSO. A diferencia, en el departamento de Río Cuarto la asignación cambia según la fase del fenómeno climático. En ciclos húmedos (Niño), el maíz es el cultivo preferido, mientras que en años secos (Niña), predomina el girasol. Esto confirma que cada región responde de manera diferente a las condiciones ENSO.

Una diferencia notable entre ambas regiones es la participación de la soja de segunda. En San Martín, la soja de segunda tiene una participación considerable en todos los escenarios, mientras que en Río Cuarto su presencia es marginal. Este contraste resalta cómo las condiciones locales y la sensibilidad climática influyen en la viabilidad de los cultivos.

A medida que aumenta la aversión al riesgo, se observa una mayor diversificación en el mix de cultivos. Esta lógica responde a la correlación imperfecta entre los rendimientos de los distintos cultivos: al combinarlos estratégicamente, es posible compensar pérdidas en unos con ganancias en otros.

Este patrón se observa con claridad en los frentes de Pareto de la Figura 24, que ilustran el trade-off entre rentabilidad esperada y riesgo. En todos los casos, las curvas presentan una pendiente positiva y forma cóncava, lo que indica que, a medida que aumenta λ , el riesgo (medido como el desvío estándar de los rendimientos) disminuye, aunque también lo hace la rentabilidad esperada. La forma cóncava de las curvas implica que los primeros incrementos en λ generan reducciones significativas en el riesgo con una pérdida relativamente baja de rentabilidad. Sin embargo, a partir de un cierto umbral, los beneficios adicionales de reducir el riesgo se vuelven marginales. Esto da lugar a una región del frente en la que las decisiones se vuelven más costosas en términos de sacrificio económico por cada unidad adicional de estabilidad.

Figura 23. Modelo 1: Asignación óptima en función del nivel de aversión al riesgo

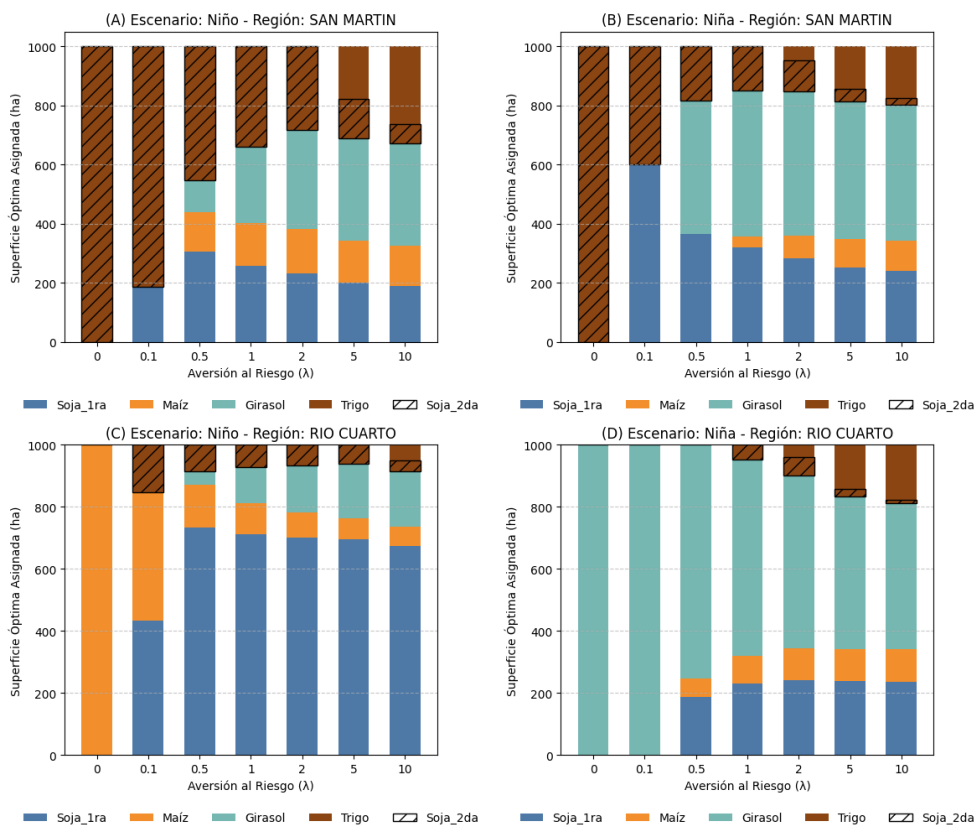
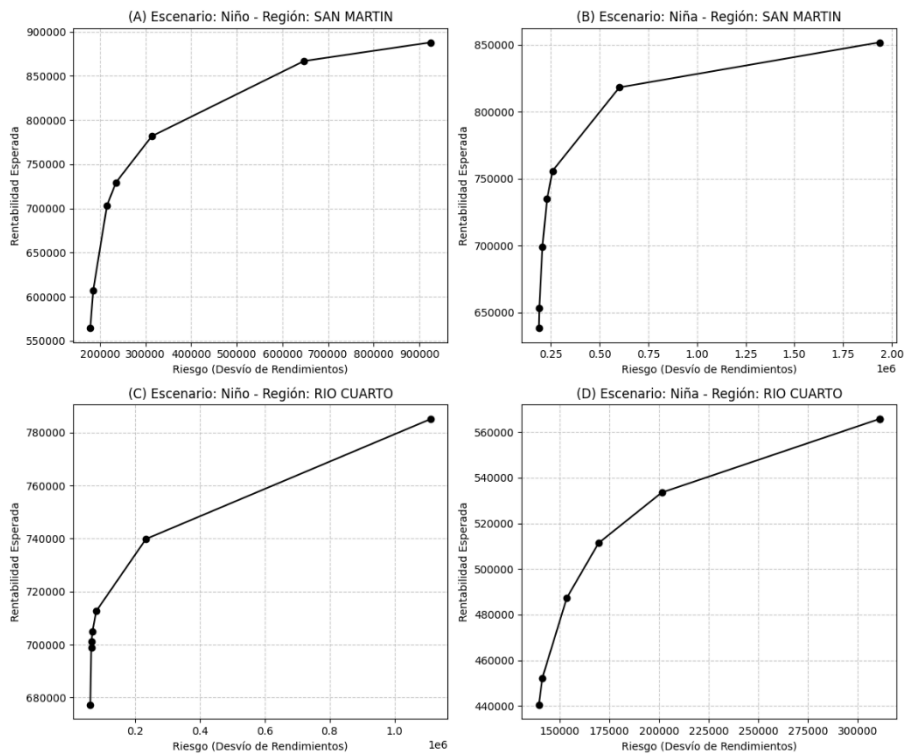


Figura 24. Modelo 1: Frente de Pareto entre rentabilidad y riesgo



El comportamiento observado en los frentes de Pareto y la asignación de tierras respalda las conclusiones de van Noordwijk et al. (1994) que argumenta que la diversificación puede ser una estrategia efectiva para reducir la volatilidad del ingreso agrícola. Al combinar cultivos que no están perfectamente correlacionados, los productores pueden mitigar los riesgos asociados con las variaciones climáticas, equilibrando de esta forma el riesgo y la rentabilidad de sus decisiones.

En este contexto, para los escenarios planteados, valores de λ entre 0.1 y 0.5 representan una buena compensación entre rendimiento y riesgo. Para estos niveles de aversión, las asignaciones del modelo 1 indican que, bajo la fase fría (Niña), predomina el girasol, especialmente en Río Cuarto, mientras que en años Niño, se observa un mix más diverso, predominando el maíz junto con la soja de primera en Río Cuarto y soja (tanto de primera como segunda), maíz y trigo en San Martín.

5.1.2. Modelo 2: Penalización basada en la varianza del ingreso

En este modelo, la penalización al riesgo se basa en la varianza del ingreso, que se calcula como el cuadrado del producto entre precios y toneladas. Debido a que la varianza tiende a ser un valor elevado, fue necesario utilizar valores pequeños de λ para evitar que la función objetivo tome valores negativos.

La asignación óptima de cultivos según el nivel de aversión al riesgo se muestra en la Figura 25. En líneas generales, los resultados obtenidos replican las principales tendencias observadas en el modelo 1 de aversión al riesgo. Para valores bajos de λ (≈ 0), el modelo asigna la totalidad de la superficie al cultivo con la mayor rentabilidad esperada. A medida que λ aumenta, se incrementa la diversificación del mix de cultivos. Esta consistencia entre modelos refuerza la robustez de los resultados.

En el departamento San Martín, bajo el escenario Niño, el modelo 2 mantiene una proporción significativa de la superficie destinada al trigo combinado con soja de segunda, incluso para valores moderados de λ . Bajo el escenario Niña, el girasol sigue siendo el cultivo predominante, con asignaciones similares entre los dos modelos, reflejando que el girasol es más adecuado para condiciones secas.

En el departamento Río Cuarto, bajo el escenario Niño, se incrementa la participación relativa de la soja de primera en detrimento del maíz. Mientras que el Modelo 1 asigna superficies similares a soja de primera y maíz para niveles moderados de aversión al riesgo, el Modelo 2 otorga un mayor peso a la soja de primera. Además, al igual que el modelo 1, en este escenario no se asignan hectáreas al girasol para bajos niveles de aversión.

Bajo el escenario Niña, el girasol sigue siendo el cultivo dominante en Río Cuarto. Sin embargo, el Modelo 2 asigna una mayor superficie al trigo en niveles altos de aversión al riesgo. Esta diferencia con el Modelo 1 se debe a que el trigo, debido a su menor precio, reduce la varianza del ingreso, favoreciendo su inclusión en el mix en condiciones de alta aversión al riesgo.

Figura 25. Modelo 2: Asignación óptima en función del nivel de aversión al riesgo

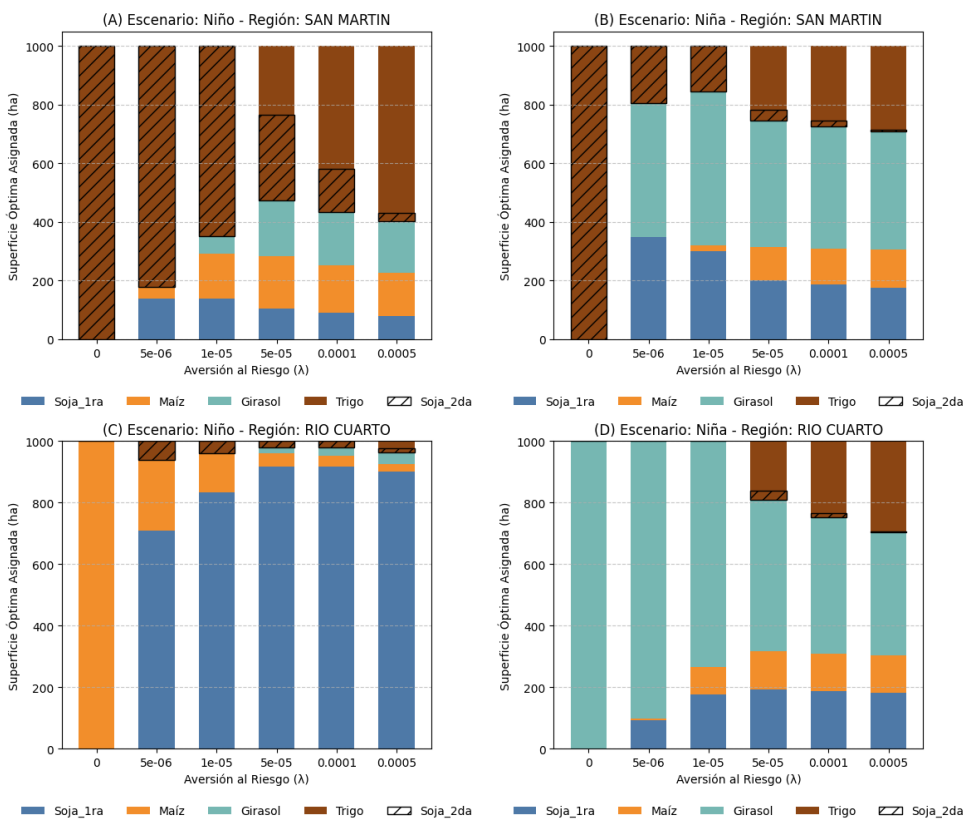
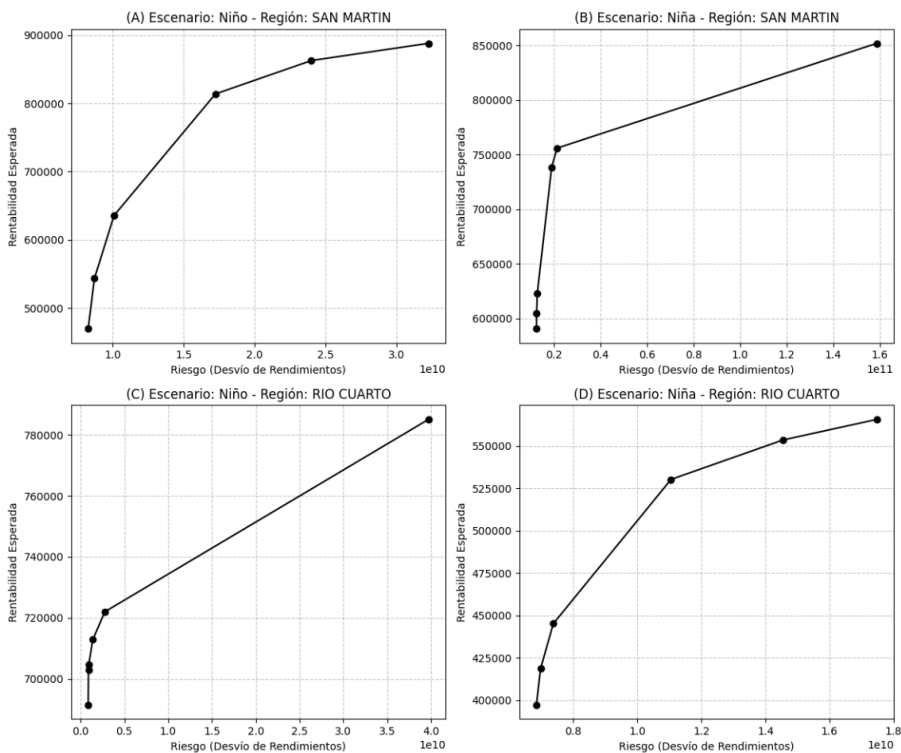


Figura 26. Modelo 2: Frente de Pareto entre rentabilidad y riesgo



Los Frentes de Pareto del Modelo 2 (Figura 26) mantienen una forma similar a los del Modelo 1, muestran una pendiente positiva clara, aunque con una concavidad algo menor. En los escenarios (A) y (D), se observa que los primeros incrementos de λ generan reducciones proporcionales tanto en riesgo como en rentabilidad. A diferencia, el escenario (B) presenta una pendiente inicial más plana, lo que indica que es posible reducir significativamente el riesgo sin una pérdida considerable de rentabilidad. Este comportamiento es especialmente valioso en contextos donde se prioriza la estabilidad. En contraste, el escenario (C) muestra un comportamiento opuesto, en las primeras combinaciones de λ , al disminuir el riesgo, la rentabilidad decrece rápidamente.

Un comportamiento que se observa en ambos modelos es que, a medida que aumenta el coeficiente λ de aversión al riesgo, la superficie asignada a soja de segunda disminuye en relación con la superficie destinada a trigo. Dado que el modelo maximiza beneficios penalizando la exposición al riesgo, esto podría explicarse debido a que, para altos niveles de λ , el beneficio marginal esperado de asignar una hectárea adicional a soja de segunda no compensa el aumento en el riesgo total del portafolio. En contraste, el trigo presenta un perfil de riesgo-retorno más favorable bajo estas condiciones, lo que lo vuelve más atractivo en contextos de alta aversión al riesgo.

En cuanto a las preferencias por cultivo, bajo la fase fría (Niña), los resultados son muy similares al modelo anterior, predominando el girasol. Por el contrario, en fase cálida, en la región de Río Cuarto la soja de primera toma mayor relevancia por sobre el maíz, mientras que el trigo en combinación de soja de segunda es la combinación que predomina, en San Martín.

5.1.3. *Modelo 3: Penalización sobre la variabilidad del beneficio neto*

Este modelo introduce una visión más completa del riesgo económico al incorporar los costos en el término de penalización. A diferencia del Modelo 1, que penaliza únicamente la variabilidad de los rendimientos, y del Modelo 2, que considera la variabilidad de los ingresos (rendimiento por precio), este enfoque penaliza la variabilidad del beneficio neto, es decir, ingreso menos costo.

Una consecuencia importante de esta formulación es que cultivos con altos costos, como el maíz en este estudio, son fuertemente penalizados incluso si presentan buenos rendimientos o precios. Esto se traduce en una asignación de superficie mínima o nula al maíz, como se puede observar en la Figura 27. Este efecto se explica por los elevados costos que tiene el cultivo en relación con el resto, lo cual amplifica la penalidad en la función objetivo. Las tablas 6, 7, 8 y 9 del Apéndice A evidencian esta diferencia desproporcionada en la penalidad para los cuatro escenarios planteados.

Este modelo genera resultados sustancialmente distintos respecto a los modelos anteriores. En San Martín, bajo el escenario Niño, se observa un aumento significativo de la participación del girasol en el mix óptimo, mientras que el trigo pierde relevancia en comparación con lo observado en los modelos 1 y 2. En el escenario Niña, el modelo sugiere una fuerte concentración en soja de primera, que se mantiene incluso ante niveles altos de aversión al riesgo. Además, no se asignan hectáreas al girasol, cultivo que en los modelos anteriores resultaba dominante para niveles intermedios de aversión.

Figura 27. Modelo 3: Asignación óptima en función del nivel de aversión al riesgo

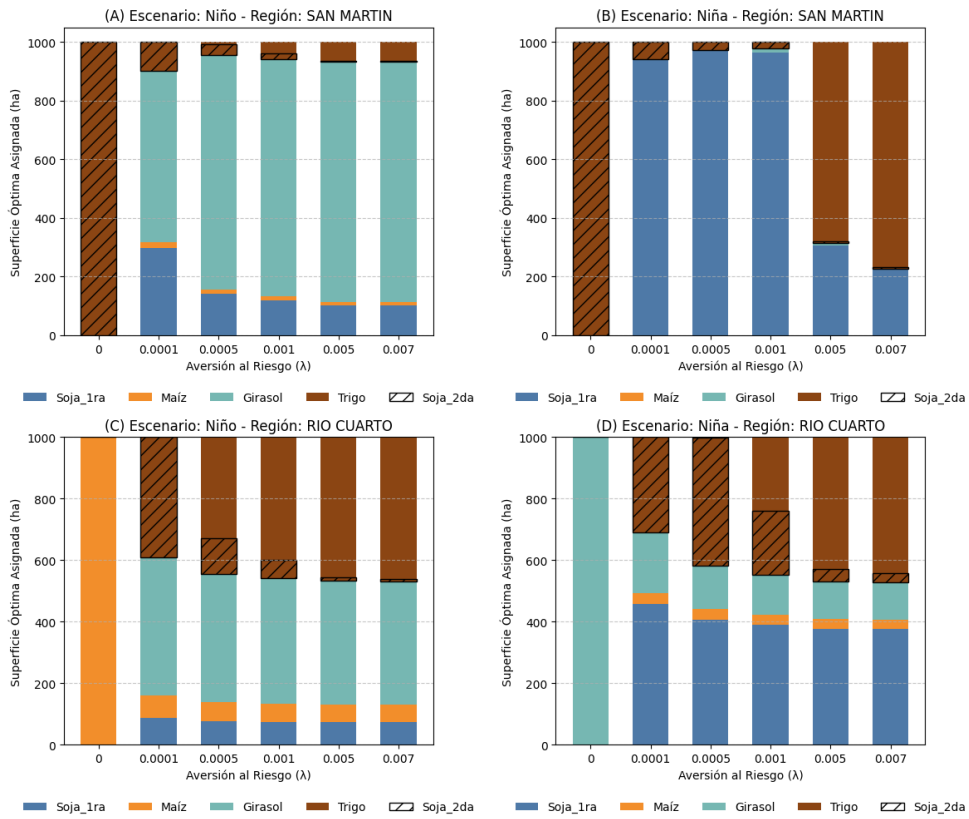
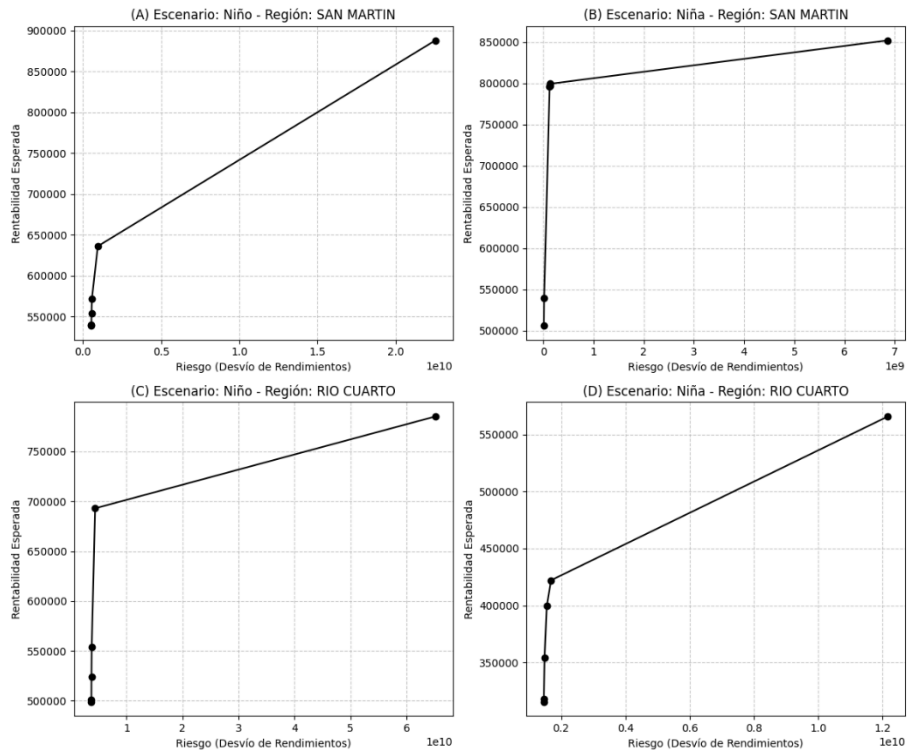


Figura 28. Modelo 3: Frente de Pareto entre rentabilidad y riesgo



En Río Cuarto, para el escenario Niño, el girasol adquiere una participación significativa, lo que contrasta con su nula presencia en los modelos anteriores. Por el contrario, bajo el escenario Niña, el girasol pierde relevancia, nuevamente en contradicción con los resultados obtenidos previamente.

Otra particularidad notable de este modelo se observa en las pendientes de los Frentes de Pareto representados en la Figura 28. En los escenarios (A) Niño - San Martín y (D) Niña - Río Cuarto, el cambio de neutralidad a aversión presenta una pendiente elevada. Esto implica que ganancias en términos de estabilidad requieren grandes sacrificios en rentabilidad, es decir, el paso del monocultivo a la diversificación con lleva menor riesgo, pero también una pérdida relevante en rentabilidad.

Por el contrario, en los escenarios (B) Niña - San Martín y (C) Niño - Río Cuarto, la pendiente es visiblemente más plana, principalmente en el escenario (B). Esto sugiere lo opuesto, es decir, el paso de la neutralidad a la diversificación trae aparejado importantes ganancias en termino de reducción del riesgo sin pérdidas importantes en rentabilidad.

5.1.4. Comparativa de resultados entre modelos

Luego de analizar los resultados de los tres modelos, se identifican tanto similitudes como diferencias entre ellos, lo cual permite arribar a algunas conclusiones preliminares sobre el problema en cuestión.

En los tres modelos, a medida que aumenta la aversión al riesgo, se observa un incremento en la diversificación del mix de cultivos. Asimismo, en todos los modelos, los Frentes de Pareto presentan pendiente positiva, a mayor rentabilidad esperada, mayor es el riesgo asumido. Este comportamiento refleja el trade-off clásico entre riesgo y retorno.

La forma de los frentes de Pareto y la asignación de tierras evidencian que la diversificación es una estrategia óptima para reducir el riesgo. Al combinar cultivos con dinámicas productivas distintas y no perfectamente correlacionadas, los productores pueden mitigar los riesgos asociados a las variaciones climáticas, equilibrando de esta forma el riesgo y la rentabilidad de sus decisiones. Este equilibrio depende del nivel de aversión al riesgo de cada productor, por lo tanto, el mix óptimo de cultivos varía según dicho nivel y la fase climática del ENSO prevista para la próxima campaña.

Las diferencias entre los modelos radican en los mix óptimos seleccionados para cada fase del fenómeno ENSO. En los dos primeros modelos, durante la fase fría (Niña), se observa una preferencia más marcada por el girasol, mientras que en el tercer modelo este cultivo no tiene una participación significativa, ganando relevancia la soja de primera. En cuanto a la fase cálida (Niño), los modelos 1 y 2 muestran diversas combinaciones de cultivos, predominando el maíz, la soja de primera y el trigo, con nula o baja participación del girasol. En contraste, en el modelo 3, el girasol adquiere una participación predominante.

Estas diferencias se explican por el hecho de que el Modelo 3 penaliza fuertemente los cultivos de alto costo, como el maíz. Aun cuando el maíz presenta buenos rendimientos en ciertos escenarios, su alto costo por hectárea amplifica la penalidad por riesgo, reduciendo o eliminando su participación en el mix óptimo. Este comportamiento puede distorsionar el

análisis, ya que no necesariamente refleja la lógica de decisión de un productor, quien podría estar dispuesto a asumir mayores costos si la rentabilidad esperada lo justifica.

Por esta razón, y dada la sensibilidad excesiva del Modelo 3 a los costos, se optó por continuar el análisis con los Modelos 1 y 2, que capturan mejor el comportamiento racional de los productores bajo incertidumbre climática.

Considerando los modelos 1 y 2, se observa que bajo la fase fría (Niña) predomina el girasol, especialmente en el departamento de Río Cuarto, mientras que el maíz se evita. Por el contrario, en los años Niño se presentan combinaciones más diversas entre maíz, soja de primera y trigo (en combinación con soja de segunda), sin una participación destacada del girasol.

Estos resultados se alinean con lo observado en el análisis exploratorio de los datos desarrollado en la sección 2, donde se mostró que el girasol presenta un buen desempeño bajo condiciones hídricas moderadas, siendo un cultivo más resistente al estrés hídrico. Incluso, los excesos de agua pueden afectar negativamente su rendimiento, por lo que es razonable que sea el cultivo preferido por los modelos en los escenarios Niña, mientras que el maíz —cuyos buenos rendimientos se alcanzan con niveles de precipitaciones más elevados— pierde relevancia.

En cuanto a la mayor diversidad de combinaciones de cultivos observada en los escenarios Niño, esta se explica por el hecho de que las precipitaciones elevadas benefician tanto al maíz como a la soja de primera, los cuales requieren umbrales hídricos elevados para alcanzar sus mejores rendimientos. El trigo, por su parte, tiene la particularidad de alcanzar rendimientos aceptables con lluvias moderadas, pero también mejora significativamente su desempeño en contextos más húmedos. Esta versatilidad justifica su participación relevante en el departamento de San Martín. En este sentido, el trigo actúa como un cultivo “comodín”, capaz de adaptarse tanto a condiciones secas como húmedas, lo que le permite integrarse de manera flexible en distintas combinaciones productivas según el escenario climático previsto.

5.2. Análisis de resultados: sensibilidad al cultivo de segunda

Este análisis tiene como objetivo evaluar la sensibilidad de los modelos 1 y 2 ante la exclusión del cultivo de segunda, en este caso, soja de segunda. Para ello, se redefinió el conjunto de cultivos disponibles como $C = \{\text{soja de primera, maíz, girasol, trigo}\}$, eliminando la posibilidad de combinar trigo con soja de segunda en la misma campaña.

El análisis se realizó para cada escenario climático (Niño y Niña) y para ambas regiones bajo estudio (San Martín y Río Cuarto). Se mantienen los distintos niveles de aversión al riesgo (λ) definidos previamente, con el objetivo de comparar cómo varían las decisiones de siembra ante la imposibilidad de sembrar soja de segunda. Las Figuras 29 y 30 presentan las nuevas asignaciones de tierra en función del nivel de aversión al riesgo para los modelos 1 y 2, respectivamente.

Figura 29. Asignación óptima sin Soja de Segunda en función del nivel de aversión al riesgo de Modelo 1

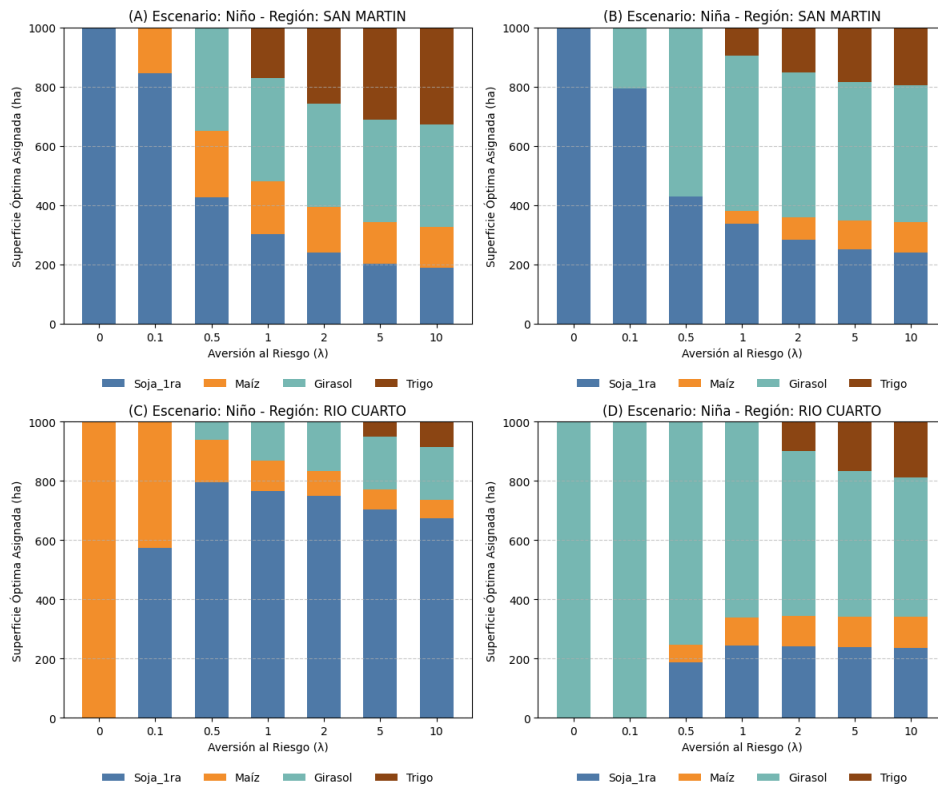
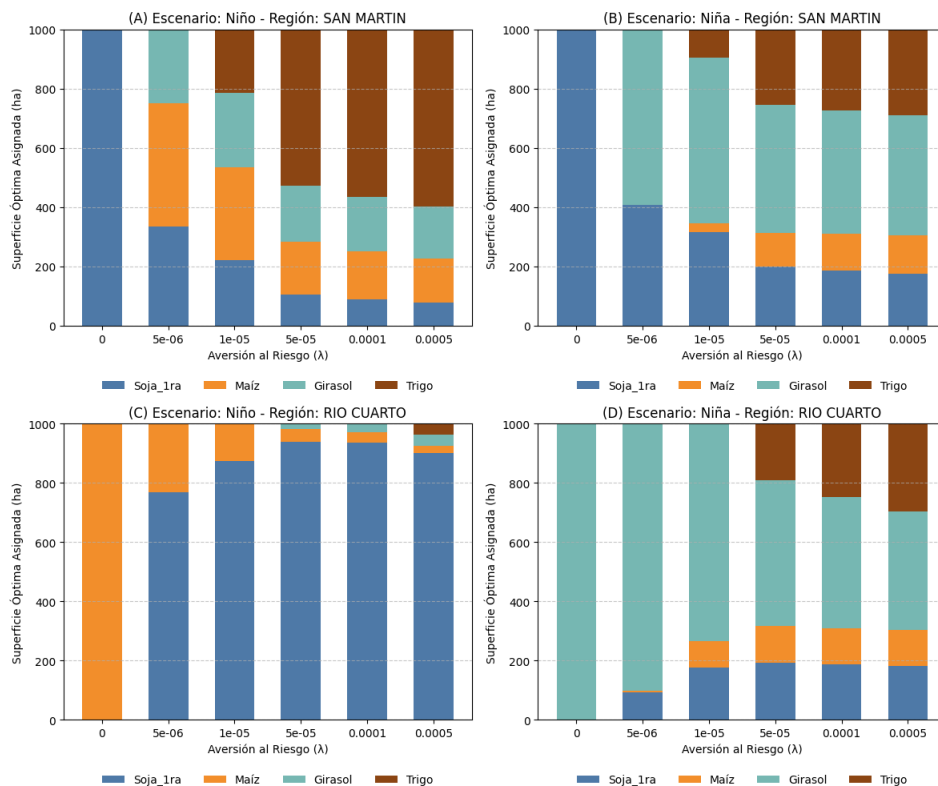


Figura 30. Asignación óptima sin Soja de Segunda en función del nivel de aversión al riesgo de Modelo 2



Una primera diferencia evidente, común a ambos modelos, se observa en el departamento de San Martín. En ausencia de soja de segunda, el productor neutral al riesgo (es decir, con $\lambda = 0$) asigna toda la superficie disponible (1.000 ha) a soja de primera, reemplazando así la estrategia previa que combinaba trigo seguido de soja de segunda. Este comportamiento se repite tanto bajo el escenario Niño como Niña, lo cual evidencia que, para este nivel de aversión al riesgo, el trigo solo resultaba atractivo cuando se encontraba asociado al doble cultivo con soja de segunda. A su vez, como en este departamento en la versión original del modelo se asigna una participación significativa al trigo (combinado con soja de segunda), la eliminación del cultivo de segunda, provoca una reconfiguración drástica del patrón de asignación, acentuando el peso de la soja de primera como cultivo principal. En el modelo 2, si bien el trigo recupera relevancia a medida que aumenta la aversión al riesgo —debido a su precio y al rol que este juega en la penalización del desvío—, su aparición es más tardía en comparación con el caso original.

En contraste, en el departamento de Río Cuarto la eliminación de la soja de segunda no altera la estrategia del productor neutral al riesgo: se conserva la preferencia por maíz bajo el escenario Niño y por girasol en el escenario Niña. Sin embargo, se advierte una modificación más sutil en el comportamiento del trigo, que ahora comienza a formar parte de la estrategia recién a niveles más elevados de aversión al riesgo. En la versión inicial del modelo, el trigo tenía presencia desde niveles intermedios de λ , por lo que esta postergación sugiere una menor competitividad relativa del cultivo cuando se lo considera como opción única. De todos modos, como su participación ya era limitada en esta región, los cambios no resultan tan marcados como en San Martín, donde el trigo —cuando era acompañado de soja de segunda— tenía una presencia considerable.

En el Apéndice B, las Figuras 31 y 32, muestran los frentes de Pareto que relacionan rentabilidad y riesgo para los modelos 1 y 2, excluyendo la posibilidad de contar con soja de segunda. Los resultados muestran que, a pesar de esta restricción, las curvas mantienen sus formas características: son crecientes y cóncavas, lo que indica que el comportamiento del modelo frente al trade-off entre rentabilidad y riesgo se conserva. En el caso del departamento San Martín, se observa una disminución en la rentabilidad máxima alcanzable para el productor neutral al riesgo, lo que resulta lógico dado que se ha reducido el conjunto de estrategias posibles. Por el contrario, en Río Cuarto, las curvas prácticamente no se ven alteradas, ya que la soja de segunda no formaba parte de la estrategia óptima en los niveles bajos de aversión al riesgo. Estos frentes reafirman que, aunque la estructura general del modelo se mantiene estable, la disponibilidad de cultivos de segunda puede influir de manera significativa en el espacio de soluciones eficientes, particularmente en regiones donde su implementación constituía un componente central de la estrategia productiva.

Este ejercicio pone en evidencia el rol estructural que desempeña el cultivo de segunda, en particular la soja de segunda, en la planificación productiva. Su inclusión permite estrategias más diversificadas y eficientes, especialmente en regiones donde el doble cultivo es viable. La imposibilidad de contar con esta opción restringe las alternativas disponibles, reduce la complementariedad entre cultivos y tiende a concentrar las decisiones en opciones más simples, como la siembra exclusiva de soja de primera. En este contexto, se observa además cómo el trigo pierde relevancia en ausencia de un cultivo de segunda que lo complementa, ya

que en muchos casos su competitividad estaba asociada precisamente a su integración en esquemas de doble cultivo. Esta pérdida de complementariedad no solo limita su presencia en los modelos, sino que también afecta la diversificación de la estrategia productiva general. Los resultados reflejan cómo esta limitación impacta de manera diferenciada según la región y el grado de aversión al riesgo, destacando la importancia de incorporar la factibilidad del doble cultivo en los modelos de asignación óptima como una variable clave en la toma de decisiones agrícolas.

6. Capítulo 6: Conclusiones

Los modelos presentados en este trabajo determinan la asignación óptima de tierras entre cultivos en la región pampeana argentina, considerando las distintas fases climáticas del fenómeno ENSO (Niño y Niña). El objetivo es maximizar el beneficio esperado del productor incorporando un término de riesgo, con el fin de identificar el mix óptimo de cultivos en términos de rentabilidad esperada y riesgo.

Los tres enfoques propuestos muestran que la asignación óptima de tierras varía significativamente según el escenario climático y el nivel de aversión al riesgo considerado. En condiciones de neutralidad al riesgo ($\lambda = 0$), la estrategia óptima tiende a concentrarse en el cultivo —o en combinaciones de cultivos, cuando se incorpora el cultivo de segunda— con mayor rentabilidad esperada. Sin embargo, a medida que aumenta la aversión al riesgo, se observa una mayor diversificación en el mix de cultivos, como estrategia para mitigar la variabilidad de los rendimientos. Además, en todos los modelos se corrobora una relación positiva entre rentabilidad y riesgo: mayores niveles de rentabilidad exigen asumir riesgos más elevados.

El análisis comparativo de los modelos de penalización —basados en la desviación estándar, la varianza del ingreso y la variabilidad del beneficio neto— evidenció que los Modelos 1 y 2 ofrecen resultados más consistentes y alineados con el comportamiento real de los productores. En contraste, el Modelo 3, al penalizar fuertemente los costos asociados a los cultivos, tendió a eliminar alternativas de mayor costo como el maíz, lo que derivó en asignaciones que, bajo ciertas condiciones, no reflejan adecuadamente la lógica de decisión de los productores, quienes podrían estar dispuestos a asumir costos más elevados si la rentabilidad esperada lo justifica. Por esta razón, las conclusiones y recomendaciones finales del trabajo se fundamentan en los resultados de los primeros dos modelos.

La asignación óptima de tierras predicha varió entre las fases del ENSO de manera consistente con las influencias conocidas del fenómeno sobre las precipitaciones y la sensibilidad de los cultivos a la disponibilidad de agua, tal como se analizó en el Capítulo 2. Bajo condiciones de Niña, el girasol adquiere un rol predominante, especialmente en el departamento de Río Cuarto, mientras que el maíz tiende a evitarse. En cambio, en los años Niño, las mejores condiciones hídricas amplían las opciones productivas, favoreciendo cultivos como el maíz, la soja de primera y el trigo (en combinación con soja de segunda), mientras que la participación del girasol resulta marginal.

En este sentido, la principal recomendación que surge del trabajo es que, ante una campaña afectada por la fase fría del ENSO (Niña), la estrategia óptima debe incorporar una proporción considerablemente mayor de girasol. El mix óptimo dependerá del nivel de aversión al riesgo del productor y de la región donde se ubican sus campos, pero en todos los casos el girasol debe tener una presencia significativa. Este resultado se alinea con la resistencia del girasol al estrés hídrico, característica que lo convierte en una opción estratégica en contextos de disponibilidad de agua limitada. Por el contrario, en escenarios Niño, las precipitaciones elevadas favorecen cultivos como el maíz y la soja de primera, que requieren mayores umbrales hídricos para alcanzar su potencial de rendimiento. En estos contextos, el mix óptimo dependerá del nivel de aversión al riesgo y de la región en cuestión.

El trigo, por su parte, se destaca por su versatilidad, logra rendimientos aceptables con lluvias moderadas, pero también mejora significativamente su productividad en condiciones más húmedas. Esta característica justifica su presencia relevante en el departamento de San Martín, donde actúa como un cultivo “comodín”, integrándose con flexibilidad en distintas combinaciones productivas, según el escenario climático previsto.

Adicionalmente, el análisis de la exclusión del cultivo de segunda —en este caso, la soja de segunda— evidenció su rol estructural en la planificación productiva. La imposibilidad de realizar el doble cultivo redujo la diversidad de estrategias posibles, concentrando la producción en alternativas más simples como la soja de primera, especialmente en San Martín, y afectando la competitividad del trigo, cuya participación estaba fuertemente asociada a esquemas de doble cultivo. Estos resultados subrayan la importancia de considerar la viabilidad del doble cultivo como un factor clave en los modelos de asignación óptima.

Los resultados de este trabajo complementan estudios previos sobre optimización agrícola bajo diferentes escenarios climáticos. La estructura del modelo desarrollado resulta suficientemente flexible para incorporar nuevas restricciones u objetivos.

En cuanto a los factores adicionales considerados, se evaluó inicialmente la incorporación de plagas como variable de riesgo. Sin embargo, dada la efectividad de los agroquímicos modernos y las prácticas de manejo actuales, su impacto sobre los rendimientos se ha reducido considerablemente, convirtiéndolo en un factor menos relevante, motivo por el cual se decidió no incorporarlos como un factor determinante en este estudio.

En síntesis, este trabajo ofrece una herramienta valiosa para la toma de decisiones en la región pampeana, al permitir evaluar estrategias de asignación de tierras considerando no solo la rentabilidad esperada, sino también el riesgo asociado a las variaciones climáticas. Los resultados obtenidos pueden ser utilizados para diseñar estrategias de adaptación y mitigación frente a fenómenos climáticos extremos.

Finalmente, se sugiere que futuras investigaciones profundicen en la integración de herramientas de gestión del riesgo, como los seguros agrícolas. La incorporación de seguros en el modelo de optimización podría ofrecer una forma adicional de protegerse contra los efectos negativos de eventos climáticos adversos, al tiempo que contribuiría a reducir la exposición financiera de los productores y a sostener la continuidad de las actividades productivas ante escenarios de alta incertidumbre.

Referencias Bibliográficas

Alotaibi, A., & Nadeem, F. (2021). A Review of Applications of Linear Programming to Optimize Agricultural Solutions. *I.J. Information Engineering and Electronic Business*, 2, 11-21.

Bhatia, M., & Rana, A. (2020). A Mathematical Approach to Optimize Crop Allocation – A Linear Programming Model. *International Journal of Design & Nature and Ecodynamics*, 15(2), 245-252.

Jones, J. W., Hansen, J. W., Royce, F. S., & Messina, C. D. (2000). Potential benefits of climate forecasting to agriculture. *Agriculture, Ecosystems and Environment*, 82(2), 169-184.

Liu, J., Men, C., Cabrera, V. E., Uryasev, S., & Fraisse, C. W. (2007). Optimizing crop insurance under climate variability. *Agricultural Systems*, 97(3), 96-105.

Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77–91.

Messina, C. D., Hansen, J. W., & Hall, A. J. (1999). Land allocation conditioned on El Niño-Southern Oscillation phases in the Pampas of Argentina. *Field Crops Research*, 63(1), 1-12.

Podestá, G. P., Messina, C. D., Grondona, M., & Magrin, G. O. (1999). Associations between grain crop yields in central-eastern Argentina and El Niño-Southern Oscillation. *Journal of Applied Meteorology*, 38(10), 1488-1501.

Profertil. (s.f.). *Urea granulada Argentina*.
<https://www.profertil.com.ar/index.php/productos/urea>

Van Noordwijk, M., Dijksterhuis, G. H., & Van Keulen, H. (1994). Risk management in crop production and fertilizer use with uncertain rainfall: How many eggs in which baskets? *Netherlands Journal of Agricultural Science*, 42(4), 249–269.

Villavicencio, A. (2014). Modelo de optimización de recursos prediales mediante programación lineal (Boletín INIA, N° 304). INIA Quilamapu.

Apéndice A. Resultados por escenario climático en el Modelo 3: impacto de los costos en la penalización del riesgo

Tabla 6. Penalización por cultivo - Escenario Niño, Departamento San Martín

Cultivo	Precio (p_c)	Desvío (σ_c)	Costo (c_c)	Penalización Modelo 3 ($(p_c\sigma_c - c_c)^2$)
Girasol	425,3	0,5	242,5	655
Maíz	179,2	1,3	454,6	46.761
Soja de Primera	330,6	1,0	258,1	5.259
Trigo	227,7	0,5	204,8	7.737
Soja de Segunda	330,6	0,4	258,1	14.773

Tabla 7. Penalización por cultivo - Escenario Niña, Departamento San Martín

Cultivo	Precio (p_c)	Desvío (σ_c)	Costo (c_c)	Penalización Modelo 3 ($(p_c\sigma_c - c_c)^2$)
Girasol	425,3	0,4	242,5	4.355
Maíz	179,2	1,7	454,6	22.001
Soja de Primera	330,6	0,8	258,1	129
Trigo	227,7	0,9	204,8	2
Soja de Segunda	330,6	1,0	258,1	6.851

Tabla 8. Penalización por cultivo - Escenario Niño, Departamento Río Cuarto

Cultivo	Precio (p_c)	Desvío (σ_c)	Costo (c_c)	Penalización Modelo 3 ($(p_c\sigma_c - c_c)^2$)
Girasol	425,3	0,3	242,5	9.252
Maíz	179,2	1,1	454,6	65.183
Soja de Primera	330,6	0,1	258,1	51.381
Trigo	227,7	0,5	204,8	7.898
Soja de Segunda	330,6	0,6	258,1	3.686

Tabla 9. Penalización por cultivo - Escenario Niña, Departamento Río Cuarto

Cultivo	Precio (p_c)	Desvío (σ_c)	Costo (c_c)	Penalización Modelo 3 ($(p_c\sigma_c - c_c)^2$)
Girasol	425,3	0,3	242,5	12.149
Maíz	179,2	1,3	454,6	47.072
Soja de Primera	330,6	0,6	258,1	3.931
Trigo	227,7	0,7	204,8	3.069
Soja de Segunda	330,6	0,7	258,1	402

Apéndice B. Frente de Pareto entre rentabilidad y riesgo sin Soja de Segunda de Modelo 1 y 2.

Figura 31. Modelo 1: Frente de Pareto entre rentabilidad y riesgo sin Soja de Segunda

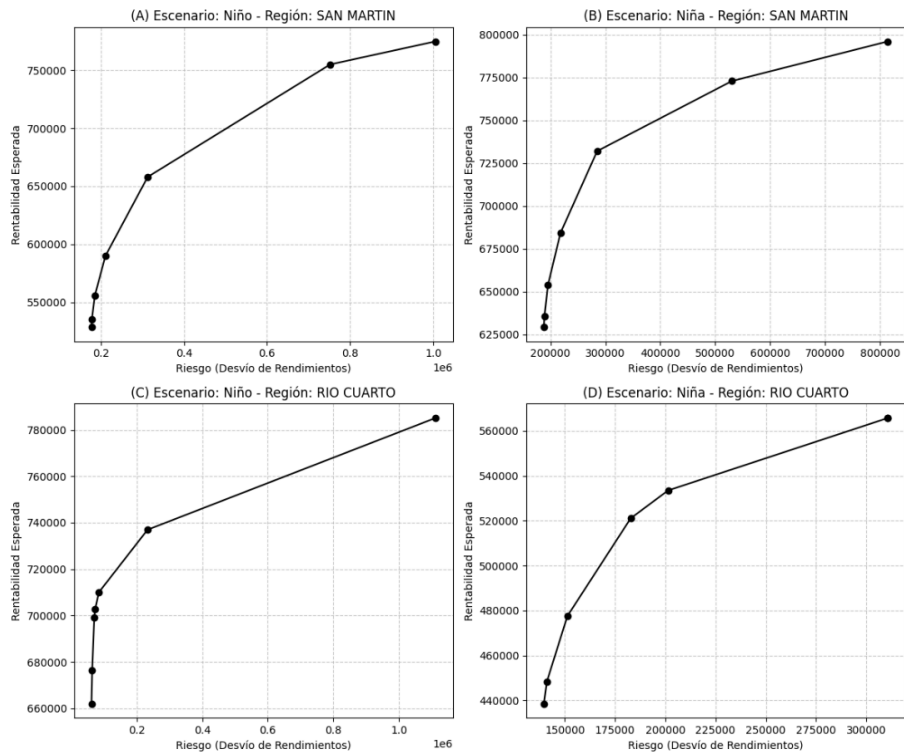


Figura 32. Modelo 2: Frente de Pareto entre rentabilidad y riesgo sin Soja de Segunda

