



UNIVERSIDAD NACIONAL DEL SUR

TESIS DE DOCTORADO EN INGENIERÍA

Planificación óptima del manejo
integrado de malezas

Lucía Damiani

BAHÍA BLANCA

ARGENTINA

2021

PREFACIO

Esta tesis se presenta como parte de los requisitos para optar al grado académico de Doctora en Ingeniería de la Universidad Nacional del Sur y no ha sido presentada previamente para la obtención de otro título similar en esta institución u otras. La misma contiene los resultados obtenidos de la investigación llevada a cabo en el ámbito de la Planta Piloto de Ingeniería Química (PLAPIQUI) durante el período comprendido entre el 1 de abril de 2016 y el 31 de marzo de 2021, bajo la dirección de los Dres. Aníbal M. Blanco y Mariano Frutos.

Lucía Damiani



UNIVERSIDAD NACIONAL DEL SUR

Secretaría General de Posgrado y Educación Continua

La presente tesis ha sido aprobada el /..... /....., mereciendo la
calificación de (.....)

AGRADECIMIENTOS

A mi director, el Dr. Aníbal Blanco por estar siempre presente, por su guía y apoyo en todo momento, así como la formación y la paciencia a lo largo de estos cinco años.

A mis codirectores de beca y de tesis, los Dres. Guillermo Chantre y Mariano Frutos, respectivamente, por las recomendaciones que me brindaron para poder completar este trabajo.

A mis compañeros de PLAPIQUI, en particular el grupo de procesos, por las horas de trabajo y los momentos compartidos. En especial a mis compañeros de oficina Fiorella Cravero, Yamila Grassi y Franco Poggio.

A Franco Molinari, por permitirme sumarme a su proyecto y ayudarme a entender sobre la parte agronómica de la tesis. Además, por su apoyo, las charlas y los mates que, en conjunto, motivaron el día a día de la última etapa de la tesis.

A CONICET por brindar los medios económicos para la realización de esta tesis a través de una beca doctoral.

Siempre a mi familia, sin ellos nada sería posible.

RESUMEN

Una de las mayores limitaciones para lograr el rendimiento y la calidad deseada de los cultivos en la mayoría de los sistemas agronómicos del mundo es la presencia de malezas. Para mitigar su propagación e influencia, en los últimos años se comenzó a implementar el Manejo Integrado de Malezas (MIM), que pretende evitar los efectos negativos resultantes del uso exclusivo de herbicidas como único mecanismo de control al combinar diferentes técnicas de prevención y control que también incluyen rotaciones de cultivos, prácticas mecánicas y medidas culturales.

Motivados por esta realidad, en esta tesis se planteó, primeramente, extender las prestaciones de un modelo de simulación desarrollado en el ámbito del grupo de investigación. El objetivo del mismo fue estimar los efectos de diferentes estrategias de manejo sobre la dinámica demográfica de una maleza anual (*Avena fatua* L.) en competencia con cereales de invierno (trigo y cebada) en un plan de rotación multianual, y proporcionar suficiente detalle agronómico, económico y medioambiental para orientar la toma de decisiones.

Adicionalmente, con el propósito de explorar sistemáticamente la gran cantidad de posibles estrategias de MIM que se pueden representar con el modelo desarrollado e identificar automáticamente aquellas que resultan más prometedoras, se implementó un optimizador que proporciona un conjunto de soluciones en la frontera de los objetivos de desempeño considerados. Este se basó en un algoritmo estocástico no-lineal por enjambre de partículas (PSO), al que se le incorporaron técnicas para el manejo de restricciones, de manipulación de variables binarias y de consideración de objetivos múltiples. Así, el optimizador desarrollado permite identificar los mejores esquemas de rotación de cultivos y de tratamientos para controlar la maleza teniendo en cuenta, simultáneamente, el beneficio económico y el impacto ambiental. La herramienta desarrollada se considera de potencial utilidad para guiar el complejo proceso de toma de decisiones de la actividad agrícola.

ABSTRACT

One of the greatest limitations to achieve the desired yields and quality of crops in most agronomic systems around the world is the presence of weeds. To prevent their spread and influence, in recent years Integrated Weed Management (IWM) practices began to be implemented, which aims at avoiding the negative effects of the sole use of herbicides as control mechanism by combining different prevention and control techniques that also include rotations, mechanical practices and cultural measures.

Motivated by this reality, in this thesis it was firstly proposed to extend the features of a simulation model developed in our research group. It aimed at estimating the effects of different management strategies on the demographic dynamics of an annual weed (*Avena fatua* L.) in competition with winter cereals (wheat and barley) in a multi-year rotation plan, providing sufficient agronomic, economic and environmental detail to guide decision making.

Additionally, in order to systematically explore the large number of possible IWM strategies that can be represented with the developed model and automatically identify the most promising ones, an optimizer that provides a set of solutions on the frontier of the considered performance objectives was implemented. It was based on a non-linear stochastic particle swarm algorithm (PSO), enhanced with techniques for constraint management, binary variables handling and multiple objectives consideration. In this way, the developed optimizer allows identifying the best crop rotation and treatment schemes for weeds control, simultaneously considering the economic benefit and the environmental impact. The developed tool is considered of potential utility to guide the complex decision-making process of the agricultural activity.

TABLA DE CONTENIDOS

PREFACIO	1
RESUMEN	4
ABSTRACT	5
TABLA DE CONTENIDOS	6
ÍNDICE DE FIGURAS	10
ÍNDICE DE TABLAS	14
CAPÍTULO 1: INTRODUCCIÓN	
1.1 Problemática de la agricultura industrial en la Argentina.....	16
1.1.1 <i>Avena Fatua</i> L.	18
1.1.2 Resistencia de malezas a herbicidas	19
1.2 Manejo Integrado de Malezas (MIM).....	21
1.3 Planeamiento del MIM basado en modelos matemáticos	25
1.3.1 Modelos de simulación agronómicos.....	26
1.3.2 Optimización de modelos de simulación agronómicos	31
1.4 Tecnología de desarrollo adoptada.....	36
1.5 Objetivos y estructura de la tesis	39
CAPÍTULO 2: SIMULACIÓN DEL SISTEMA CULTIVO-MALEZA	
Introducción General	
2.1 Introducción.....	42

2.2 Ingreso de datos	43
2.3 Modelo de simulación del cultivo	45
2.4 Modelo de simulación de la maleza	47
2.5 Determinación de las fechas fenológicas del cultivo	52
2.6 Módulo económico.....	56
2.6.1 Margen Bruto (<i>MB</i>).....	56
2.6.2 Valor Actual (<i>VA</i>).....	62
2.7 Módulo de impacto ambiental.....	64
2.7.1 Coeficiente de Impacto Ambiental (<i>EIQ</i>).....	65
2.7.2 Índice de Riesgo.....	67
2.8 Casos de estudio.....	76
2.8.1 CASO SI	79
2.8.2 CASO SII	82
2.8.3 CASO SIII	85
2.8.4 CASO SIV	88
2.8.5 CASO SV	91
2.8.5 Resumen de los casos de estudio.....	94
2.9 Análisis de Sensibilidad.....	95
2.9.1 Análisis de sensibilidad sobre el porcentaje de semillas de maleza a cosecha.....	96
2.9.2 Análisis de sensibilidad sobre el banco inicial de semillas.....	98
2.9.3 Análisis de sensibilidad sobre la tasa de descuento	99

2.9.4 Análisis de sensibilidad sobre la ocurrencia de resistencia de la maleza al herbicida postemergente.....	100
--	-----

CAPÍTULO 3: ALGORITMO DE OPTIMIZACIÓN

Introducción General

3.1 Optimización MINLP-MO	104
3.1.1 Formulación matemática	105
3.1.2 Complejidad no lineal y combinatoria	106
3.1.3 Algoritmos determinísticos y metaheurísticos	107
3.2 Optimización continua por enjambre de partículas (PSO).....	109
3.2.1 Formulación matemática	112
3.2.2 Elementos y parametrización del PSO	114
3.3 PSO: tratamiento de restricciones.....	120
3.4 PSO: tratamiento de variables binarias	123
3.5 PSO: tratamiento de múltiples objetivos	126
3.6 Implementación propia del algoritmo PSO MINLP-MO	131
3.7 Testeo del PSO	135

CAPÍTULO 4: APLICACIONES DEL ALGORITMO

Introducción General

4.1 Esquema de optimización.....	144
4.1.1 Variables de decisión.....	146
4.2 Casos de estudio del modelo de optimización.....	153

4.2.1 CASO OI.....	154
4.2.2 CASO OII.....	162
4.2.3 CASO OIII.....	171
4.2.4 CASO OIV	177
CAPÍTULO 5: CONCLUSIONES Y TRABAJOS FUTUROS	
5.1 Contribución de la tesis y conclusiones generales	182
5.2 Trabajo futuro.....	186
REFERENCIAS	190
ANEXO I.....	200
ANEXO II.....	209
AII.1 Modelo de simulación del cultivo	209
AII.2 Modelo de simulación de la maleza.....	213
ANEXO III.....	221
ANEXO IV	225

ÍNDICE DE FIGURAS

Fig. 1.1: Técnicas de gestión de MIM	22
Fig. 2.1: Ingreso de datos	45
Fig. 2.2: Modelo de simulación de cultivos	46
Fig. 2.3: Etapas del ciclo de vida de AVEFA	48
Fig. 2.4: Modelo de simulación de la maleza	51
Fig. 2.5: Dinámica poblacional de AVEFA y factor de competencia (FC)	52
Fig. 2.6: Salida del software CRONOS.....	53
Fig. 2.7: Cálculo del índice para herbicidas (P).....	71
Fig. 2.8: Cálculo del índice de labranza (T).....	75
Fig. 2.9: Tasa de emergencia de la maleza AVEFA vs tiempo	76
Fig. 2.10: Datos meteorológicos vs tiempo.....	77
Fig. 2.11: Dinámica poblacional de AVEFA y factor de competencia en CASO SI	79
Fig. 2.12: Dinámica poblacional de AVEFA y factor de competencia en CASO SII	83
Fig. 2.13: Dinámica poblacional de AVEFA y factor de competencia en CASO SIII	86
Fig. 2.14: Dinámica poblacional de AVEFA y factor de competencia en CASO SIV	89
Fig. 2.15: Dinámica poblacional de AVEFA y factor de competencia en CASO SV.....	92
Fig. 2.16: Análisis de sensibilidad sobre el porcentaje de semillas de maleza a cosecha.....	97
Fig. 2.17: Análisis de sensibilidad sobre el banco de semillas	98
Fig. 2.18: Análisis de sensibilidad sobre la tasa de descuento.....	100

Fig. 2.19: Análisis de sensibilidad sobre la ocurrencia de resistencia de AVEFA al herbicida postemergente	102
Fig. 3.1: Descripción gráfica del PSO	111
Fig. 3.2: Descomposición de la velocidad.....	114
Fig. 3.3: Relajación de la región factible para el tratamiento de restricciones.....	121
Fig. 3.4: Función generada para valores específicos de a, b, c, d	125
Fig. 3.5: Soluciones dominadas y no dominadas: conformación del frente de Pareto	128
Fig. 3.6: Pseudocódigo del cálculo de la distancia de hacinamiento	130
Fig. 3.7: Esquema del PSO con variables continuas, binarias y multiobjetivo	132
Fig. 3.8: Pseudocódigo del PSO con variables continuas, binarias y multiobjetivo	133
Fig. 3.9: Esquema ingreso/salida PSO	134
Fig. 3.10: Frente de Pareto MO1 literatura vs PSO	136
Fig. 3.11: Frente de Pareto MO2 literatura vs PSO	137
Fig. 3.12: Frente de Pareto MO3 literatura vs PSO	138
Fig. 3.13: Frente de Pareto MO4 literatura vs PSO	138
Fig. 3.14: Frente de Pareto MO5 literatura vs PSO	139
Fig. 3.15: Frente de Pareto MO6 literatura vs PSO	140
Fig. 3.16: Frente de Pareto MO7 literatura vs PSO	141
Fig. 3.17: Frente de Pareto MO8 literatura vs PSO	142
Fig. 4.1: Sistema de asistencia a la toma de decisiones agronómicas	145
Fig. 4.2: Estructura de las variables continuas	147
Fig. 4.3: Representación de las variables continuas	147

Fig. 4.4: Esquema de las fechas de siembra según el tipo de cultivo	148
Fig. 4.5: Esquema de las fechas de aplicación de control de malezas	149
Fig. 4.6: Estructura de las variables binarias	150
Fig. 4.7: Representación de las variables binarias	151
Fig. 4.8: Frente de Pareto CASO OI.....	155
Fig. 4.9: Resultados de la optimización del CASO OI.....	156
Fig. 4.10: Dinámica poblacional de AVEFA y factor de competencia de S12-CASO OI.....	160
Fig. 4.11: Dinámica poblacional de AVEFA y factor de competencia de S9-CASO OI.....	161
Fig. 4.12: Dinámica poblacional de AVEFA y factor de competencia de S8-CASO OI.....	162
Fig. 4.13: Frente de Pareto CASO OII.....	163
Fig. 4.14: Resultados de la optimización del CASO OII.....	164
Fig. 4.15: Dinámica poblacional de AVEFA y factor de competencia de S11-CASO OII.....	168
Fig. 4.16: Dinámica poblacional de AVEFA y factor de competencia de S5-CASO OII.....	169
Fig. 4.17: Dinámica poblacional de AVEFA y factor de competencia de S8-CASO OII.....	170
Fig. 4.18: Frente de Pareto CASO OIII.....	171
Fig. 4.19: Resultados de la optimización del CASO OIII.....	172
Fig. 4.20: Dinámica poblacional de AVEFA y factor de competencia de	

S16-CASO OIII	176
Fig. 4.21: Dinámica poblacional de AVEFA y factor de competencia de	
S9-CASO OIII	176
Fig. 4.22: Dinámica poblacional de AVEFA y factor de competencia de	
S5-CASO OIII	177
Fig. 4.23: Resultados de la optimización del CASO OIV	179
Fig. 4.24: Dinámica poblacional de AVEFA y factor de competencia de	
S3-CASO OIV	180
Fig. 4.25: Dinámica poblacional de AVEFA y factor de competencia de	
S2-CASO OIV	181
Fig. AIII.1: Determinación de las fechas de aplicación de herbicidas post-siembra	
para el CASO SII cuando el estado vegetativo temprano (<i>VT</i>) supera los	
10 ind/m ²	222
Fig. AIII.2: Determinación de las fechas de aplicación de herbicidas post-siembra	
para el CASO SIV cuando el estado vegetativo temprano (<i>VT</i>) supera los	
10 ind/m ²	223
Fig. AIII.3: Determinación de las fechas de aplicación de herbicidas post-siembra	
para el CASO SV cuando el estado vegetativo temprano (<i>VT</i>) supera los	
10 ind/m ²	224

ÍNDICE DE TABLAS

Tabla 1.1: Modelos de simulación agronómicos.....	29
Tabla 1.1: Optimización de modelos de simulación agronómicos.....	33
Tabla 2.1: Formas de determinar las distintas fechas del ciclo de trigo según <i>TTA</i>	55
Tabla 2.2: Formas de determinar las distintas fechas del ciclo de cebada según <i>TTA</i>	56
Tabla 2.3: Valores de <i>EIQ</i> de los herbicidas utilizados en la simulación.....	66
Tabla 2.4: Cálculo del índice de herbicidas para dos estrategias de control químico.....	71
Tabla 2.5: Valores de <i>STU</i> y <i>STA</i> de las herramientas de labranza más utilizadas	72
Tabla 2.6: Relación de <i>LCC</i> con <i>TR</i>	74
Tabla 2.7: Cálculo del índice de labranza para dos estrategias de control mecánico	75
Tabla 2.8: Parámetros de todos los casos a simular	78
Tabla 2.9: Parámetros propios para cada caso a simular	78
Tabla 2.10: Resultados del CASO SI.....	81
Tabla 2.11: Resultados del CASO SII.....	84
Tabla 2.12: Resultados del CASO SIII.....	87
Tabla 2.13: Resultados del CASO SIV	90
Tabla 2.14: Resultados del CASO SV	93
Tabla 2.15: Resumen de los casos de estudio.....	94

Tabla 2.16: Eficiencia de los métodos de control postemergentes.....	101
Tabla 4.1: Resultados del CASO OI.....	159
Tabla 4.2: Resultados del CASO OII.....	167
Tabla 4.3: Resultados del CASO OIII.....	174
Tabla 4.4: Resultados del CASO OIV.....	179
Tabla AI.1: Parámetros del cultivo.....	200
Tabla AI.2: Parámetros de la maleza.....	201
Tabla AI.3: Parámetros de los métodos de control.....	202
Tabla AI.4: Datos de trigo y cebada.....	204
Tabla AI.5: Datos de <i>Avena Fatua</i> L.....	204
Tabla AI.6: Datos de los métodos de control de malezas.....	205
Tabla AI.7: Parámetros propios del caso a simular.....	207
Tabla AIII.1: Datos propios del CASO SI.....	221
Tabla AIII.2: Datos propios del CASO SII.....	221
Tabla AIII.3: Datos propios del CASO SIII.....	222
Tabla AIII.4: Datos propios del CASO SIV.....	223
Tabla AIII.5: Datos propios del CASO SV.....	224
Tabla AIV.1: Resultados del CASO OI.....	225
Tabla AIV.2: Resultados del CASO OII.....	226
Tabla AIV.3: Resultados del CASO OIII.....	227
Tabla AIV.4: Resultados del CASO OIV.....	228

CAPÍTULO 1

INTRODUCCIÓN

1.1. Problemática de la agricultura industrial en la Argentina

La agricultura es una de las principales actividades económicas de la Argentina, produciendo bienes para abastecer al país y exportar al resto del mundo. Cerca del 13% de los 280 millones de hectáreas de superficie continental del país se encuentra destinada a cultivos agrícolas¹. En estas áreas se siembra principalmente soja, trigo, maíz, girasol, sorgo y cebada. Nuestro país produce el 5% del total de granos del mundo y posee el 15% de participación en el comercio mundial de granos y subproductos¹. Debido a esta gran participación comercial, continuamente se intenta alcanzar el mayor rendimiento posible de los cultivos. Si bien existen varios factores que intervienen en ello, en esta tesis nos centraremos en la problemática que generan las malezas debido a sus efectos negativos, directos e indirectos, sobre el rendimiento y el manejo de los cultivos.

Existen diversas definiciones de maleza. El Instituto Nacional de Tecnología Agropecuaria (INTA²) las define como *“aquellas plantas que llegan a ser perjudiciales o indeseables en determinado lugar y en cierto tiempo”*³. Las malezas se caracterizan por ser más resistentes que los cultivos a: (i) los factores climáticos adversos tales como sequías, lluvias prolongadas y bajas temperaturas; (ii) los de orden edáfico, por ejemplo, la profundidad efectiva, el exceso de acidez o alcalinidad y la salinidad de los suelos; y (iii) los de orden biológico, relacionados con ataques de plagas y patógenos vegetales. Esto se debe a que estas especies fueron las primeras en ocupar los sitios dedicados actualmente a la agricultura,

¹ <https://surdelsur.com/es/agricultura-argentina/>

² <https://www.argentina.gob.ar/inta>

³ <https://inta.gob.ar/documentos/malezas-en-plantaciones-citricas-caracteristicas-y-metodos-de-control>

por lo cual, debieron subsistir por más tiempo, logrando un mayor poder de adaptación en ese espacio.

Dentro de sus principales particularidades se encuentran: su crecimiento vigoroso y rápido con fuertes raíces; su rápido ritmo de reproducción, tanto por semillas como por medios vegetativos; sus tasas de supervivencia elevadas, aún en medios hostiles; su largo período de latencia; su gran capacidad de dispersión de semillas y su alta diversidad genética, a tal punto que se adaptan a un amplio rango de condiciones. Las malezas compiten con el cultivo por agua, luz y nutrientes esenciales. Asimismo, pueden favorecer la proliferación de insectos y patógenos dañinos a las plantas de los cultivos. Finalmente, los exudados de raíces y hojas pueden ser tóxicos para las plantas cultivadas (Labrada y Parker, 1994).

La magnitud de los daños asociados a la presencia de malezas varía según la interacción de numerosos factores, tales como la composición de la comunidad de malezas, la abundancia de cada especie que la compone, el tiempo que dura esa interferencia, así como de las condiciones ambientales, entre otros.

Por todas estas razones, las malezas son consideradas unas de las más grandes limitaciones para alcanzar el rendimiento deseado de la gran mayoría de los sistemas de cultivos en el mundo. Por ejemplo, en Argentina se ha determinado que, si no se realiza un control de las malezas, las pérdidas de rendimiento del cultivo por competir con ellas rondan entre el 30 y 60%, dependiendo del cultivo y la maleza en particular⁴.

Además, estas plantas no deseadas también causan pérdidas en la calidad de producto obtenido. Las semillas, frutos u otras partes de las malezas afectan la pureza de los granos al mezclarse con éste durante la cosecha. También, la calidad del grano puede disminuir debido a que las semillas de malezas inmaduras presentes en las cosechas almacenadas aumentan el contenido de humedad, lo que habilita la proliferación de hongos y un aumento brusco de temperatura que provoca una disminución del poder germinativo de la semilla del cultivo. Asimismo, la presencia de maleza en la cosecha se considera materia extraña y puede ocurrir que, si esta cantidad supera el umbral de calidad propio para cada

⁴ <http://sedici.unlp.edu.ar/handle/10915/87468>

cultivo, se deban realizar erogaciones de dinero en costos de limpieza para cumplir con las normas de calidad impuestas.

Debido a estos perjuicios, tanto de rendimientos como de calidad, es muy importante y necesario su control para alcanzar buenos resultados económicos en la actividad agrícola.

Sin embargo, a pesar de que existe una gran cantidad de especies identificadas como malezas de los cultivos, aquellas que realmente causan un perjuicio significativo para la actividad agrícola son relativamente pocas. A dicho grupo reducido se lo identifica como “malezas problema” y son las que concentran la atención de investigadores, técnicos y productores. Particularmente en esta tesis se analizará la maleza *Avena fatua* L., la cual se encuentra segunda en una lista de las diez peores malezas del mundo (Valverde y Heap, 2010) con una presencia importante en nuestra zona productiva.

1.1.1. *Avena fatua* L.

Avena fatua L. (AVEFA) es una especie originaria de Eurasia que se encuentra distribuida principalmente en una amplia región del sudoeste de la provincia de Buenos Aires, Santa Fe, Entre Ríos, Córdoba, Tucumán y parte de La Pampa. Esta especie anual produce semillas con distinto grado de dormición (estado en el cual una semilla viable no germina, aunque los factores externos sean favorables para hacerlo) que pueden germinar típicamente desde marzo a noviembre. Esto genera un amplio período de emergencia con patrones variables entre años, hecho que dificulta más su control.

AVEFA es una especie autógama (aquellas que se reproducen por autofecundación) con una capacidad reproductiva de entre 50 y 1000 semillas por planta. La longevidad de las semillas es de aproximadamente 3 años, aunque dentro del primer y segundo año, después de la dispersión natural, germinan alrededor del 80% de las semillas que se encuentran en el suelo.

En Scursoni y col. (2018) se pueden encontrar más detalles de interés agronómico referido a esta maleza, como por ejemplo su taxonomía, biología, fenología, caracterización botánica, dinámica poblacional, distribución geográfica y su incidencia en diferentes sistemas de producción. Algunos datos reportados por estos autores fueron necesarios para confeccionar el modelo agronómico de Molinari y col. (2020), el cual se empleó en esta tesis (Capítulo 2).

Esta maleza es una de las más importantes del sur de la provincia de Buenos Aires debido al daño que provoca en los cereales de invierno (especialmente en trigo). Este perjuicio se percibe en la disminución de rendimiento y aumento de los costos para su control, como también en descuentos en la comercialización del cultivo (Scursoni y col., 2018). A pesar de que desde 1970 el desarrollo y uso de herbicidas eficientes minimizó su avance, su presencia en los lotes continúa siendo alta⁵.

Asimismo, se ha detectado la aparición de resistencia de AVEFA a ciertos herbicidas (como diclofop-metil) debido al uso reiterado de este tipo de control a lo largo de varios años. Esto ha ocasionado que los costos para su control aumenten, así como también el impacto negativo al medio ambiente. A continuación, se detallará esta problemática.

1.1.2. Resistencia de malezas a herbicidas

En los sistemas productivos actuales, las malezas siguen siendo la principal adversidad biótica en tanto resultan un desafío para la investigación científica-tecnológica. Durante muchas décadas, los herbicidas han sido el medio de control de malezas más utilizado en cultivos convencionales debido a su simplicidad, efectividad y asequibilidad. Por estas razones, el empleo de herbicidas se redujo durante mucho tiempo a la aplicación rutinaria del agroquímico, sin considerar aspectos de la biología de las malezas ni su integración con otras técnicas de control. Sin embargo, se ha demostrado que el uso ininterrumpido de

⁵ https://inta.gob.ar/sites/default/files/script-tmp-inta_bordenave_-_avena_fatua_resistente_a_herbicidas.pdf

estos productos ha provocado, en muchos casos, la pérdida de su eficacia debido a que algunas malezas desarrollaron mecanismos de resistencia.

En 1998, el Herbicide Resistant Plants Committee⁶ consideró como malezas resistentes a aquellas que cuentan con la habilidad inherente de sobrevivir y reproducirse al ser expuestas a dosis de herbicidas que normalmente matarían a un individuo de la misma especie (definición aceptada también por la Weed Science Society of America).

Las malezas resistentes surgen de aplicar el mismo herbicida, del uso generalizado de un ingrediente activo en particular o, incluso, debido a la sub-dosificación de los agroquímicos (Lanfranconi y col., 2012). Por ejemplo, algunos grupos de herbicidas que ejercen una gran presión de selección sobre biotipos resistentes pueden crear problemas de resistencia en períodos de tan solo cuatro a seis años de aplicación repetida (Papa y Tuesca, 2014).

En los últimos años, en los sistemas agrícolas actuales se han presentado cada vez más cantidad de poblaciones de malezas difíciles de controlar. Las mismas, además de requerir mayores dosis y frecuencias de aplicaciones de herbicidas, provocando la aparición de biotipos de malezas resistentes, imposibilitan su correcto control repercutiendo negativamente sobre estos sistemas. Esta problemática no solo se aprecia en Argentina, sino que también cobra gran importancia en otros países de Latinoamérica, EEUU y Australia, entre otros. Según Palau y col. (2018), que se basaron en un análisis de artículos de la revista Weed Science⁷, en todo el mundo existen 383 biotipos resistentes de malezas. Por otro lado, de acuerdo con el Herbicide Resistant Action Committee⁸ (HRAC), en marzo del 2021 el número de casos de resistencia asciende a 521 a nivel mundial.

En nuestro país, el camino de las malezas hacia la resistencia se inició en 1996, con la aparición y adopción del cultivar de soja resistente a glifosato. En 2018, en Argentina se identificaron diecisiete malezas resistentes a agroquímicos (principalmente relacionadas al cultivo de soja), tratándose el 41% de latifoliadas (especies que poseen hojas anchas) y el 59% de gramíneas (plantas monocotiledóneas de tallo cilíndrico, nudoso y generalmente

⁶ <https://wssa.net/wssa/weed/resistance/herbicide-resistance-and-herbicide-tolerance-definitions/>

⁷ <https://www.cambridge.org/core/journals/weed-science>

⁸ <http://www.weedscience.org/Home.aspx>

hueco, hojas alternas que abrazan el tallo, flores agrupadas en espigas o en panojas y grano seco cubierto por las escamas de la flor). De este total de especies, el 88% presenta resistencia a glifosato (Palau y col., 2018).

En marzo de 2021, en una página del HRAC⁹ se establece que en Argentina el total de especies resistentes asciende a veintiocho. Actualmente no se conoce el total de la superficie afectada por malezas resistentes, sin embargo, es preocupante su avance y su impacto negativo a nivel productivo, económico y medioambiental.

En respuesta al creciente aumento de malezas (con y sin resistencia) y buscando un desarrollo sustentable de la actividad agrícola, que considere tanto la protección del medio ambiente como la viabilidad económica y productiva, surge el manejo integrado de malezas.

1.2. Manejo Integrado de Malezas (MIM)

El MIM puede ser definido como un proceso de toma de decisiones que combina diferentes técnicas para el manejo de malezas teniendo en cuenta información ambiental, biológica y ecológica tanto de los cultivos como de las malezas (Menalled, 2010). Esta metodología de manejo combina juiciosamente múltiples técnicas de control con el fin de reducir la interferencia de las malezas y limitar su propagación (INTA¹⁰) aceptando el hecho de que ninguna técnica individual es totalmente efectiva o carente de consecuencias negativas. Esta forma de lidiar con las malezas pretende reducir su presencia a niveles tales que los perjuicios económicos producidos se hallen por debajo de un umbral económico aceptable para el sistema general de producción (Chantre y col., 2013). Asimismo, el MIM también tiene en cuenta la sostenibilidad medioambiental del agroecosistema y reduce la presión de selección sobre la resistencia a herbicidas de las malezas (Harker y O'Donovan, 2013).

⁹ <http://www.weedscience.org/Pages/GeoChart.aspx>

¹⁰ <https://inta.gob.ar/documentos/introduccion-al-manejo-integrado-de-malezas>

Para poder implementar el MIM es necesario: (i) identificar las malezas presentes, su distribución y nivel de infestación; (ii) conocer la biología y ecología de las especies predominantes; (iii) determinar el daño potencial que pueden ocasionar y (iv) disponer de los recursos requeridos para llevar a cabo los métodos de control técnicamente más efectivos, aceptables económicamente y seguros para el medioambiente. El MIM de malezas es un programa que debería ser sostenible en el tiempo, logrando que las poblaciones de especies no deseadas se mantengan a niveles que no causen daños excesivos a los cultivos. En la Fig. 1.1 se resumen los distintos métodos del control de malezas que se pueden combinar a través del MIM. A continuación, se detalla cada uno de ellos, en base a la información provista por GROW¹¹ (Getting Rid Of Weeds - red pública conformada por un grupo de agrónomos, especialistas en malezas y economistas de EEUU) y FAO¹² (Organización de las Naciones Unidas para la Agricultura y la Alimentación).

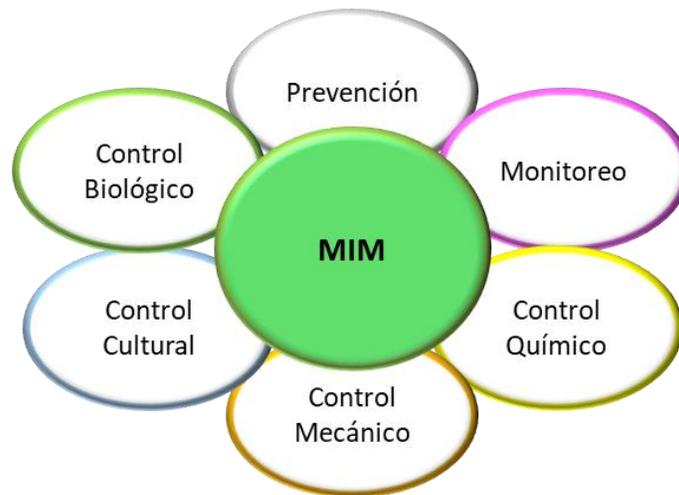


Fig. 1.1: Técnicas de gestión de MIM

1. *Prevención de la dispersión de semillas de malezas:* es una parte importante del control integrado de malezas, aunque muchas veces se la subestima. La dispersión

¹¹ GROW <https://growiwm.org/what-is-integrated-weed-management/>

¹² FAO <http://www.fao.org/3/a0884s/a0884s.pdf>

de semillas ocurre naturalmente (por el viento, agua y animales, entre otros) y también por actividades humanas. Esta última puede reducirse e incluso eliminarse con una planificación apropiada. Un método efectivo para esto es la implementación de medidas adecuadas de limpieza de la maquinaria y de equipos agrícolas. Asimismo, también es primordial mantener el control de malezas alrededor de los márgenes de los lotes y establecer vegetación deseable en el suelo inmediatamente después de haberlo laboreado, para prevenir futuras infestaciones de malezas.

2. *Monitoreo de las poblaciones de malezas:* La recopilación sistemática de datos sobre la distribución de las especies de malezas que afectan a las distintas etapas del proceso productivo es útil, en el corto plazo, para tomar decisiones inmediatas para un control adecuado y evitar pérdidas en el cultivo. A largo plazo, estos registros constituyen una buena base para evaluar la efectividad de los controles llevados a cabo y contribuyen a una toma de decisiones más informada.
3. *Control cultural:* Implica diversos manejos agronómicos tanto del suelo como del cultivo. Su objetivo es ayudar a que el ambiente sea más favorable para el desarrollo del cultivo, intentando que sea más competitivo frente a la maleza. Entre las medidas culturales se destacan:
 - i. *Rotación de cultivos:* esta práctica involucra la alternancia de diferentes cultivos en el mismo lote. Debido a que algunas especies de malezas crecen habitualmente en cultivos específicos por haberse adaptado a sus fechas de siembra y competencia, una buena rotación de cultivos tiende a desestabilizar e impedir su crecimiento. Mientras más diversas sean estas rotaciones, mejor será la interrupción del ciclo de vida de la maleza. Otro beneficio asociado a esta medida es la oportunidad de utilizar herbicidas con modos de acción diferentes (por tratarse de distintos cultivos), retrasando de esta manera el desarrollo de malezas resistentes.
 - ii. *Elección del cultivar:* es uno de los métodos más económicos. Se refiere al uso de un cultivar más competitivo para asegurar que sea éste el que domine el lote

al establecerse rápidamente en forma vigorosa y con alta densidad. Sin embargo, su desventaja es que suele poseer un rendimiento potencial del cultivo menor que el del cultivar estándar.

iii. *Preparación de suelos*: Existen ciertas situaciones en las que si se mejoran las condiciones del suelo aumentan las posibilidades de reducir la competitividad de las malezas. Conociendo el tipo de suelo y la biología y ecología de las malezas es posible planificar una mejor estrategia que favorezca más al desarrollo del cultivo en detrimento de la maleza.

iv. *Fertilización*: Como ya se mencionó, los cultivos y las malezas compiten por los nutrientes, pero algunos estudios demostraron que el agregado de los mismos puede beneficiar en mayor medida al cultivo si se los aplica de manera localizada sobre el surco y no en toda la extensión del lote.

v. *Manejo de agua*: un riego apropiado durante las etapas de crecimiento del cultivo permitiría que éste crezca más rápido y vigorosamente, logrando que compita más con la maleza. Sin embargo, es necesario controlar la forma en que se suministra agua de riego, dado que puede resultar una fuente de contaminación de semillas de malezas.

vi. *Densidad de siembra*: el aumento de las densidades de siembra de los cultivos permite que éstos aprovechen mejor y más rápido los recursos ambientales existentes compitiendo mejor con la maleza presente. Esto puede conducir también a un mayor rendimiento del cultivo a costa, generalmente, de un aumento en los gastos de siembra.

4. *Control mecánico*: se trata de técnicas con las que se efectúa la remoción de malezas de manera manual o mediante alguna herramienta de labranza. Los métodos manuales son más lentos y caros que la realización de labranzas, aunque éstas últimas tienen la desventaja de poder ocasionar efectos negativos sobre el desarrollo del cultivo y sobre las propiedades del suelo.

5. *Control químico*: se refiere al uso de herbicidas para el control de malezas. Éstos son uno de los principales métodos de control dentro del MIM por ser una de las técnicas más eficaces. Sin embargo, también se considera que son los que ocasionan mayor daño medioambiental, sobre todo si no se los usa responsablemente. Para ello es importante usar en forma secuencial herbicidas con distintos modos de acción para evitar generar resistencia por parte de las malezas. Idealmente, cada componente de una mezcla de herbicidas debería tener diferente modo de acción, un alto grado de eficacia y ser efectivo contra las malezas problemáticas.
6. *Control biológico*: se trata de diversos agentes que poseen modos de acción de control biológico sobre las malezas, como por ejemplo insectos, nematodos, hongos, virus, aves y mamíferos. El más exitoso hasta el momento ha sido utilizar insectos que provocan cierta destrucción de las plantas no deseadas al defoliarlas, penetrar en sus tallos o raíces, comer sus semillas o formar agallas en las partes reproductivas. Sin embargo, el control biológico per se no ha tenido un impacto importante en la agricultura extensiva debido a la alta especificidad requerida entre huésped y hospedante que restringe el uso de biocontroladores en grandes superficies.

1.3. Planeamiento del MIM basado en modelos matemáticos

Los modelos matemáticos de simulación, que representan sistemas cultivos-malezas, pueden emplearse para guiar la toma de decisiones relacionadas con el MIM a través de sistemas de soporte a la toma de decisiones (DSS por sus siglas en inglés). Según Chantre y González-Andújar (2020), los DSS se definen como programas computacionales que, utilizando el conocimiento de expertos, modelos de simulación y/o bases de datos, asisten al proceso de toma de decisiones al ofrecer una serie de recomendaciones y/u opciones. El

principal objetivo del DSS es mejorar la calidad, el tiempo y la eficiencia con que se toman las decisiones sobre diversas áreas de estudio.

Por ejemplo, algunos modelos agronómicos permiten predecir teóricamente, a lo largo de un período de varios años, la dinámica de las poblaciones de malezas y los rendimientos de los cultivos como consecuencia de la aplicación combinada de las diferentes estrategias que conforman la caja de herramientas del MIM. De esta manera, el usuario podría obtener información del sistema cultivo-maleza al estudiar diversos escenarios y evaluar, de todos los casos simulados, cuál considera la mejor estrategia a implementar.

Sin embargo, las posibles combinaciones de todas las opciones que abarca el MIM suelen ser muy grandes para analizar cada una de ellas en una simulación (más aún si el horizonte de planeamiento es de varios años). Para suplir esta desventaja, se realiza la optimización de los modelos agronómicos. Esta herramienta permite encontrar las mejores estrategias de MIM en función de ciertos objetivos, evitándole al usuario la necesidad de hallarlas por su cuenta.

A continuación, se proporciona un panorama de la bibliografía referente a la simulación de modelos agronómicos orientados específicamente al control de malezas. Luego, se efectúa una revisión de trabajos previos sobre optimización del manejo de malezas empleando modelos matemáticos de competencia cultivo-maleza sobre diferentes sistemas de producción, que constituyen la base de los DSS.

1.3.1. Modelos de simulación agronómicos

En el caso de la agricultura, desde finales de 1980, una gran cantidad de modelos de simulación orientados al soporte a la toma de decisiones han sido desarrollados. En particular, en esta sección nos centraremos en realizar una breve revisión bibliográfica de modelos de simulación cultivo-maleza. En la Tabla 1.1, adaptada de Lodovichi (2018), se puede observar una clasificación de diversos modelos en función de: (i) la maleza/cultivo que simulan; (ii) el país donde se desarrolló el estudio, ya que según el lugar deben ajustarse

ciertos parámetros requeridos para la simulación; (iii) el tipo del modelo, que puede ser climático (si hace uso explícito de datos meteorológicos) y/o biológico (si cuantifica el modelado de algunos subprocesos eco-fisiológicos importantes). A su vez, estos últimos se dividen en modelos empíricos (basados en relaciones estadísticas) o mecanicistas (basados en primeros principios); (iv) si presenta una evaluación económica o medioambiental de las estrategias propuestas y (v) si el alcance es operativo o táctico/estratégico.

En general, la mayoría de los modelos de la literatura se centran en el estudio de las malezas anuales típicas presentes en las rotaciones de trigo, aunque también existe el modelado de otros tipos de cultivo.

Como se puede apreciar de la Tabla 1.1, la mayoría de los desarrollos se llevaron a cabo en países europeos. De todas formas, también se han realizado estudios al respecto en Australia y América, por lo cual se evidencia que se trata de un tema de interés mundial.

En cuanto al tipo de modelo, a excepción de una de las referencias enunciadas (Colbach y col. (2007)), el resto presentan modelos biológicos y empíricos. Sólo en cuatro de los quince trabajos analizados (Colbach y col. (2007), Mézière y col. (2013), Andrew y Storkey (2017) y Molinari y col. (2020)) se tiene en cuenta los datos meteorológicos como requerimiento necesario para la simulación.

Por otro lado, más de la mitad de la literatura presentada en esta sección realiza una evaluación económica en su simulación. Esto resulta muy útil para estimar los resultados económicos de la actividad agronómica y comparar las distintas estrategias implementadas entre sí. Sin embargo, solo recién en los últimos años se ha manifestado la preocupación por cuantificar los efectos negativos que podrían tener los distintos métodos de control de malezas sobre el medio ambiente. Es por esta razón que relativamente pocos de estos artículos incluyen una evaluación cuantitativa del impacto ambiental (Berti y Zanin (1997), Berti y col. (2003) y Molinari y col. (2020)).

En base a esta revisión parcial, se puede decir que el desarrollo de modelos agronómicos se concentra principalmente en problemas de simulación táctica/estratégica, considerando horizontes de planificación de varios años, más que en decisiones de tipo operativas dentro

de una temporada. Sin embargo, debido a la gran cantidad de posibles combinaciones de diferentes opciones de control, así como también de otras decisiones agronómicas que pueden simularse en el corto o largo plazo, resulta casi imposible analizar por simulación todos los escenarios agronómicos que podrían llevarse a cabo a lo largo de un periodo de varios años. Es por esta razón que se considera imprescindible contar con métodos sistemáticos de exploración del espacio de soluciones, por ello, muchos DSS también implementaron algoritmos de optimización numérica para automatizar la búsqueda de la mejor estrategia agronómica.

Tabla 1.1: Modelos poblacionales de manejo de malezas

Referencia	Maleza/Cultivo	País de desarrollo	Tipo de modelo		Evaluación		Alcance		
			Climático	Biológico Empírico Mecanicista	Económica	Impacto Ambiental	Operacional	Táctico/ Estratégico	
Doyle y col. (1986)	<i>Alopecurus myosuroides</i> / Trigo de invierno	Reino Unido		X		X			X
Cousens y col. (1987)	<i>Avena fatua</i> L./ Trigo de invierno	Reino Unido		X		X			X
González-Andújar (1991)	<i>Avena sterilis</i>	España		X					X
Wiles y col. (1996)	General	USA		X		X			X
Berti y Zanin (1997) / Berti y col. (2003)	16 especies de malezas/ soja y trigo	Italia		X		X	X		X
González-Andújar y Fernández-Quintanilla (2004)	<i>Lolium rigidum</i>	España		X					X
Pannell y col. (2004)	<i>Lolium rigidum</i>	Australia		X		X			X
Colbach y col. (2007)	<i>Alopecurus myosuroides</i>	Francia	X		X			X	

Tabla 1.1 (continuación): Modelos poblacionales de manejo de malezas

Referencia	Maleza/Cultivo	País de desarrollo	Tipo de modelo			Evaluación		Alcance	
			Climático	Biológico		Económica	Impacto Ambiental	Operacional	Táctico/ Estratégico
				Empírico	Mecanicista				
Torra y col. (2010)	<i>Papaver rhoeas</i> /trigo y colza	España		X					X
Mézière y col. (2013)	<i>Alopecurus Myosurroides</i>	Francia	X	X					X
Vasileiadis y col. (2015)	Diversas malezas/maíz	Alemania/ Italia/Eslovenia		X		X			X
Menegat y col. (2017)	<i>Avena Fatua</i> L./trigo y colza	Alemania		X		X			X
Andrew y Storkey (2017)	<i>Alopecurus Myosurroides</i> /trigo	Reino Unido	X	X					X
Molinari y col. (2020)	<i>Avena fatua</i> L./trigo y cebada	Argentina	X	X		X	X		X

1.3.2. Optimización de modelos de simulación agronómicos

La optimización de modelos matemáticos sobre el manejo de malezas es un campo de estudio bastante amplio. Por ejemplo, existen numerosos trabajos sobre el control óptimo de infestaciones de malezas dentro de diversos ecosistemas (no sólo relacionados con cultivos) con la finalidad de analizar el efecto de especies invasoras. A su vez, una gran cantidad de literatura profundiza en el control de maleza desde el punto de vista de su distribución espacial.

En esta sección nos enfocaremos en trabajos que comprenden específicamente la optimización del control de malezas empleando modelos matemáticos que representan su competencia con cultivos en sistemas de producción agrícola. Los mismos se presentan en la Tabla 1.2 clasificados según: (i) la maleza/cultivo que optimizan; (ii) el país donde se desarrolló el estudio; (iii) el tipo de optimización que se realiza; (iv) el alcance del trabajo, que puede ser operativo o táctico; (v) la función objetivo a optimizar, que puede tener en cuenta el aspecto económico y medioambiental; (vi) el control de maleza, que puede ser químico, cultural, mecánico, biológico y/o manual; (vii) el horizonte de planeamiento (HP) del modelo agronómico y (viii) las variables de decisión: aquellas variables que, al optimizarse, modificarán su valor hasta encontrar el que mejor se ajuste según la función objetivo que se maximiza o minimiza.

Según lo expuesto en la Tabla 1.2, se puede decir que la mayor parte de la investigación realizada en este campo utiliza un enfoque de programación dinámica o dinámica estocástica para resolver los problemas de optimización, si bien existen otras metodologías utilizadas en menor medida, como la programación matemática. Además, al igual que en los modelos agronómicos de simulación analizados anteriormente, la mayoría de los trabajos de optimización también tienen un alcance táctico.

Adicionalmente, cabe destacar que gran parte de estos trabajos considera únicamente el efecto económico de las estrategias de control. Sólo tres de ellos (Sells (1995), Neeser y col.

(2004), Lodovichi y col. (2013)) también tienen en cuenta el impacto ambiental ocasionado por los métodos de control de malezas.

Asimismo, existen pocos estudios respecto de la resistencia que pueden desarrollar las malezas frente a la aplicación de ciertos herbicidas. Sólo Gordard y col. (1995) y Doole y Panell (2008) plantean un modelo que tiene en cuenta este tema, el cual recientemente está cobrando más importancia.

En cuanto al control de malezas más estudiado, es evidente que el mayor análisis se concentra en los métodos químicos (once trabajos) y en menor medida en métodos culturales (seis trabajos) y mecánicos (tres trabajos). Sólo Chalak-Haghighi y col. (2008) considera también métodos biológicos, mientras que, Martínez y col. (2018) es el único que tiene en cuenta el control manual.

Gran parte de los trabajos de la Tabla 1.2 plantean un horizonte de planeamiento mayor a cinco años, mientras que la mitad de ellos permite optimizar lo que sucederá en un plazo superior a diez años. De esta manera, la mayoría de estas herramientas brindan una estrategia a largo plazo.

Por último, es importante destacar que los estudios de optimización se enfocan principalmente en establecer la mejor estrategia de control de malezas, analizando qué método de control establecer (en general eligiendo entre diferentes herbicidas). Sólo dos de ellos (Sells (1995) y Neeser y col. (2004)) también determinan la mejor rotación de cultivos y su fecha de siembra.

En líneas generales, se podría decir que la optimización de este tipo de modelos de manejo de cultivos-malezas constituyen herramientas útiles de soporte al proceso de toma de decisiones agronómicas. Las mismas permiten planificar una estrategia a seguir por varios años al evaluar los resultados de combinar una amplia gama de acciones que no podrían analizarse sólo simulando escenarios específicos.

De la revisión anterior se destaca el hecho de que no se han identificado estudios que aborden de manera explícita la optimización multiobjetivo del MIM, así como la consideración del impacto ambiental asociado al control mecánico.

Tabla 1.2: Optimización de modelos de simulación agronómicos

Referencia	Maleza/Cultivo	País de desarrollo	Optimización	Alcance	Función objetivo		Control	HP (años)	Variables de decisión
					Económica	Impacto Ambiental			
Fisher y Lee (1981)	<i>Avena Fatua</i> L. o <i>Avena ludovica</i> /Trigo	Australia	Dinámica	Táctico	Máx. VA ¹³	-	Químico	10	(i) Estrategia de control
Taylor y Burt (1984)	<i>Avena Fatua</i> L./trigo de primavera	EEUU	Dinámica estocástica	Táctico	Máx. VA	-	Químico	5	(i) Estrategia de control
Pandey y Medd (1991)	<i>Avena Fatua</i> L./Trigo	Australia	Dinámica estocástica	Táctico	Máx. VA	-	Químico/ Cultural	-	(i) Dosis herbicidas
Sells (1995)	<i>Avena Fatua</i> L./trigo-cebada	Reino Unido	Dinámica estocástica	Táctico	Mín. Costos	Involucrado como costo económico	Químico/ Cultural	10	(i) Trigo/cebada de invierno o primavera; (ii) Fecha de siembra del cultivo; (iii) Estrategia de control
Gorddard y col. (1995)	<i>Lolium rigidum</i> /Trigo	Australia	No lineal	Táctico	Máx. VA	-	Químico/ no-químico	30	(i) Estrategia de control

¹³ VA: Valor Actual

Tabla 1.2 (continuación): Optimización de modelos de simulación agronómicos

Referencia	Maleza/Cultivo	País de desarrollo	Optimización	Alcance	Función objetivo		Control	HP (años)	Variables de decisión
					Económica	Impacto Ambiental			
Wu (2000)	<i>Setaria pumila</i> – <i>Xanthium strumarium</i> /maíz	EEUU	Teoría de control óptimo	Táctico	Máx. VA	-	Químico	5	(i) Dosis herbicidas
Neeser y col. (2004)	46 malezas/trigo de invierno-maíz-soja-remolacha azucarera-sorgo	EEUU	Clasificación	Táctico	Máx. Ganancia Neta	Involucrado como restricción	Químico	-	(ii) Esquema de rotación de cultivos; (i) Dosis herbicidas
Doole y Panell (2008)	<i>Lolium rigidum</i> / altramuces-trigo- cebada-canola- 3 tipos de pastos	Australia	Estocástica	Táctico	Máx. VA	-	Químico/ Mecánico/ Cultural	20	(ii) Estrategia de control
Chalak-Haghighi y col. (2008)	<i>Cirsium arvense</i> / Pasturas	Nueva Zelanda	Dinámica	Táctico	Máx. Ganancia Neta	-	Químico/ Mecánico/ Cultural/ Biológico	40	(i) Estrategia de control

Tabla 1.2 (continuación): Optimización de modelos de simulación agronómicos

Referencia	Maleza/Cultivo	País de desarrollo	Optimización	Alcance	Función Objetivo		Control	HP (años)	Variables de decisión
					Económica	Impacto Ambiental			
Benjamin y col. (2009)	<i>A. myosuroides</i> - <i>Anisantha sterilis</i> L.- <i>Stellaria media</i> L./ guisantes-patatas- colza- remolacha azucarera- trigo- cebada- habas	Reino Unido	Dinámica estocástica	Táctico	Máx. Ganancia Neta	-	Químico/ Mecánico/ Cultural	6	(i) Estrategia de control
Lodovichi y col. (2013)	<i>Avena fatua</i> L./trigo	Argentina	MINLP	Operativo	Máx. Ganancia Neta	Involucrado como costo económico	Químico	1	(i) Estrategia de control
Martínez y col. (2018)	<i>Zea mays ssp</i> /maíz	España	Dinámica	Táctico	Mín. Costos	-	Cultural/ Manual	15	(i) Estrategia de control

1.4. Tecnología de desarrollo adoptada

En esta sección se presentará la tecnología que fue necesario emplear para poder implementar el modelo de DSS de MIM, así como también para el desarrollo de la herramienta que lo optimizará.

Si bien existen diversas plataformas de programación de modelos de simulación y algoritmos numéricos muy desarrollados para optimizarlos, la mayoría del software más competitivo es propietario y posee costos elevados en conceptos de licencias (como gProms¹⁴, GAMS¹⁵ y MATLAB¹⁶). Asimismo, para muchas aplicaciones de cierta dimensión, aun contando con las plataformas de desarrollo más sofisticadas y amigables, se suele requerir de un esfuerzo de programación adicional significativo para implementar y resolver los modelos resultantes (Chen y col. (2017), Lang y Zhao (2016), Pfetsch y col. (2015)).

Con el fin de evitar los costos relacionados con la adquisición de licencias propietarias, en esta tesis se propone confeccionar una herramienta propia de simulación y optimización del MIM, empleando recursos de software libre. Es importante destacar que, con la creación de un software propio, no se pretende competir con plataformas comerciales de modelado y optimización (como las comentadas previamente). Lo que se busca es disponer de un instrumento accesible para desarrollar proyectos de investigación y transferencia, que proporcione soluciones de aceptable eficiencia y no requiera presupuestos para adquisición y mantenimiento de licencias comerciales de software lo que, en la práctica, suele resultar una restricción importante para transferir y desarrollar colaborativamente.

A su vez, cabe mencionar que existen muchas herramientas de optimización no comerciales muy competitivas y utilizadas que podrían llegar a adaptarse a los fines perseguidos (por ejemplo, PYOMO¹⁷ y PyGAD¹⁸ desarrollados en Python entre varios otros). Sin embargo,

¹⁴ <https://www.psenterprise.com/products/gproms>

¹⁵ <https://www.gams.com/>

¹⁶ <https://www.mathworks.com/products/matlab.html>

¹⁷ <http://www.pyomo.org/>

¹⁸ <https://pygad.readthedocs.io/en/latest/>

éstas no cuentan con la garantía de un soporte permanente, lo que podría llegar a ocasionar su interrupción en el futuro, amenazando la continuidad del presente proyecto. Además, aunque el código de dichas herramientas esté desarrollado con las mejores prácticas, suele resultar complejo adaptarlo y modificarlo, a veces tanto o más que desarrollar una herramienta propia. Por estas razones se prefirió apostar a dar continuidad a desarrollos propios (Damiani y col., 2018) en lugar de emplear desarrollos libres de otros grupos de investigación.

En materia de software de desarrollo, existen en la actualidad diversas opciones con excelentes prestaciones para emprender un proyecto de estas características entre las que se destacan Julia¹⁹, R²⁰ y Python²¹. En este trabajo, tanto el modelo de simulación agronómica como el algoritmo de optimización se programaron en el lenguaje de código abierto Python. Se seleccionó esta alternativa porque el grupo de investigación posee cierta experiencia en su uso y además por su enorme popularidad y disponibilidad de complementos como se menciona a continuación.

Python es considerado uno de los lenguajes de programación libres o gratuitos más populares por su simplicidad, versatilidad, agilidad de lectura, flexibilidad y gran precisión y calidad de sintaxis. Al ser de alto nivel admite un prototipado rápido de todo tipo de aplicaciones o algoritmos utilizando muy poco código. Además, acepta la incorporación de nuevas funciones y clases a un objeto existente porque es orientado a objetos y dinámico.

Python es un lenguaje interpretado por una máquina virtual. Esto permite que pueda utilizarse en cualquier sistema que contenga su interpretador, constituyéndose como un lenguaje multiplataforma. De esta manera, admite que se combinen distintas aplicaciones realizadas en diversas plataformas, por eso se lo utiliza como software “glue”.

Debido a que su sintaxis es muy intuitiva y de propósito general, su curva de aprendizaje resulta ser realmente corta, esto es muy importante dado que permite que un desarrollador se enfoque más en la creación de nuevos productos que en el lenguaje en sí. Python facilita

¹⁹ <https://julialang.org/>

²⁰ <https://www.r-project.org/>

²¹ <https://www.python.org/>

la programación ya que posee una gran variedad de bibliotecas, paquetes y “toolboxes”. Asimismo, cuenta con una comunidad muy activa que responde a problemas concretos a través de sugerencias, tutoriales o incluso hasta brindando el código para resolverlos.

A continuación, se describirán en detalle las tres librerías científicas, gratuitas y de gran capacidad, que potencian el uso de Python en diferentes aplicaciones:

- *Numpy*: añade a Python funcionalidades para el manejo sencillo y eficiente de operaciones matriciales y vectoriales, desde las más básicas hasta las más complejas. Además, proporciona herramientas que permiten incorporar código fuente de otros lenguajes de programación como C/C++ o Fortran, lo que incrementa notablemente su compatibilidad e implementación.
- *Scipy*: es una librería de herramientas numéricas que usa Numpy como base. Posee módulos para optimización de funciones, integración, funciones especiales, y resolución de ecuaciones diferenciales ordinarias, entre otros.
- *Matplotlib*: es una biblioteca para la generación de gráficos 2D y 3D a partir de datos contenidos en listas o arrays.

Además de los mencionados, Python cuenta con una gran variedad de otros entornos de trabajo (frameworks) que son muy convenientes para el desarrollo de actividades complementarias a esta investigación. Por ejemplo, Pandas²² brinda herramientas para análisis y manipulación de datos. En otro orden de aplicaciones, Django²³, posibilita la construcción de aplicaciones web, lo cual es sumamente útil porque aumenta la capacidad de transferencia de los desarrollos realizados en Python.

Una de las desventajas de Python frente a lenguajes compilados como C y Fortran es su menor rapidez de ejecución. Esto se debe a que Python, al ser un lenguaje dinámico e interpretado, ejecuta el código línea a línea y, además, utiliza una gran cantidad de memoria, lo que se traduce en tiempos de cómputo más elevados.

²² <https://pandas.pydata.org/>

²³ www.djangoproject.com

Este lenguaje se puede ejecutar en varios editores (IDEs). En esta tesis se decidió utilizar Pycharm²⁴, debido a que presenta una comunicación más fluida con Bitbucket²⁵, herramienta que se explica posteriormente.

Bitbucket es un Sistema de Control de Versiones (SCV) distribuido basado en web, para los proyectos que utilizan Mercurial y Git. Este sistema informático permite registrar los cambios realizados sobre un archivo o conjunto de archivos a lo largo del tiempo. Además, su uso permite una revisión de código de manera más eficiente y una comunicación más sencilla entre los miembros del grupo, facilitando la colaboración y acelerando el proceso de desarrollo.

1.5. Objetivos y Estructura de la Tesis

El objetivo general de la tesis es desarrollar un prototipo de sistema de asistencia a la toma de decisiones que permita guiar el MIM en sistemas de producción de cereales de invierno. Dentro de este marco se plantean, a su vez, tres grandes objetivos específicos:

1. Adaptar, extender e implementar computacionalmente un modelo de simulación cultivo-maleza que pueda representar el comportamiento multianual de los sistemas productivos típicos de la zona de estudio seleccionada.
2. Desarrollar una herramienta de software propia para resolver problemas de optimización mixto-entero no lineales. En particular, este algoritmo debe permitir optimizar modelos con restricciones y variables binarias, así como también tratar problemas multiobjetivo.
3. Optimizar el modelo del ítem 1 empleando el algoritmo de optimización del ítem 2, con el fin de encontrar mejores esquemas de rotación de cultivos y estrategias de manejo de malezas a largo plazo, para sistemas de la región sur-sudoeste de la provincia de Buenos Aires. De esta manera, el usuario de esta herramienta (productor,

²⁴ www.jetbrains.com/pycharm

²⁵ www.bitbucket.org

extensionista, asesor agropecuario), puede obtener información acerca de: (i) el mejor esquema de rotación de cultivos; (ii) la fecha de siembra de los cereales; (iii) su densidad de siembra; (iv) los tratamientos más adecuados para manejar las malezas; (v) la fecha de aplicación de los métodos de control; (vi) el rendimiento de los cultivos; (vii) el margen bruto anual; (viii) el valor actual (*VA*) del horizonte de planeamiento y (ix) el impacto ambiental de la estrategia de producción.

A continuación, se detalla brevemente la estructura de esta tesis:

En el Capítulo 2, se describe el modelo de simulación del sistema cultivo-maleza adoptado. En específico, se presentan los datos necesarios para su ejecución y la descripción detallada de los modelos de los cultivos trigo y cebada, así como el de la maleza *Avena fatua* L. Además, se detallan las adaptaciones y extensiones introducidas al modelo para su empleo como parte del DSS propuesto. En particular, se propone una metodología para determinar las fechas fenológicas del cultivo, lo que evita la necesidad de recurrir a simulaciones externas. También, se incorpora un indicador económico adicional para evaluar la rentabilidad de la actividad y se amplía el número de términos en el cálculo de costos. Adicionalmente, se calculan dos nuevos índices que determinan el impacto ambiental ocasionado por las distintas estrategias de control. A continuación, se presentan cinco casos de estudio para determinar y comparar las consecuencias económicas y ambientales de diferentes estrategias aplicadas al sistema cultivo-maleza. Por último, se realiza un análisis de escenarios sobre tres parámetros inciertos muy importantes, como lo son la cantidad de semillas de maleza cosechadas, el banco de semillas inicial y la tasa de descuento aplicada.

En el Capítulo 3, se desarrolla el concepto de optimización Mixto Entera No Lineal Multiobjetivo (MINLP-MO), explicando su formulación y complejidad. A su vez, se describe la clasificación de los algoritmos de optimización en determinísticos y metaheurísticos, para luego desarrollar uno de ellos en particular, el algoritmo de optimización continua por enjambre de partículas (PSO). Se presenta la formulación matemática de este optimizador junto con la descripción de sus elementos y su parametrización. Posteriormente, se detalla el tratamiento de restricciones propuesto, así como también la técnica de manejo de variables binarias y la metodología elegida para optimizar múltiples objetivos. Finalmente,

se presenta la implementación propia del algoritmo PSO MINLP-MO y su testeo con diferentes funciones *benchmark*.

En el Capítulo 4, se describen las variables continuas y binarias optimizadas por el PSO cuando es aplicado sobre el modelo agronómico estudiado en el Capítulo 2, así como también se detallan los valores de los parámetros utilizados por el mismo. A continuación, se formulan y presentan los resultados de cuatro casos de estudio, que difieren entre sí por las funciones objetivo a optimizar y/o por la parametrización específica del modelo de simulación. Se analizan los resultados con énfasis en los aspectos agronómicos, económicos y medioambientales.

Por último, en el Capítulo 5 se presentan las conclusiones de la tesis y se plantea el trabajo a futuro según la experiencia obtenida durante el desarrollo de la misma.

CAPÍTULO 2

SIMULACIÓN DEL SISTEMA CULTIVO-MALEZA

En este capítulo se presentará primeramente el modelo de simulación del MIM de Molinari y col. (2020) que fue tomado como base en este trabajo. Luego se explicarán las tres contribuciones principales de esta tesis a dicho modelo de simulación; específicamente en la determinación de las fechas fenológicas del cultivo y en los módulos económico y ambiental. El primer aporte consiste en adoptar una forma de relacionar las distintas fechas claves del desarrollo del cultivo a la fecha de siembra del mismo, evitando así recurrir a cálculos externos. En el segundo caso se tuvieron en cuenta más términos en el cálculo del margen bruto y, además, se propone la evaluación de otro indicador económico: el valor actual (VA). Por otro lado, se incorporó el cálculo de dos nuevos índices para estimar el impacto ambiental, uno de herbicidas (P) y otro de labranzas (T). Finalmente, se simulan cinco casos de estudio para ilustrar las prestaciones de la herramienta.

2.1. Introducción

El modelo matemático de simulación del MIM propuesto por Molinari y col. (2020) permite simular:

- La dinámica poblacional de la maleza teniendo en cuenta las estrategias de control seleccionadas para cada año.
- El nivel de competencia cultivo-maleza.
- El rendimiento esperado del cultivo según la competencia con la maleza y la estrategia de manejo utilizada.
- Distintos indicadores económicos y ambientales.

A partir de un horizonte de simulación indicado por el usuario, el modelo predice la dinámica diaria de las principales variables asociadas a la maleza y al cultivo a lo largo de cada ciclo agronómico anual. Dicho modelo emplea información biológica y agronómica de las malezas y de los cultivos simulados, registros o pronóstico de temperaturas medias y precipitaciones diarias y datos relacionados con la aplicación de medidas de manejo químicas, mecánicas y culturales especificadas por el usuario.

El modelo original, propuesto por Molinari y col. (2020), fue desarrollado en un libro de Excel con macros en Visual Basic para potenciar las prestaciones de la planilla de cálculos. En este trabajo, dicho modelo fue traducido al lenguaje de programación Python para acelerar su ejecución, poder extender sus prestaciones e integrarlo con otras herramientas en los capítulos subsiguientes. Igualmente se preservó Excel como mecanismo para ingreso de datos y escritura de resultados dado que constituye una plataforma intuitiva y sencilla para la mayoría de los usuarios.

Si bien el modelo es de propósito general, adaptable en principio a cualquier maleza anual, en competencia con todo tipo de cultivos en rotación, fue diseñado sobre sistemas agrícolas de la región semiárida templada argentina, específicamente a partir de abundante información obtenida de sistemas extensivos del sudoeste de la provincia de Buenos Aires. En particular se trabajará sobre un plan de rotación basado en trigo (*Triticum aestivum* L.) y cebada (*Hordeum vulgare* L.) en competencia con la maleza anual AVEFA (*Avena fatua* L.), como se mencionó en el capítulo anterior.

En este capítulo se presentarán únicamente los elementos básicos del modelo de Molinari y col. (2020). Dado que se trata de un modelo relativamente extenso, la versión detallada, junto con la nomenclatura y datos correspondientes puede consultarse en los Anexos I y II.

2.2. Ingreso de datos

El modelo de simulación posee una estructura de cálculo muy general que puede ser utilizada para cualquier tipo de cultivo y maleza de ciclo anual, incorporando los datos

propios de cada uno. El ingreso de los mismos se realiza en una hoja Excel, una plataforma familiar para la mayoría de los usuarios, que brinda una interfaz sencilla para la especificación de la información. Luego, dicha hoja es leída por Python para comenzar la simulación.

En la Fig. 2.1 se muestra un resumen de todos los datos que es necesario especificar para poder utilizar los modelos de simulación que se detallarán en las siguientes secciones. La definición de cada variable y parámetro se presenta en forma detallada en el Anexo I. En la Tabla AI.1 se especifican los parámetros del cultivo, en la Tabla AI.2 los de la maleza y en la Tabla AI.3 los de los métodos de control.

Los parámetros definidos anteriormente se consideran datos constantes debido a que representan un determinado cultivo, una cierta maleza y los posibles métodos de control específicos que podrían aplicarse para ese sistema.

Particularmente, los cereales adoptados en esta tesis son trigo y cebada cervecera, típicos de las rotaciones del sudoeste bonaerense, cuyos parámetros se proporcionan en la Tabla AI.4. Como se describió detalladamente en el capítulo introductorio, debido a su interés en la zona bajo estudio, se eligió AVEFA (Tabla AI.5) como maleza problemática. Los métodos de control que se tienen en cuenta en esta tesis son los típicamente empleados para el sistema descrito y los parámetros correspondientes se detallan en la Tabla AI.6. Todos los datos del cultivo, maleza y su control fueron tomados de Molinari y col. (2020).

Una vez definidos los cultivos y la maleza a simular, es necesario proporcionar otras especificaciones que varían de acuerdo al caso de estudio que se desea analizar. Para ello, es necesario que el usuario ingrese, a través de una hoja Excel, la información necesaria para simular cada caso en particular (Tabla AI.7).

La tabla con los datos propios de la simulación se presentará en detalle en la sección de casos de estudio, de acuerdo a las distintas estrategias de manejo que se analizarán.



Fig. 2.1: Ingreso de datos

2.3. Modelo de simulación del cultivo

En la Fig. 2.2 se puede observar un resumen de la secuencia de cálculo diario del modelo de simulación de cultivos con las ecuaciones más importantes detalladas en el Anexo II.

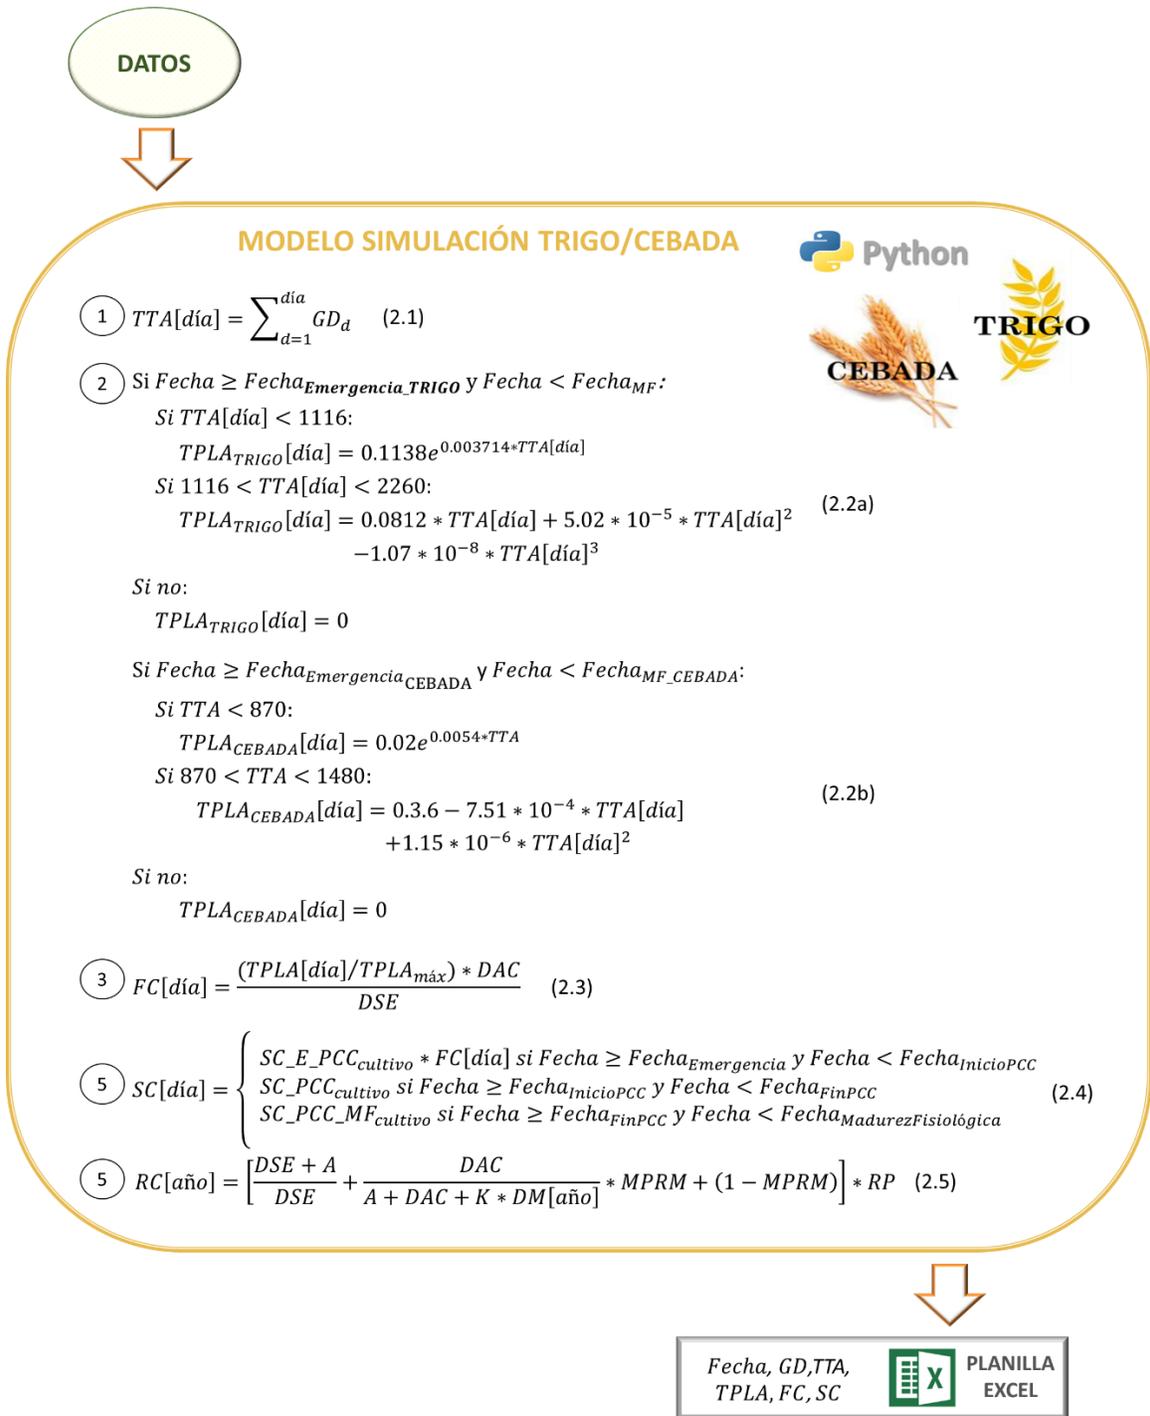


Fig. 2.2: Modelo de simulación de cultivos

En primer lugar, se calculan los grados día (*GD*) a partir de los datos suministrados por el usuario a través del pronóstico o registro meteorológico y, a continuación, se determina el

tiempo térmico acumulado (*TTA*). Este factor se utiliza para definir el área foliar total de la planta (*TPLA* por sus siglas en inglés). Luego, se determina el factor de competencia (*FC*); éste establece el grado en que el cultivo permite el avance o crecimiento de la maleza en competencia. Posteriormente, se calcula la susceptibilidad del cultivo a la competencia con la maleza (*SC*) que, junto con el *TPLA*, establece la conexión entre este modelo y el de simulación de la maleza. Por último, al finalizar la temporada agronómica se estima el rendimiento del cultivo (*RC*).

Una vez completada la simulación, se extrae en una hoja Excel el valor diario de los parámetros del cultivo que se consideraron más relevantes: los grados día (*GD*), el tiempo térmico acumulado (*TTA*), el área foliar total de la planta (*TPLA*), el factor de competencia diaria del cultivo sobre la maleza (*FC*), la susceptibilidad del cultivo a la competencia interespecífica (*SC*) y el rendimiento esperado del cultivo (*RC*).

2.4. Modelo de simulación de la maleza

En líneas generales, el modelo de crecimiento para una maleza anual (AVEFA) sigue el esquema presentado en la Fig. 2.3. En la misma se tienen en cuenta tres etapas básicas para su desarrollo: 1) Banco de semillas del suelo, 2) Dinámica poblacional en términos de sus principales estados fenológicos: i) Plántula, ii) Vegetativo Temprano, iii) Vegetativo Avanzado, iv) Reproductivo Inicial, v) Reproductivo Avanzado. 3) Producción de semillas.

En primer lugar, se establece el banco inicial de semillas quiescentes (sin dormición) (*BS*). Éste indica el conjunto de semillas presentes en el suelo que emergerán en el año de simulación. Se trata de un parámetro difícil de conocer y requiere de metodologías muy específicas para su determinación. Asimismo, es necesario establecer la proporción de semillas que podrían germinar si las condiciones ambientales son adecuadas, las cuales son las que efectivamente emergerán cada año.

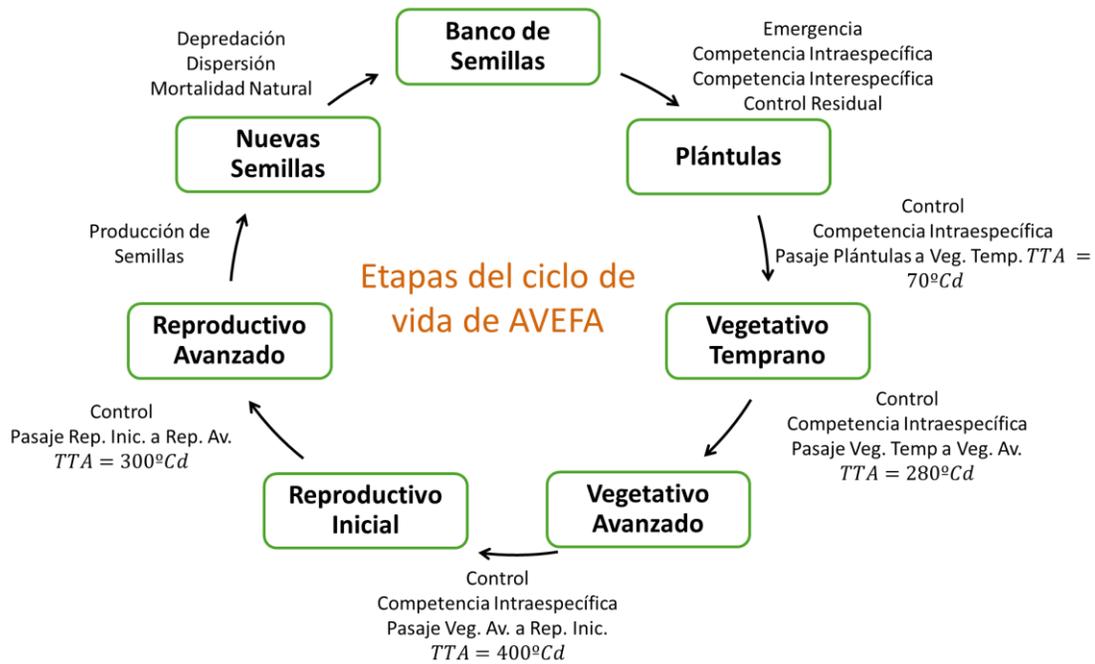


Fig. 2.3: Etapas del ciclo de vida de AVEFA

Para estimar la emergencia de *Avena fatua* a campo, se utiliza el modelo propuesto por Chantre y col. (2018). El mismo, basándose en variables ambientales (temperatura máxima y mínima y precipitaciones en base diaria), permite establecer la tasa de emergencia diaria de la maleza.

Luego, es necesario definir en qué estado se encuentra la maleza según el tiempo térmico acumulado (TTA). En esta simulación se consideran cinco estados fenológicos (EF):

- i. *Plántula (P)*: es la fase inicial de la maleza comprendida entre la emergencia de las hojas primordiales (cotiledón) y la aparición de la primera hoja verdadera. Sobre este estado influye mayormente la competencia interespecífica ($Comp_{interespec}$), que representa el efecto competitivo del cultivo sobre la maleza.
- ii. *Vegetativo Temprano (VT)*: es la segunda fase de la maleza, se identifica por la aparición de dos a cuatro hojas verdaderas. Para la AVEFA este estado se alcanza cuando se logra una acumulación de grados día igual a $70^{\circ}Cd$ a partir del estado anterior.

- iii. *Vegetativo Avanzado (VA)*: se caracteriza por la aparición de nuevos tallos (macollos) sobre la base del tallo principal, aumentado su capacidad competitiva intra (con otras plantas de la propia maleza) e interespecífica (con plantas de otra especie). En AVEFA, su aparición se debe a la superación de una acumulación de grados días igual a 280°Cd a partir del estado anterior.
- iv. *Reproductivo Inicial (RI)*: período de floración que se encuentra entre la aparición de la panoja (flores agrupadas en un mismo tallo) y el estado de madurez fisiológica antes de la dispersión natural de las semillas. Su capacidad competitiva intra e interespecíficas también es importante. En la maleza AVEFA, esta fase se inicia cuando la acumulación de grados días es igual a 400°Cd a partir del estado anterior.
- v. *Reproductivo Avanzado (RA)*: período de dispersión posterior al llenado del grano. La capacidad competitiva en este estado es poco significativa en comparación con los dos estados previos porque los individuos comienzan a envejecer (proceso de senescencia). Este estado surge cuando la acumulación de grados días es igual a 300°Cd a partir del estado anterior en AVEFA.

Sin embargo, el ingreso de la maleza a cada estado fenológico no sólo depende de alcanzar cierto *TTA*, sino también de la magnitud de la competencia intraespecífica ($Comp_{intraesp}$). Ésta tiene en cuenta la presión competitiva que ejerce cada individuo sobre los demás de la misma especie. La cantidad máxima de individuos que pueden coexistir en un determinado momento en el agroecosistema está restringida por la denominada capacidad ambiental máxima ($CA_{m\acute{a}x}$) o capacidad de porte.

Asimismo, para establecer la cantidad de maleza presente cada día en el sistema, es necesario tener en cuenta la posible aplicación de una acción de control (*Control*) que elimine, con cierta eficiencia, los individuos que podrían ingresar a un cierto estado fenológico ($Ingreso_{individuos}$), así como también los acumulados ($Acum_{individuos}$) en cada estado.

Teniendo en cuenta todos estos procesos, es posible calcular la densidad de maleza que influye en la pérdida de rendimiento del cultivo (*DM*), la cual se obtiene como la suma ponderada de las densidades presentes en los distintos estados fenológicos. Por último, se

estima la cantidad de semillas que se producirán al final del ciclo ($Prod_{sem}$), de acuerdo a la cantidad de individuos que alcancen el estado reproductivo avanzado. Dichas semillas se sumarán al banco de semillas preexistente y se comenzará el ciclo nuevamente.

La Fig. 2.4 muestra, de manera esquemática, el procedimiento general para la simulación del crecimiento de AVEFA comentado. Las ecuaciones correspondientes de este modelo se detallan en el Anexo II.

Cuando termina la simulación, al igual que en el modelo de cultivos, se extrae en una hoja Excel el valor diario de las variables que describen el desarrollo de la maleza: los grados día (GD), el banco de semillas de cada año (BS), la producción de semillas ($Prod_{sem}$), la emergencia diaria ($Emergencia$), la competencia intra-específica de cada estado fenológico ($Compet_{intraesp}$), el factor de competencia diaria del cultivo sobre la maleza (FC), la competencia interespecífica de cada estado fenológico ($Compet_{interesp}$), el ingreso de individuos a cada estado fenológico EF ($Ingreso_{individuos}$), la cantidad acumulada de individuos en cada estado fenológico EF ($Acum_{individuos}$), el pasaje de un estado fenológico de la maleza al siguiente ($Pasaje[EF \rightarrow EF + 1]$), la efectividad del método de control sobre cada EF ($Control$) y la competencia ponderada de la maleza ($Compet_{ponderada}$).

Con el objeto de ilustrar los resultados típicos del modelo propuesto se presenta una simulación correspondiente al sistema Trigo - AVEFA para el año 2014, que incluye dos aplicaciones de herbicida antes de la siembra del cultivo (presiembr) y una posterior a su emergencia (postemergencia). Los resultados se muestran en la Fig. 2.5. En lo que respecta a la maleza se pueden observar la cantidad de individuos en los distintos estados fenológicos (RI : Reproductivo Inicial, VA : Vegetativo Avanzado, VT : Vegetativo Temprano, P : Plántula). Para representar la dinámica del cultivo, se grafica el factor de competencia (FC). Este factor indica el grado en que el cultivo permite el establecimiento y desarrollo fenológico de la maleza (si FC es igual a cero, no existe competencia, mientras que si FC vale uno, la competencia ejercida es máxima). Se indica con líneas punteadas las aplicaciones de herbicidas presiembr (G: glifosato) y postemergente (D: diclofop-metil) y con flecha sólida el momento de la siembra del cultivo (T: Trigo).

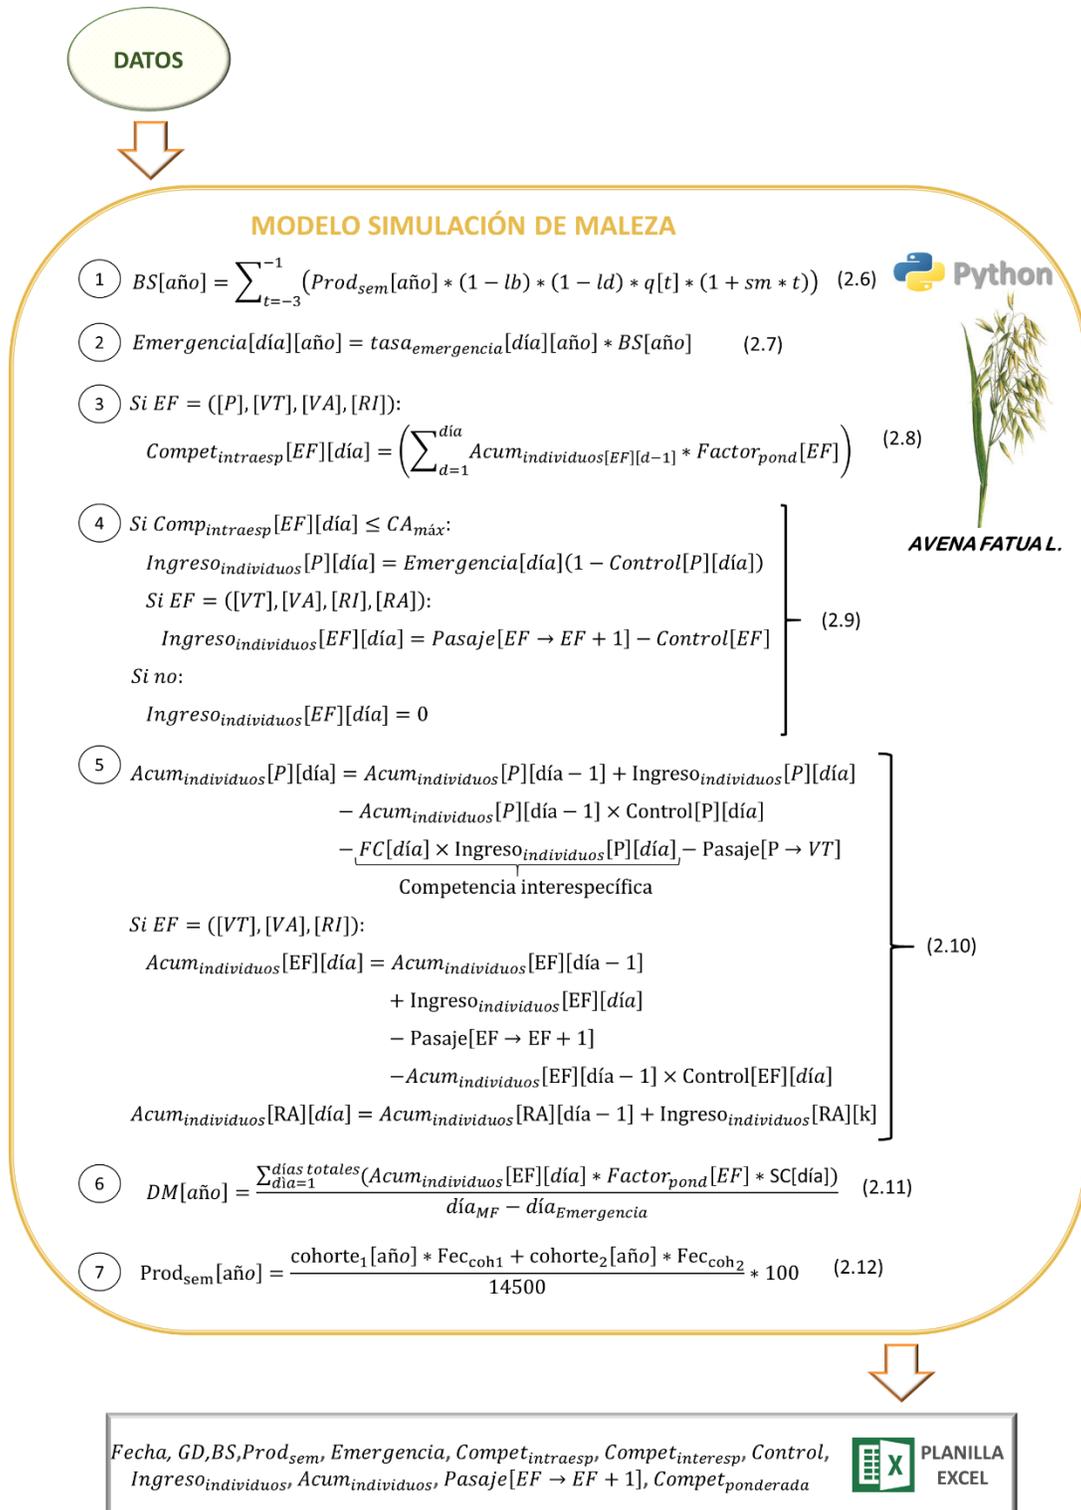


Fig. 2.4: Modelo de simulación de AVEFA

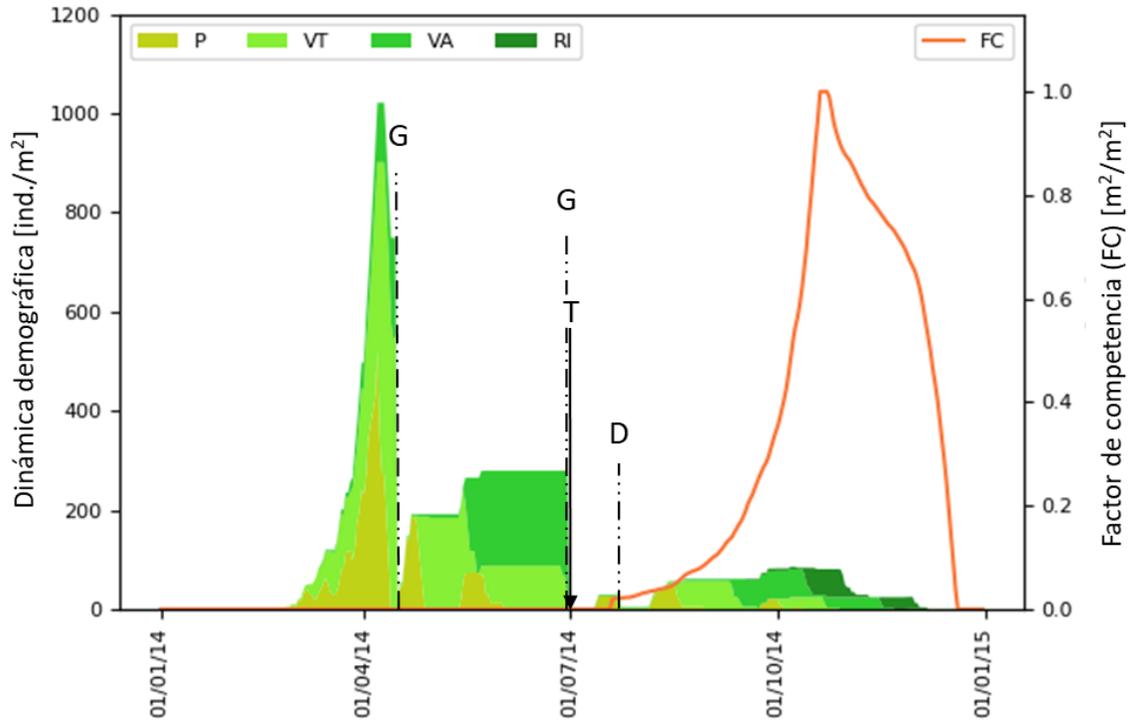


Fig. 2.5: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*)

2.5. Determinación de las fechas fenológicas del cultivo

El modelo de simulación agronómico propuesto por Molinari y col. (2020) requiere como datos de entrada las fechas de siembra, emergencia, inicio y fin del período crítico del cultivo (PCC) y madurez fisiológica de los cultivos. En ese trabajo dichas fechas se obtienen directamente del software CronoTrigo¹ y CronoCebada² mediante ejecuciones adicionales externas de estos programas para la temporada específica bajo estudio.

Los modelos de la serie CRONOS son softwares sencillos basados en modelos termofotoperiódicos. Permiten predecir la ocurrencia de distintos eventos fenológicos en los cultivos de trigo y cebada para una amplia variedad de cultivares comerciales disponibles en el mercado argentino. Simplemente ingresando la localidad de siembra, el cultivar que

¹ <http://cronos.agro.uba.ar/index.php/cronos/cronotrigo>

² <http://cronos.agro.uba.ar/index.php/cronos/cronocebada>

se desea sembrar y la fecha de siembra del cultivo, es posible estimar las fechas importantes para el desarrollo del cultivo, las cuales constituyen parte de la información necesaria para comenzar la simulación.

Sin embargo, no es posible establecer una conexión directa entre este software y el modelo de simulación agronómico propuesto. Dado que en este trabajo se pretende crear un modelo independiente, que no requiera buscar datos externamente al momento de iniciar la simulación, se buscó la forma de relacionar automáticamente todas estas fechas. Una manera práctica de hacerlo es a través del tiempo térmico acumulado (TTA) que proporciona CRONOS. Éste informa los TTA que serán necesarios alcanzar para determinar la fecha de emergencia ($Fecha(TTA_{Eme})$), madurez fisiológica ($Fecha(TTA_{MF})$) y floración ($Fecha(TTA_{Flo})$) del cultivo (Fig. 2.6).

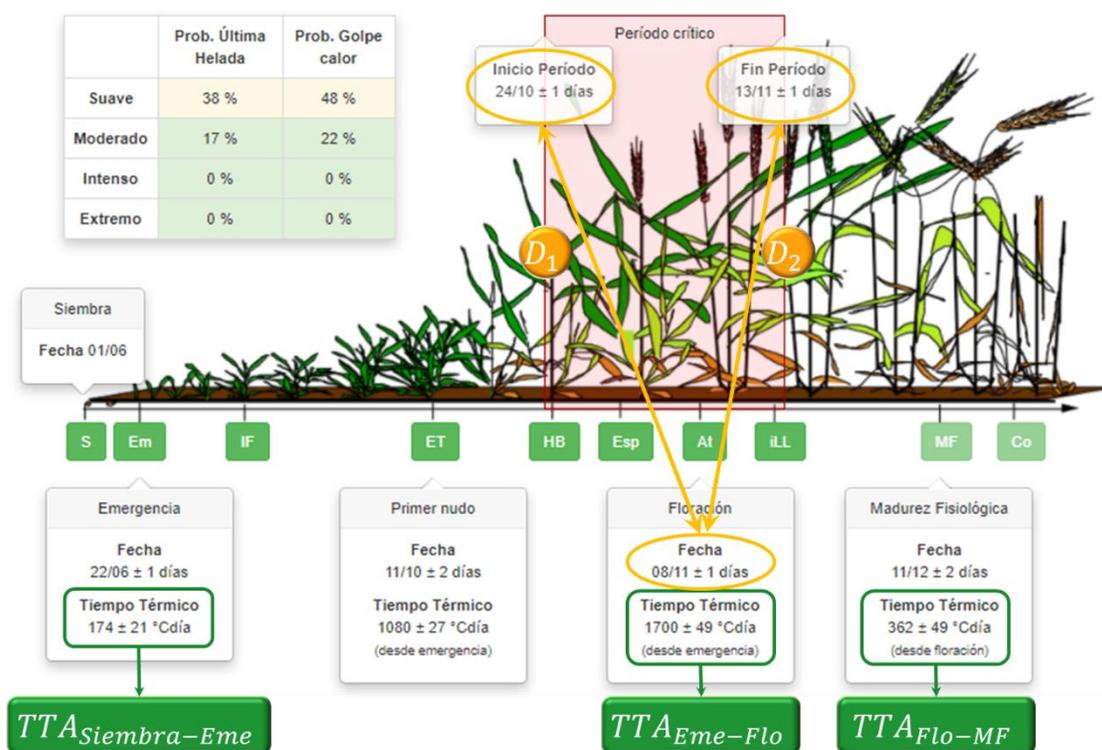


Fig. 2.6: Salida del software CRONOS³

³ <http://cronos.agro.uba.ar/index.php/cronos/cronotriglo> o
<http://cronos.agro.uba.ar/index.php/cronos/cronocebada>
 Mail de contacto: cronotri@agro.uba.ar

A partir de estos datos de CRONOS, se puede obtener la fecha de emergencia directamente según la Ec. 2.13, donde $Fecha(TTA_{Siembra-Eme})$ es la fecha en la que se logra una acumulación de tiempo térmico mayor a $TTA_{Siembra-Eme}$ desde la fecha de siembra.

$$Fecha_{Emergencia} = Fecha(TTA_{Siembra-Eme}) \quad (2.13)$$

Asimismo, se encontró que la fecha de inicio ($Fecha_{InicioPCC}$) y fin de PCC ($Fecha_{FinPCC}$), Ecs. 2.14 y 2.15 respectivamente, se puede basar en la fecha en donde el TTA es mayor a la suma del TTA desde la siembra hasta la emergencia ($TTA_{Siembra-Eme}$) y el TTA desde la emergencia hasta la floración ($TTA_{Eme-Flo}$) más/menos una cierta cantidad de días (D_1 y D_2) que dependen de la fecha de siembra. El parámetro D_1 se determina como los días transcurridos entre la fecha de inicio de PCC y la de floración dado por el software CRONOS en función de la fecha de siembra, mientras que D_2 se establece como los días entre la fecha de floración y la de fin de PCC (Fig. 2.6).

$$\left. \begin{aligned} Fecha_{InicioPCC} &= Fecha_{InicioPCC}(TTA_{Siembra-Eme} + TTA_{Eme-Flo}) - D_1 \text{ días} \\ Fecha_{InicioPCC} &= Fecha_{InicioPCC}(TTA_{Siembra-Floración}) - D_1 \text{ días} \end{aligned} \right| \quad (2.14)$$

$$\left. \begin{aligned} Fecha_{FinPCC} &= Fecha_{FinPCC}(TTA_{Siembra-Eme} + TTA_{Eme-Flo}) + D_2 \text{ días} \\ Fecha_{FinPCC} &= Fecha_{FinPCC}(TTA_{Siembra-Floración}) + D_2 \text{ días} \end{aligned} \right| \quad (2.15)$$

Sin embargo, tanto los TTA reportados por CRONOS como los números de días D_1 y D_2 varían con la fecha de siembra y la variedad del cultivo seleccionada. Teniendo en cuenta el criterio de los investigadores/extensionistas del INTA Bordenave, se propuso un cierto rango de siembra en base a las variedades del cultivo más utilizadas en la zona. Ingresando al software CRONOS la localidad "Bordenave" (que representa la zona bajo estudio), la

fecha de siembra (igual al límite inferior de cada rango dado en la primera columna de las próximas tablas) y la variedad correspondiente, este software brinda los TTA junto con los días D_1 y D_2 correspondientes a los datos establecidos. La relación entre la fecha de siembra y estos parámetros, necesarios para determinar las fechas de crecimiento del cultivo requeridas por el modelo agronómico, se exponen en la Tabla 2.1 para trigo y en la Tabla 2.2 para cebada.

Por su parte, la fecha de madurez fisiológica ($Fecha_{MF}$) se calcula, según la Ec. 2.16, como la fecha en que se alcanza un TTA superior a la suma del tiempo térmico acumulado desde la siembra hasta la emergencia ($TTA_{Siembra-Eme}$), el TTA desde la emergencia hasta la floración ($TTA_{Eme-Flo}$) y el TTA desde floración hasta la madurez fisiológica (TTA_{Flo-MF}).

$$\begin{aligned} Fecha_{MF} &= Fecha(TTA_{Siembra-Eme} + TTA_{Eme-Flo} + TTA_{Flo-MF}) \\ Fecha_{MF} &= Fecha(TTA_{Siembra-MF}) \end{aligned} \quad (2.16)$$

Tabla 2.1: Formas de determinar las distintas fechas del ciclo de trigo según TTA

Fecha de Siembra	Variedad	TTA	TTA	D_1 (días)	D_2 (días)	TTA
		Siembra a Emergencia (°Cd)	Siembra a Floración (°Cd)			Siembra a MF (°Cd)
01/06-14/06	BIOINTA 3005	174	1874	15	5	2836
15/06-30/06	ACA 320	176	1728	15	5	2148
01/07-14/07	ACA 602	141	1458	15	5	1806
15/07-31/07	BIOINTA 1006	169	1326	15	5	1888

Tabla 2.2: Formas de determinar las distintas fechas del ciclo de cebada según *TTA*

Fecha de Siembra	Variedad	<i>TTA</i>	<i>TTA</i>	D_1 (días)	D_2 (días)	<i>TTA</i>
		Siembra a Emergencia (°Cd)	Siembra a Floración (°Cd)			Siembra a MF (°Cd)
11/06-24/06	TRAVELER	137	1358	20	5	1734
25/06-10/07	JENNIFER	134	1318	20	5	1757
11/07-24/07	ALICIANA	160	1306	15	5	1702
25/07-31/07	ANDREIA	162	1277	15	5	1658

2.6. Módulo económico

Empleando como base los modelos de simulación explicados, se implementó un módulo para evaluar el desempeño económico resultante de las distintas estrategias de manejo adoptadas para el control de malezas y la siembra de los cultivos. En el modelo de Molinari y col. (2020) se realiza el balance económico de la actividad a través del margen bruto. Un aporte de este capítulo reside en ampliar los términos considerados en el cálculo del mismo. Asimismo, con el objeto de analizar el sistema en un horizonte de varios años, se incluyó el cálculo de otro indicador económico importante: el valor actual (*VA*). Ambas contribuciones se explicarán en detalle a continuación.

2.6.1. Margen Bruto (*MB*)

Constituye una herramienta muy directa para evaluar los procesos de decisión en general y, en particular, estimar cómo incide el empleo de diferentes estrategias de MIM en los resultados económicos de la actividad agronómica. Los márgenes brutos directos (*MB*)

exponen comparativamente la diferencia existente entre el valor bruto de la producción, también llamado ingreso bruto y el costo directo asociado a dicha actividad. En esta tesis el MB se calcula anualmente según Ec. 2.17.

$$MB[año] = Ingreso_{Bruto}[año] - Costos_{Directos}[año] \quad (2.17)$$

donde $MB[año]$ es el margen bruto directo anual; $Ingreso_{Bruto}[año]$ es el ingreso bruto anual de la actividad; $Costos_{Directos}[año]$ son los costos directos anuales de la actividad.

A continuación, se describirá cada componente:

Ingreso Bruto

Se entiende como ingreso bruto a la cifra en dinero que resulta de multiplicar el rendimiento del cereal por el precio bruto (Ec. 2.18). En otras palabras, esta variable representa el beneficio que se obtiene por la venta de los granos del cultivo.

$$Ingreso_{Bruto}[año] = RC[año] * Precio_{venta_{CULTIVO}} \quad (2.18)$$

donde $Ingreso_{Bruto}[año]$ es el ingreso bruto anual de la actividad [USD/ha]; $RC[año]$ es el rendimiento anual del cultivo [t/ha] y $Precio_{venta_{CULTIVO}}$ es el precio de venta del cultivo [USD/t].

Costos directos

Dado que el margen bruto se utilizará para estimar el beneficio o pérdida resultante de aplicar las diferentes estrategias de MIM y poder compararlas entre sí, en su cálculo sólo se consideró la influencia de los costos directos ($Costos_{Directos}$), es decir, los gastos directos ocasionados por la actividad (Ec. 2.19). Por simplicidad, los gastos indirectos (costos de agua, alquiler y/o depreciación de maquinaria, etc.) no se tuvieron en cuenta porque dependen de diversos factores y se requiere gran cantidad de información adicional para poder especificarlos, aunque se podrían incluir en el cálculo sin mayor dificultad.

$$\begin{aligned} Costos_{Directos}[año] = & Gastos_{Cosec.yComer.}[año] + Gastos_{Siembra}[año] \\ & + Gastos_{Control}[año] + Gastos_{Limp.Granos}[año] \end{aligned} \quad (2.19)$$

• *Gastos por cosecha y comercialización del cultivo* ($Gastos_{Cosec.yComer.}$): estos gastos dependen a su vez de varios parámetros, como por ejemplo la maquinaria a utilizar en la cosecha, el rinde del cultivo, la superficie a cosechar y la cadena de comercialización, entre otros. Debido a que existen numerosas alternativas de cosecha y comercialización, cuya desagregación escapan a los alcances generales de esta tesis, se los calcula simplemente como un porcentaje de los ingresos por venta del cultivo (Ec. 2.20). Este porcentaje varía de acuerdo al tipo de cultivo cosechado.

$$\begin{aligned} Gastos_{Cosec.yComer.}[año] = & Porcentaje_{Gastos_{cc}} * Rendimiento_{CULTIVO}[año] \\ & * Precio_{venta_{CULTIVO}} \end{aligned} \quad (2.20)$$

donde $Gastos_{Cosec.yComer.}[año]$ son los gastos anuales por cosecha y comercialización del cultivo [USD/ha]; $Porcentaje_{Gastos_{cc}}$ es el porcentaje de ingresos que corresponde a los gastos de cosecha y comercialización según el tipo de cultivo cosechado [%]; $Rendimiento_{CULTIVO}[año]$ es el rendimiento anual del cultivo [t/ha] y $Precio_{venta_{CULTIVO}}$ es el precio de venta del cultivo [USD/t].

• *Gastos por siembra del cultivo ($Gastos_{Siembra}$):* Se consideró que los gastos de siembra de los cultivos solo dependen del tipo de cultivo y de su densidad de siembra. Para simplificar, a través de una regresión lineal, se estableció que los gastos de siembra se determinen según las Ecs. 2.21a y 2.21b.

$$Gastos_{Siembra_{CEBADA}}[año] = 0.10 * DAC_c + 258 \quad (2.21a)$$

$$Gastos_{Siembra_{TRIGO}}[año] = 0.15 * DAC_T + 258 \quad (2.21b)$$

donde $Gastos_{Siembra}[año]$ son los gastos anuales de siembra del cultivo [USD/ha] y DAC es la densidad actual de siembra del cultivo [$plantas/m^2$].

• *Gastos por control de la maleza ($Gastos_{Control}$):* se determinan anualmente como la suma de todos los gastos originados por la compra de insumos y la aplicación de cada control de malezas, químico o mecánico, seleccionado en cada año de simulación (Ec. 2.22). Los mismos se determinan de acuerdo al precio del tipo de control elegido y a la cantidad de aplicaciones necesarias por hectárea, sumándole a este valor un costo fijo correspondientes a la aplicación del método de control (el cual es independiente del control escogido).

$$Gastos_{Control}[año] = \sum_{CM=1}^{Control_{totales}} (Precio_{CM} * Aplic_{CM}[año] + Costo_{aplic}) \quad (2.22)$$

donde $Gastos_{Control}[año]$ son los gastos anuales por la compra de insumos y aplicación de las acciones de control [USD/ha]; $Precio_{CM}$ es el precio de los insumos correspondientes a cada aplicación del método de control de malezas [USD/L o kg]; $Aplic_{CM}[año]$ es la dosis de herbicida requerida para cada aplicación en el año (o el combustible de la herramienta de labranza en caso de control mecánico) [L o kg/ha]; $Costo_{aplic}$ es el costo fijo por la aplicación del herbicida seleccionado [USD/ha] (cabe destacar que este costo para el caso de labranza es nulo).

• *Gastos por limpieza de granos cosechados* ($Gastos_{Limp.Granos}$): La inclusión de este término constituye uno de los agregados principales al modelo de simulación cultivo-maleza adoptado. Se determina como la suma de un término fijo y de otro variable. El costo fijo (Ec. 2.23) corresponde al servicio de clasificación y limpieza de los granos que depende solamente de la cantidad de granos del cultivo y de semillas de maleza recolectados en la cosecha.

$$Gastos_{Limp.Granos_{Fijo}}[año] = Costo_{Limpieza} * (RC[año] + Prod_{Sem}[año] * \%Sem_{Cosec} * \%Sem_{zar}) \quad (2.23)$$

donde $Gastos_{Limp.Granos}[año]$ son los gastos anuales de limpieza de semillas fijos [USD/ha]; $Costo_{Limpieza}$ es el costo fijo de limpieza [USD/t]; $RC[año]$ es el rendimiento anual del cultivo [t/ha]; $Prod_{Sem}[año]$ es la producción anual de semillas de maleza [t/ha]; $\%Sem_{Cosec}$ es el porcentaje del total de semillas de la maleza que es levantado junto con el cereal al momento de la cosecha [%]; $\%Sem_{zar}$ es el porcentaje de semillas de malezas que continúa con los granos del cultivo después del zarandeo que realiza la propia cosechadora [%].

Según las normas de calidad de la bolsa de comercio, los granos cosechados deben cumplir con ciertas especificaciones, dentro de las cuales se encuentra la cantidad máxima de materia extraña permitida, categoría dentro de la que se encuentran las semillas de AVEFA. Si esto no

donde $\%Sem[año]$ es la cantidad anual de semillas de la maleza que se recolectan junto con los granos en la cosecha [%] (considerada como pérdida de semillas por dispersión); $Gastos_{Limp.Granos_{Var.}}[año]$ son los gastos anuales de limpieza de semillas variables [USD/ha]; $Precio_{venta_{Cultivo}}$ es el precio de venta del cultivo [USD/t] y $Costo_{zar}$ es el costo por zarandear la muestra de semillas y grano luego de la cosecha [USD/t].

2.6.2. Valor Actual (VA)

Dado que la simulación propuesta pretende analizar un horizonte de varios años aplicando diferentes estrategias de MIM, es necesario incorporar un método para poder evaluar la viabilidad económico financiera de las diferentes alternativas que se presentan y compararlas entre sí en función del margen bruto asociado a cada una de ellas. La decisión pasará por aceptar o rechazar cierta estrategia, o bien, aceptar la más conveniente en caso de existir más de una. Si bien existen muchos métodos estadísticos y dinámicos para ello, uno de los más comúnmente utilizados es el valor actual (VA) o Valor Presente (Gaspars-Wieloch, 2019).

El VA tiene en cuenta el valor temporal del dinero al considerar que aquello que se gastará (o ganará) en unos años tendrá un valor diferente en el presente. La metodología consiste en descontar al momento actual, es decir, actualizar mediante una tasa de interés determinada, todos los flujos de dinero futuros. En otras palabras, se trata de determinar la equivalencia en el tiempo cero de los flujos de efectivo futuros que genera un proyecto. Cabe aclarar que, en esta tesis, el término “proyecto” hace referencia a las distintas estrategias de MIM que se podrían implementar.

El VA (Ec. 2.26) depende de las siguientes variables:

- *Flujos netos de efectivo (F_t):* representan la diferencia entre los ingresos y gastos que podrán obtenerse por la ejecución de un proyecto durante su vida útil.

- *Tasa de descuento (r)*: también conocida como costo o tasa de oportunidad. Es la tasa de retorno requerida sobre una inversión. Refleja la oportunidad perdida de gastar o invertir en el presente.
- Número de períodos que dure el proyecto (n).

$$VA = \sum_{t=1}^n \frac{F_t}{(1+r)^t} = \frac{F_1}{(1+r)} + \frac{F_2}{(1+r)^2} + \dots + \frac{F_n}{(1+r)^n} \quad (2.26)$$

donde F_t son los flujos de dinero en cada periodo t ; n es el número de períodos de tiempo y r es la tasa de descuento.

De acuerdo al modelo planteado en esta tesis, el margen bruto anual descrito en la sección anterior equivale al flujo neto de efectivo. Bajo estas consideraciones la Ec. 2.26 se transforma en la Ec. 2.27, siendo esta última la forma particular de calcular el VA que se aplicará en este trabajo.

$$VA = \sum_{t=0}^n \frac{MB_t}{(1+r)^t} \quad (2.27)$$

donde MB_t es el margen bruto esperado en el año t [USD/ha]; r es la tasa de descuento y n la cantidad total de años.

Entonces, el VA permite estimar el equivalente en unidades monetarias actuales de todos los ingresos y egresos, presentes y futuros que despliega el proyecto durante toda su vida útil, constituyendo una medida de la rentabilidad de un proyecto en términos absolutos netos. Evaluando su signo y magnitud es posible establecer rápidamente la conveniencia económica de realizar cierto proyecto, siendo una herramienta de análisis fundamental en la toma de decisiones. Los criterios de decisión se basan en las siguientes reglas:

- $VA > 0$: Establece que el valor actualizado de los cobros y pagos futuros de la inversión a la tasa de descuento elegida generará beneficios, por lo cual el proyecto podría ejecutarse. Para el caso de proyectos mutuamente excluyentes, donde se debe optar por uno u otro, debe elegirse el que presente el mayor valor actual.
- $VA = 0$: Este resultado no significa que el proyecto no genere beneficios, sino que éstos apenas alcanzan a cubrir las expectativas.
- $VA < 0$: Esta situación implica que los beneficios son inexistentes, o bien, que no son suficientes. Esto indicaría que el proyecto no debería realizarse.

De esta manera, el valor actual sirve para guiar dos tipos de decisiones: establecer si el proyecto es rentable y evaluar qué proyecto, o estrategia de manejo de malezas en nuestro caso, es mejor que otro en términos absolutos.

2.7. Módulo de impacto ambiental

Dado que en la actualidad se ha profundizado la preocupación por los efectos negativos de los métodos para el control de malezas, uno de los principales análisis de la sustentabilidad de la producción agropecuaria, además del económico, es la evaluación de los efectos del uso de agroquímicos en los consumidores de alimentos, en las poblaciones rurales y sobre el agroecosistema. Incluso los métodos de control mecánicos como la labranza, también poseen impactos ambientales negativos que es preciso considerar en un esquema MIM.

Por estas razones, en los últimos años comenzaron a utilizarse numerosas herramientas de evaluación del impacto ambiental ocasionado por los distintos métodos de control de malezas. Dichos índices permiten cuantificar y comparar el riesgo asociado a la implementación de las diferentes medidas de manejo, siendo útiles para ayudar a definir estrategias de largo plazo.

Particularmente, en esta tesis, se consideraron dos criterios de evaluación populares para estimar el riesgo ecotoxicológico. Siguiendo la propuesta de Molinari y col. (2020) se

mantuvo el empleo del índice EIQ . Adicionalmente, se incorporó la metodología de los índices P y T a fin de expandir las funcionalidades del modelo.

2.7.1. Coeficiente de Impacto Ambiental (EIQ)

Una de las metodologías más conocidas para cuantificar el impacto ambiental químico en la actividad agrícola es el EIQ (Kovach y col., 1992). Cada herbicida suele estar compuesto por varios ingredientes activos (ia), que le confieren las propiedades necesarias para poder eliminar las malezas con cierta eficiencia.

Cada ia tiene asociado un cierto coeficiente de impacto ambiental (EIQ_{ia}). Este índice se encuentra estandarizado para diferentes ingredientes activos usados comercialmente en diversos contextos ambientales según Ec. 2.28. Al calcular el impacto ambiental total de cada ia , este indicador tiene en cuenta el efecto de aplicar un herbicida sobre el riesgo toxicológico que podría sufrir el aplicador, el consumidor y los componentes del ecosistema. Todos estos valores se encuentran disponibles en documentos del Colegio de Agricultura y Ciencias de la Vida⁶ (Universidad de Cornell, USA).

$$EIQ_{ia} = \frac{Efecto_{Aplicador} * Efecto_{Consumidor} * Efecto_{Ecológico}}{3} \quad (2.28)$$

donde EIQ_{ia} es el coeficiente de impacto ambiental estandarizado o teórico por ingrediente activo; $Efecto_{Aplicador}$ es el riesgo toxicológico que enfrenta el trabajador agrícola al utilizar un herbicida; $Efecto_{Consumidor}$ es el riesgo toxicológico percibido por el consumidor y las aguas subterráneas (que podrían generar un problema de salud humana)

⁶ <https://nysipm.cornell.edu/eiq/list-pesticide-active-ingredient-eiq-values/>

por el empleo de un herbicida y $Efecto_{Ecológico}$ es el riesgo toxicológico sobre mamíferos, sistema acuático, aves, peces, abejas e insectos benéficos por aplicar un herbicida.

A partir del EIQ_{ia} teórico se calcula el EIQ real del herbicida aplicado por hectárea. Éste se establece en base al EIQ_{ia} , la concentración del ingrediente activo y la cantidad aplicada a campo para cada ingrediente activo presente en el herbicida. De esta manera, es posible comparar el impacto de diferentes agroquímicos, mediante la Ec. 2.29:

$$EIQ[\text{año}] = \sum ia (\%) * Dosis_{CM}[\text{año}] * EIQ_{ia} \quad (2.29)$$

donde $EIQ[\text{año}]$ es el coeficiente de impacto ambiental anual producido por una aplicación de determinado herbicida (EIQ real); ia [%] es la concentración del ingrediente activo del herbicida (dato obtenido de la etiqueta del producto); $Dosis_{CM}[\text{año}]$ es la cantidad de herbicida que se aplica por hectárea [L o kg/ha] (dato obtenido de la etiqueta del producto) y EIQ_{ia} es el coeficiente de impacto ambiental de cada ia del herbicida.

El EIQ por aplicación de cada uno de todos los herbicidas que se consideran en este trabajo, se determina con los valores de la Tabla 2.3:

Tabla 2.3: Valores de EIQ de los herbicidas utilizados en la simulación

	$Dosis_{CM}(L/ha)$	ia	EIQ_{ia}	$EIQ(\text{Ec. 2.29})$
Glifosato	2.00	0.48	15.30	14.69
Pinoxaden	0.80	0.06	15.30	0.73
Diclofop-metil	2.00	0.28	26.00	14.77

2.7.2. Índice de Riesgo

Si bien el *EIQ* es uno de los indicadores de impacto más populares empleados en estudios agronómicos, en los últimos años su validez ha sido cuestionada (Kniss y Coburn, 2015).

Una de las críticas a este método es que, al combinarse una gran cantidad de datos cuantitativos en un solo valor cualitativo, se pierde información valiosa. Además, se le objeta su precisión, ya que depende fuertemente de supuestos subyacentes y de la combinación matemática de datos. Asimismo, se han señalado problemas en el escalado y la ponderación de la información cuantitativa del riesgo, ya que se ha notado que ciertos riesgos que difieren en órdenes de magnitud pueden recibir la misma calificación cualitativa (Kniss y Coburn, 2015).

Adicionalmente, *EIQ* está diseñado únicamente para cuantificar el impacto de los agroquímicos y no refleja las consecuencias producidas por otras acciones de control de malezas de suma importancia en el MIM, en particular, las labranzas del suelo.

Para ampliar la capacidad de estimación del impacto ambiental del modelo de Molinari y col. (2020) y teniendo en cuenta las críticas mencionadas, en este trabajo se decidió incorporar también los índices de labranza y de herbicidas propuestos por Ferraro y col. (2003).

Cada uno de estos índices se determinan de manera individual, de acuerdo a funciones matemáticas de lógica difusa que denotan el grado de ocurrencia de los eventos, independientemente del momento en que podrían ocurrir. Dichos indicadores varían entre cero y uno (si el valor se acerca a cero el riesgo asumido es inaceptable, mientras que si se aproxima a uno se lo considera aceptable). El cálculo del índice *P* depende principalmente de la toxicidad y de la dosis empleada, indistintamente del tipo de formulación, la forma de aplicación o clasificación química del herbicida. Por su parte, el índice *T* proporciona información sobre el riesgo de erosión del suelo en función de sus características y de la herramienta de labranza empleada. A continuación, se describe brevemente el procedimiento para establecer cada índice en particular.

Índice de herbicidas (P)

A cada ingrediente activo presente en los diferentes herbicidas se les asocia cierto grado de toxicidad en mamíferos e insectos que se puede representar a través de la dosis letal media aguda (DL50). Ésta hace referencia a la cantidad de sustancia necesaria, en ingestión única, que provoca la muerte del 50% del total de individuos que la ingieren. Cuanto menor sea la cantidad de principio activo requerida para alcanzarla, mayor será la toxicidad del mismo.

El cálculo del índice de herbicidas se basa principalmente en la toxicidad y la dosis empleada por hectárea, más allá del tipo de formulación, la forma de incorporarlos o su clasificación química. De esta manera, por cada herbicida utilizado, es necesario especificar: (i) dosis aplicada de ingrediente activo [mg de *ia*/ha] (*D*), dosis letal oral media aguda en ratas [mg de *ia*/1000 g rata] (*LD*_{50r}) y (iii) dosis letal oral media aguda en abejas [mg de *ia*/abeja] (*LD*_{50a}).

A partir de estos datos, propios de cada ingrediente activo, es posible estimar la magnitud de la toxicidad en mamíferos (*T*_{mam}) e insectos (*T*_{ins}) para cada herbicida (Ecs. 2.30 y 2.31 respectivamente), medidas en unidades tóxicas [tu]:

$$T_{mam} = \frac{D}{LD_{50r}} \quad (2.30)$$

$$T_{ins} = \frac{D}{LD_{50a}} \quad (2.31)$$

donde *T*_{mam} es la toxicidad en mamíferos [tu]; *T*_{ins} es la toxicidad en insectos [tu]; *D* es la dosis aplicada [mg de *ia*/ha]; *LD*_{50r} es la dosis letal oral media aguda en ratas [mg de *ia*/1000 g rata]; *LD*_{50a} es la dosis letal oral media aguda en abejas [mg de *ia*/abeja].

Dado que en un lote pueden aplicarse varios tipos de herbicidas a lo largo de una temporada y, a su vez, cada uno de ellos puede tener más de un ingrediente activo, es necesario

determinar la toxicidad total sobre mamíferos e insectos. Dicho valor se puede obtener con la suma de la toxicidad generada por cada ingrediente activo, ya que se los considera agentes tóxicos independientes entre sí (Ec. 2.32 y Ec. 2.33). Se asume que no hay efectos sinérgicos ni antagónicos.

$$Sum(T_{mam}) = \sum_{ia=1}^{iat} T_{mam_{ia}} \quad (2.32)$$

$$Sum(T_{ins}) = \sum_{ia=1}^{iat} T_{ins_{ia}} \quad (2.33)$$

donde $Sum(T_{mam})$ y $Sum(T_{ins})$ son las sumatorias de las toxicidades en mamíferos y en insectos respectivamente (medidas en unidades tóxicas tu); iat es la cantidad total de ingredientes activos presentes en todos los herbicidas aplicados por hectárea en un año; $T_{mam_{ia}}$ y $T_{ins_{ia}}$ es la toxicidad en mamíferos y en insectos respectivamente por cada ingrediente activo (medidas en unidades tóxicas tu).

Posteriormente, con estos datos, se calcula el índice de toxicidad en mamíferos (Ec. 2.34) y el correspondiente al de los insectos (Ec. 2.35).

$$M = 1 + \left(\frac{1}{Mín(Sum(T_{mam})) - Máx(Sum(T_{mam}))} \right) \times (Sum(T_{mam}) - Mín(Sum(T_{mam}))) \quad (2.34)$$

$$I = 1 + \left(\frac{1}{Mín(Sum(T_{ins})) - Máx(Sum(T_{ins}))} \right) \times (Sum(T_{ins}) - Mín(Sum(T_{ins}))) \quad (2.35)$$

donde M e I son los índices de toxicidad en mamíferos y en insectos respectivamente; $Mín(Sum(T_{mam}))$ y $Mín(Sum(T_{ins}))$ son los valores mínimos que podrían tomar las sumatorias de las toxicidades en mamíferos (0 tu) y en insectos (0 tu) respectivamente; $Máx(Sum(T_{mam}))$ y $Máx(Sum(T_{ins}))$ son los valores máximos que podrían tomar las sumatorias de las toxicidades en mamíferos (6 tu, según Ferraro y col., 2003) y en insectos (1900 tu, según Ferraro y col., 2003), respectivamente; $Sum(T_{mam})$ y $Sum(T_{ins})$ son las sumatorias de toxicidad en mamíferos y en insectos respectivamente.

Finalmente, para determinar el impacto total anual de los herbicidas en una hectárea, ambos índices se integran a través de una regla típica de la lógica difusa, que permite establecer el índice de herbicidas (P) según la Ec. 2.36:

$$P = k_1Mín(I, M) + k_2Mín(I, 1 - M) + k_3Mín(1 - I, M) + k_4Mín(1 - I, 1 - M) \quad (2.36)$$

Siendo $k_1 = 1$, $k_2 = 0,1$, $k_3 = 0,1$ y $k_4 = 0$ (según Ferraro y col., 2003)

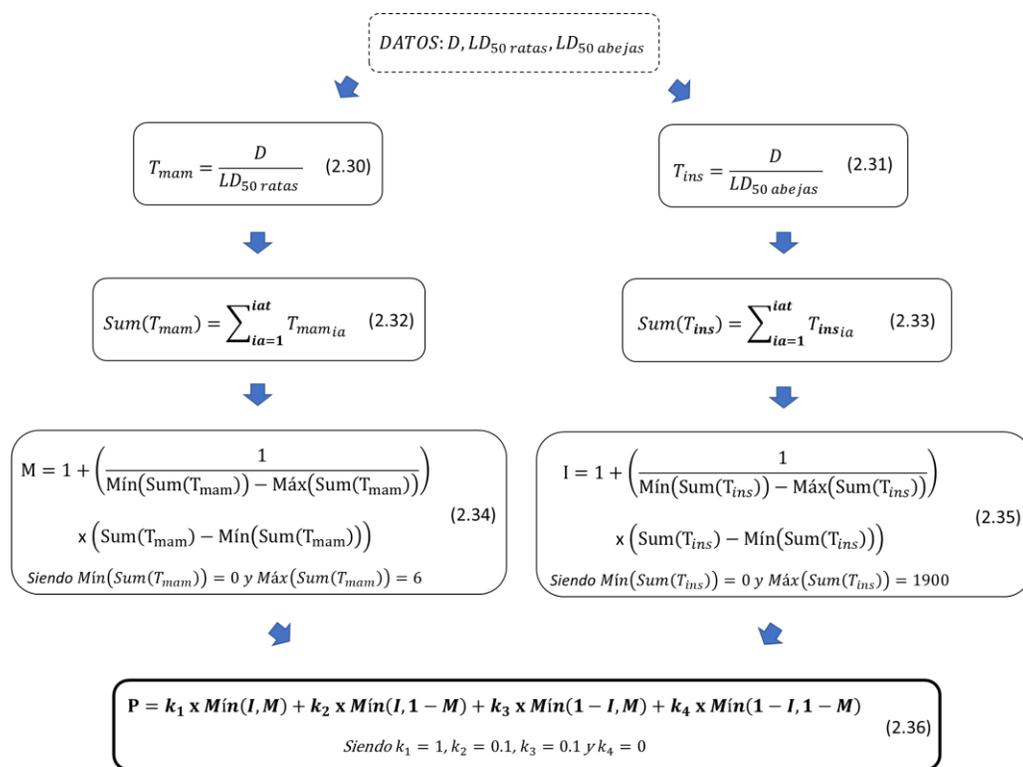
donde P es el índice de herbicidas; I y M son los índices de toxicidad en insectos y en mamíferos, respectivamente.

Para ilustrar el empleo de esta metodología, en la Tabla 2.4, se calcula el índice P para dos posibles combinaciones de herbicidas típicas consideradas en este trabajo. Las mismas consisten en dos aplicaciones de un herbicida no selectivo (glifosato) seguido por un herbicida postemergente (pinoxaden o diclofop-metil).

Un resumen del procedimiento de cálculo para determinar el Índice de Herbicidas (P) puede observarse en la Fig. 2.7.

Tabla 2.4: Cálculo del índice de herbicidas para dos estrategias de control químico

	<i>D</i> [g/ha]	<i>LD</i> _{50r} [mg/kg rata]	<i>LD</i> _{50a} [mg/abeja]	<i>T</i> _{mam} [tu]	<i>T</i> _{ins} [tu]	<i>Sum</i> (<i>T</i> _{mam})	<i>Sum</i> (<i>T</i> _{ins})	<i>M</i>	<i>I</i>	<i>P</i>
2 aplicaciones de glifosato (G) y 1 aplicación de pinoxaden (P)										
G1	2000	2000	200	1,00	10,00					
G2	2000	2000	200	1,00	10,00	2,27	28,00	0,62	0,99	0,64
P	800	3000	100	0,27	8,00					
2 aplicaciones de glifosato (G) y 1 aplicación de diclofop-metil (D)										
G1	2000	2000	200	1,00	10,00					
G2	2000	2000	200	1,00	10,00	5,91	35,27	0,02	0,98	0,11
D	2000	512	131	3,90	15,27					

**Fig. 2.7:** Cálculo del índice para herbicidas (*P*)

Índice de labranza (T)

Según Ferraro y col. (2003), el impacto que puede producir la labranza en el suelo se determina a partir de dos variables importantes: el tipo de herramienta de labranza que se va a utilizar y la clase de capacidad que tiene el suelo para el cultivo.

Las herramientas que pueden emplearse para la labranza son variadas. Dentro de las más usadas se encuentran el arado de disco y la rastra de disco. Los efectos del uso de cada una de estas herramientas se evalúan en dos de las propiedades del suelo que se considera que resultan más perjudicadas por la actividad: la cantidad de rastrojo restante luego de la labranza (*STU*) y la estabilidad de los agregados del suelo (*STA*), es decir, de la estabilidad de las partículas individuales de arena, limo y arcilla cuando se agrupan o unen entre sí. Valores bajos de *STU* indican que la cantidad de biomasa remanente en el rastrojo es mínima, mientras que valores pequeños de *STA* representan estabilidades bajas de los agregados al suelo. Estos factores se determinan en función del tipo de herramienta de labranza (Tabla 2.5) y miden la capacidad que posee cada una de ellas para provocar condiciones que podrían favorecer la erosión hídrica y eólica.

Tabla 2.5: Valores de *STU* y *STA* de las herramientas de labranza más utilizadas

Herramienta de labranza	<i>STU</i>	<i>STA</i>
Arado de disco	0,10	0,20
Rastra de discos	0,30	0,20

Con estos dos factores de impacto parcial, se calcula un peso promedio para establecer el impacto de cada herramienta de labranza (T_{imp}) según la Ec. 2.37 y el impacto total de todas las labranzas realizadas en el campo por año ($Sum(T_{imp})$) como indica la Ec. 2.38:

$$T_{imp} = 1 - (0.60 STU + 0.40 STA) \quad (2.37)$$

$$Sum(T_{imp})[año] = \sum_{nl=1}^{nlt} T_{imp_{nl}} [año] \quad (2.38)$$

donde T_{imp} es el impacto de cada herramienta de labranza empleada ese año en el suelo; STU es la cantidad de rastrojo restante luego de la labranza; STA es la estabilidad de los agregados del suelo; $Sum(T_{imp})$ es la sumatoria del impacto sobre el suelo de todas las herramientas de labranza utilizadas en el año y nlt representa todas las herramientas de labranza que se usaron por hectárea en un año.

Luego se calcula el índice de impacto de la labranza (TI) que representa el riesgo de erosión del suelo debido a la implementación de esta acción con los diversos tipos de herramientas (Ec. 2.39).

$$TI = 1 + \left(\frac{1}{Mín (Sum(T_{imp})) - Máx (Sum(T_{imp}))} \right) \times (Sum(T_{imp}) - Mín (Sum(T_{imp}))) \quad (2.39)$$

donde TI es el índice de impacto de la labranza; $Mín (Sum(T_{imp}))$ es la mínima sumatoria del impacto de la labranza (para el caso en el que no se aplica ningún tipo de labranza, 0 tu); $Máx (Sum(T_{imp}))$ es el máximo valor de impacto aceptable (se considera igual al valor correspondiente a dos usos de la herramienta de arado de reja y vertedera, 1.84 tu) y $Sum(T_{imp})$ es la sumatoria del impacto en el suelo de todas las herramientas de labranza utilizadas en el año.

Sin embargo, para determinar el índice de labranza (T) no sólo se debe tener en cuenta TI , sino también el valor intrínseco del riesgo de erosión del suelo (TR). Este factor depende

de la clasificación de la capacidad del suelo para cultivar (*LCC*), dato específico de cada campo y cuya relación se puede establecer según la Tabla 2.6.

Tabla 2.6: Relación de *LCC* con *TR*

<i>LCC</i>	Definición	<i>TR</i>
I	No tiene limitaciones significativas para el cultivo.	1,00
II	Adecuada para cultivos, pero tiene limitaciones.	0,50
III	Adecuada para cultivos, pero tiene limitaciones.	0,25
IV	Adecuado para cultivos, pero solo bajo prácticas seleccionadas.	0,10
V-VIII	Las clases V a VII son las más adecuadas para pastos. La clase VIII es apropiada sólo para usos no agrícolas.	0,00

Una vez definidos los índices *TR* y *TI*, se los integra por la regla de inferencia adoptada para estimar el índice de labranza (*T*). Éste representa el daño ocasionado por año en una hectárea al implementar labranzas con diferentes herramientas como método de control de malezas (Ec. 2.40).

$$T = k_1 \text{Mín}(TI, TR) + k_2 \text{Mín}(TI, 1 - TR) + k_3 \text{Mín}(1 - TI, TR) + k_4 \text{Mín}(1 - TI, 1 - TR) \quad (2.40)$$

Siendo $k_1 = 1$, $k_2 = 1$, $k_3 = 0,3$ y $k_4 = 0$ (según Ferraro y col., 2003)

donde *T* es el índice de labranza; *TI* es el índice de impacto de labranza en la erosión del suelo y *TR* es el valor intrínseco del riesgo de erosión en cierto suelo.

La Fig. 2.8 presenta un resumen de la metodología para calcular el índice de labranza (*T*). Por su parte, la Tabla 2.7 muestra el cálculo del índice *T* para el caso de dos labranzas en el

año, frecuencia típicamente adoptada en sistemas tradicionales (una labranza durante el barbecho y otra antes de la siembra del cultivo). Con fines ilustrativos se reportan los valores de dos herramientas de labranza diferentes, arado de disco y rastra de disco, en dos tipos de suelo diferentes.

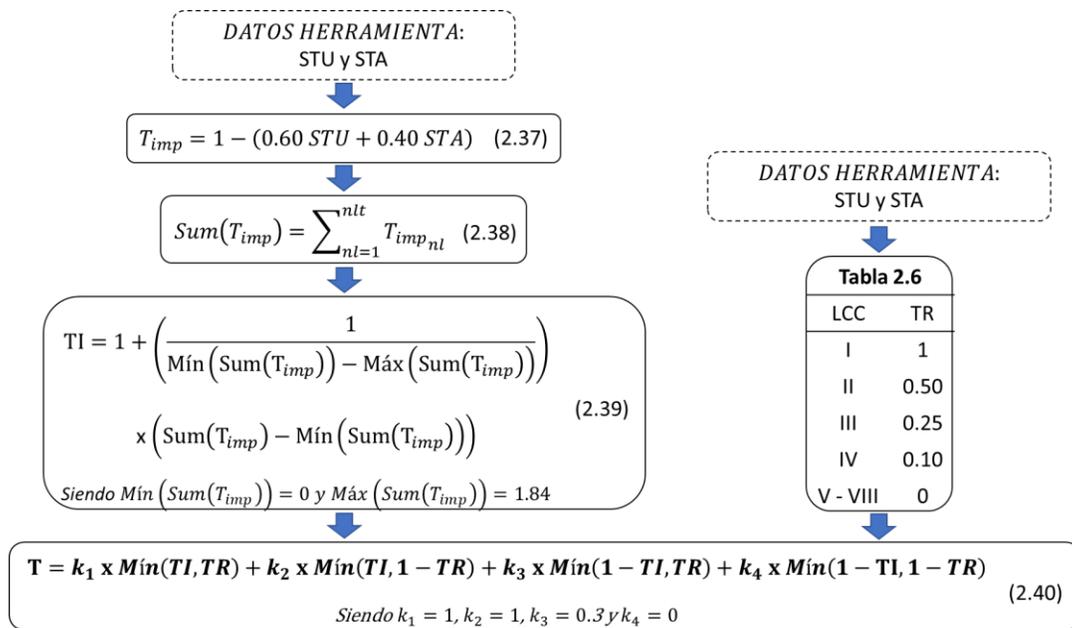


Fig. 2.8: Cálculo del índice de labranza (T)

Tabla 2.7: Cálculo del índice de labranza para dos estrategias de control mecánico

	<i>STU</i>	<i>STA</i>	<i>T_{imp}</i>	<i>Sum(T_{imp})</i>	<i>TI</i>	<i>LCC</i>	<i>TR</i>	<i>T</i>
Tipo de labranza: Arado de disco								
Primera Labranza	0,10	0,20	0,86	1,72	0,07	IV	0,10	0,14
Segunda Labranza	0,10	0,20	0,86					
Tipo de labranza: Rastra de disco								
Primera Labranza	0,30	0,20	0,74	1,48	0,20	I	1,00	0,44
Segunda Labranza	0,30	0,20	0,74					

2.8. Casos de estudio

Con el objetivo de ilustrar las prestaciones del modelo de simulación y analizar los principales indicadores económicos y ambientales descriptos, se diseñaron una serie de casos de estudio representativos de sensibilidad de manejo.

Específicamente, se presentan los resultados de simular una rotación multianual típica del sudoeste bonaerense a base de trigo y cebada cervecera en competencia con AVEFA. Con fines demostrativos, se simulan cinco casos de estudio con distintas estrategias de manejo de la maleza en el periodo 2014-2018. Para esos años, la tasa de emergencia obtenida a partir del modelo de adoptado de Chantre y col. (2018) se presenta en la Fig. 2.9. Los datos meteorológicos diarios para el cálculo de la emergencia y la acumulación de tiempo térmico fueron obtenidos de los registros de la estación meteorológica EEA-INTA Bordenave⁷(Fig. 2.10).

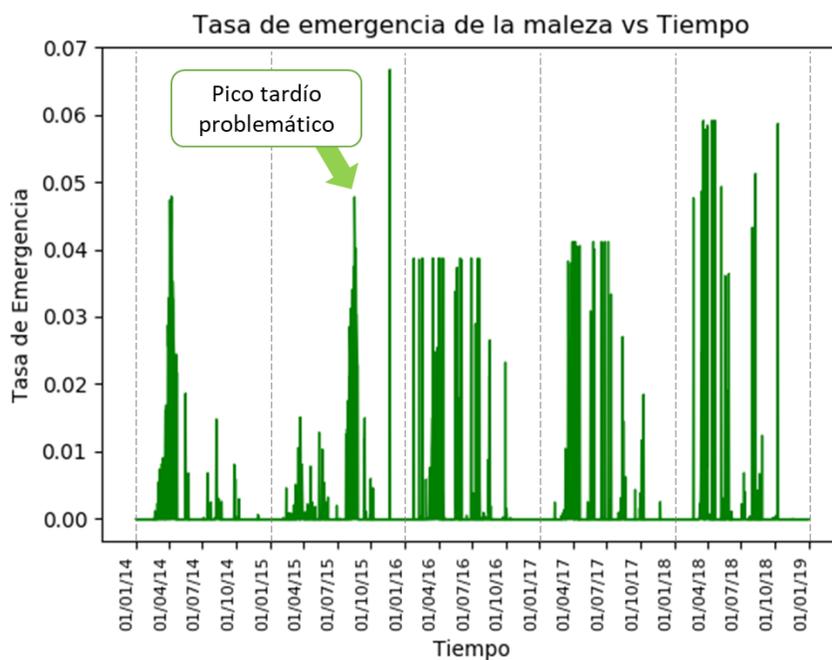


Fig. 2.9: Tasa de emergencia de la maleza AVEFA vs tiempo

⁷ <https://inta.gov.ar/documentos/informacion-agrometeorologica>

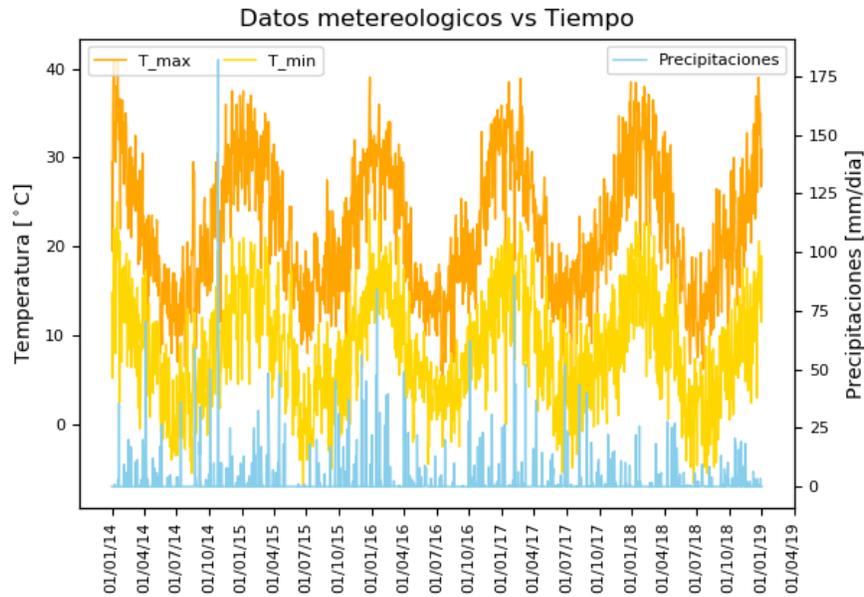


Fig. 2.10: Datos meteorológicos vs tiempo

En cuanto a las estrategias de control, normalmente se intenta eliminar la mayor cantidad posible de maleza durante el barbecho (período comprendido entre la cosecha de un cultivo y la siembra del siguiente cultivo), con el fin de optimizar la disponibilidad de agua y nutrientes en la siembra para permitir un crecimiento inicial vigoroso de los cereales. Comúnmente se suelen hacer dos acciones de control en barbecho, ya sea químicas o mecánicas. Una se realiza unos meses antes de la siembra del cultivo con el objetivo de evitar que las malezas que puedan emerger tempranamente consuman la humedad del suelo, mientras que la otra se lleva a cabo unos pocos días antes de la siembra a fin de eliminar la competencia sobre el crecimiento inicial de los cereales.

Si bien en el modelo de simulación utilizado, no se encuentra representado el efecto de la humedad y los nutrientes del suelo, se contemplan estos controles para tener en cuenta tanto el costo económico como el impacto ambiental que producen.

En la Tabla 2.8 se detallan los parámetros comunes a todos los casos a simular, mientras que los que varían con cada caso se especifican en la Tabla 2.9.

Tabla 2.8: Parámetros de todos los casos a simular

Parámetro	Valor
$r[\%]$	15
$BS[\text{semillas}/\text{m}^2]$	2000
$\%Sem_{Cosec}[\%]$	20
$\%Sem_{zar}[\%]$	5,00
$TPLA_{\text{máx}_{CEBADA}}[\text{ind}/\text{m}^2]$	0,50
$MPRM_{CEBADA}$	0,45
$RP_{CEBADA}[\text{t}/\text{ha}]$	5,00

Tabla 2.9: Parámetros propios para cada caso a simular

CASO	SI	SII	SII	SIV	SV
$DAC_{CEBADA}[\text{ind}/\text{m}^2]$	250	250	270	270	270
$TPLA_{\text{máx}_{TRIGO}}[\text{ind}/\text{m}^2]$	6,0	6,0	1,0	1,0	1,0
$MPRM_{TRIGO}$	0,6	0,6	0,2	0,2	0,2
$DAC_{TRIGO}[\text{ind}/\text{m}^2]$	200	200	300	300	300
$RP_{TRIGO}[\text{t}/\text{ha}]$	4,0	4,0	3,8	3,8	3,8

Cabe destacar que, al ejecutar todos los casos siguientes en el modelo agronómico desarrollado en Python, se logró acelerar su ejecución en un orden de 10x con respecto al programado en Excel-Visual Basic.

2.8.1. CASO SI

Se simula una estrategia de manejo básica, basada solamente en dos aplicaciones de un herbicida no selectivo (glifosato) en barbecho, optimizando así la condición inicial del cultivo. No se realizan intervenciones posteriores, por lo que el rendimiento final del cereal se basa en la capacidad de competencia del cultivo frente a la emergencia de AVEFA a lo largo de la etapa de crecimiento del cultivo. En cuanto a las fechas de siembra, éstas son estándares y se determinaron según las sugerencias de los investigadores/extensionistas del INTA Bordenave. La Tabla AIII.1 detalla los datos utilizados para simular el CASO SI.

El efecto de las medidas de control químico adoptadas en el CASO SI se observan en la Fig. 2.11, donde con línea punteada se indica la fecha de aplicación del herbicida (G) y con flecha sólida la fecha de siembra de Trigo y Cebada (T y C respectivamente).

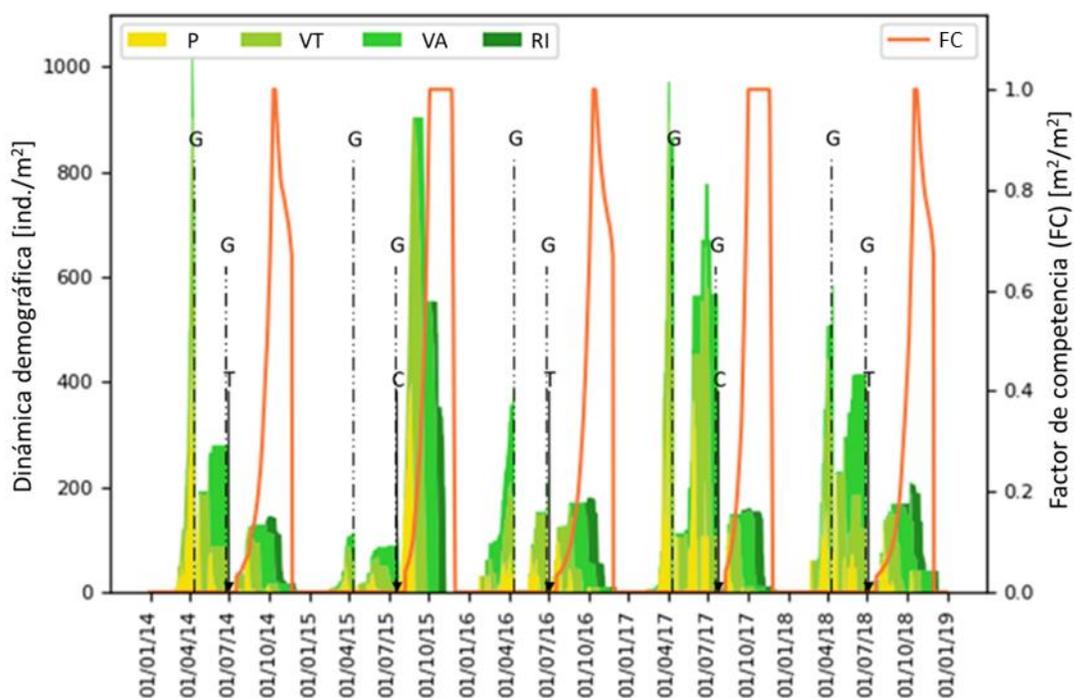


Fig. 2.11: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) en CASO SI

Se puede apreciar cómo la aplicación del glifosato en barbecho y pre-siembra elimina gran parte de la maleza en sus distintos estados fenológicos (99%), lo que se manifiesta como una caída abrupta en la densidad de la maleza luego de la aplicación. La alta eficiencia de control se debe a la efectividad del herbicida y a la elevada susceptibilidad de la maleza en sus estados iniciales de crecimiento. Sin embargo, AVEFA continúa emergiendo luego de la siembra del cereal, alcanzando picos importantes que logran competir con el cultivo.

Los resultados expuestos en la Tabla 2.10 permiten observar que los rendimientos del cultivo superan el 63% de su rendimiento potencial en todos los años (variable RC/RP), aunque esto no es suficiente para alcanzar márgenes brutos positivos, a excepción del año 2017.

Cuando se cultiva cebada (2015 y 2017), el rendimiento se incrementa ya que este cultivo logra competir mejor con la maleza y, al sembrarse más tarde que el trigo, evita algunos picos de emergencia. Sin embargo, esto no se refleja en el valor de RC/RP de 2015 debido a la mayor competencia ejercida por AVEFA. Cabe destacar que la *Avena fatua* posee un amplio período de emergencia con gran variabilidad interanual (Diez de Ulzurrun y col., 2015). Particularmente en 2015, se aprecia una gran cantidad de picos de emergencia tardíos en comparación a otros años, ya que se producen pocos días después de la siembra de cebada en ese año (Fig. 2.9), lo cual explicaría el menor rendimiento del cultivo de ese ciclo.

A su vez, se puede comprobar que la producción de semillas de AVEFA es mayor en los años con trigo que en los de cebada (alcanzando el 54, 93 y 44% de la producción de semillas máxima). Esto ocasiona que el porcentaje de semillas de AVEFA que acompañan al grano del cultivo a cosecha sea mayor al porcentaje máximo permitido por las normas de calidad. Lo anterior contribuye a que existan gastos variables por limpieza de cereal en 2014, 2016 y 2018. En el caso de la cebada, dichos costos son nulos ya que la producción de semillas de la maleza cuando se siembra este cereal no supera el 25% y, por lo tanto, la cantidad de semilla que se cosecha junto con el cultivo es inferior al 0,24%. Este costo extra en los años de trigo (necesario para cumplir con los requisitos de calidad del producto) es el que

contribuye a que el margen bruto en dichos años sea mucho más negativo que en los restantes.

En cuanto al *VA*, su valor negativo indica que el sistema no dará ganancias empleando esta estrategia de manejo.

Tabla 2.10: Resultados del CASO SI

CASO SI	2014	2015	2016	2017	2018
Cultivo	Trigo	Cebada	Trigo	Cebada	Trigo
Ing. Venta Cultivo [USD/ha]	500	492	505	567	469
Gastos Cos. y Com. [USD/ha]	-150	-123	-152	-142	-141
Gastos Siembra [USD/ha]	-288	-283	-288	-283	-288
Gastos Limp. Sem. Fijo [USD/ha]	-58	-70	-59	-81	-55
Gastos Limp. Sem. Variable [USD/ha]	-40	0	-139	0	-24
Gastos Control [USD/ha]	-36	-36	-36	-36	-36
MB [USD/ha]	-72	-20	-169	25	-75
<i>VA</i> [USD/ha]	-212				
RC/RP	0,68	0,65	0,68	0,76	0,63
Índice <i>T</i>	1,00	1,00	1,00	1,00	1,00
Índice <i>P</i>	0,69	0,69	0,69	0,69	0,69
<i>EIQ</i>	29,38	29,38	29,38	29,38	29,38
Producción de semillas [%]	53,63	18,33	93,24	24,56	44,33
%Semillas con el grano [%]	0,71	0,20	1,22	0,24	0,63
Competencia ponderada	70,85	404,93	67,19	149,62	94,18

2.8.2. CASO SII

Similarmente al caso anterior, en este caso también se simula una estrategia de control basada en dos aplicaciones de glifosato al barbecho. Sin embargo, debido a que en el CASO SI se identificó la existencia de una competencia importante de AVEFA luego de la siembra del cultivo, se decidió utilizar también herbicidas postemergentes para mitigar la competencia con el cereal. Específicamente, se incorporó un herbicida selectivo (diclofop-metil: D) en los años de siembra de trigo y un graminicida selectivo (pinoxaden: P) en los de cebada. Las fechas de siembra son iguales que en el caso previo, siguiendo las mismas recomendaciones del INTA Bordenave.

A fin de simular una práctica tendiente a evitar la aparición de resistencia, se estableció que se pueda utilizar solo una vez por año el herbicida selectivo postemergente. Adicionalmente, se definió que la misma se realizaría 20 días después de que se supere un umbral de 10 ind/m² de AVEFA en el estado vegetativo temprano. Esta estrategia de aplicación se definió arbitrariamente buscando optimizar la eficiencia de control e intentando replicar un posible criterio de manejo implementable en la práctica. Los datos ingresados para simular este caso en particular, se detallan en la Tabla AIII.2, mientras que la determinación de las fechas en que se emplean los herbicidas postemergentes se desprenden de analizar la Fig. AIII.1.

En la Fig. 2.12 se observa el resultado de los controles químicos aplicados en el CASO SII sobre los distintos estados fenológicos de la maleza. Es evidente que la incorporación de un herbicida postemergente logró controlar considerablemente la población de AVEFA.

La escala de la figura se seleccionó de manera de poder visualizar claramente la dinámica de la maleza en sus distintos estados fenológicos en los años 2015 a 2018. En el primer año (2014) los valores se van de escala dado que la emergencia y densidad de la AVEFA en ese año es muy elevada debido al importante banco inicial de semillas de malezas adoptado en este estudio.

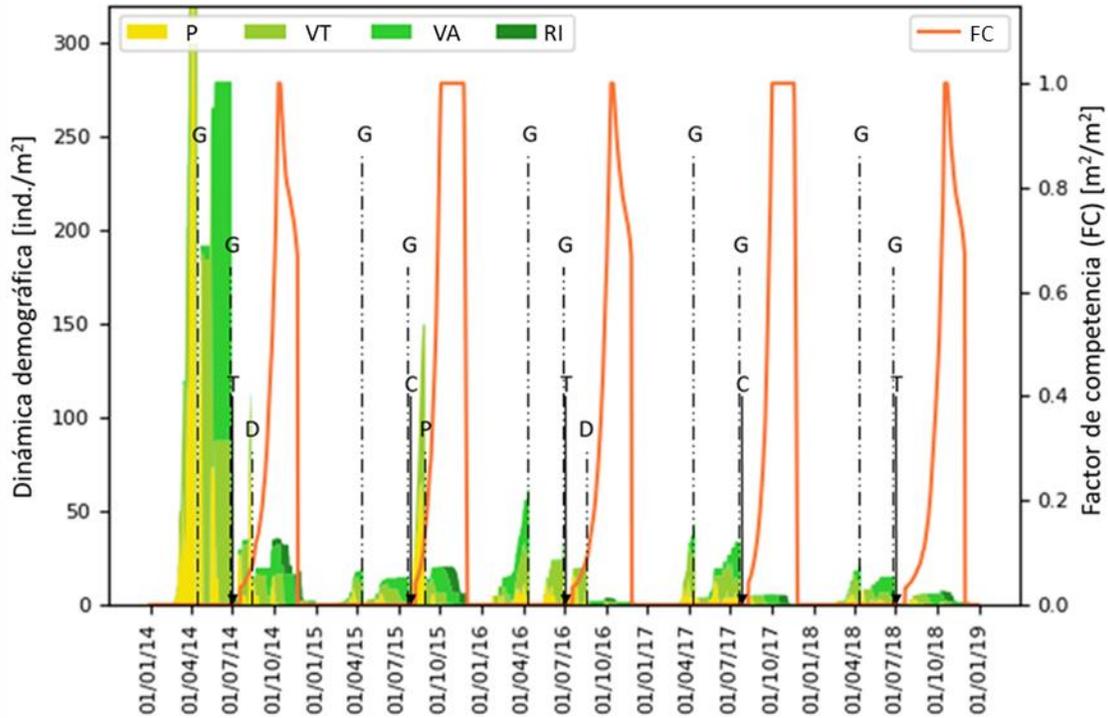


Fig. 2.12: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) en CASO SII

Los rendimientos obtenidos al implementar dichas medidas (Tabla 2.11) superan todos los años el 84% del rendimiento potencial del cultivo (RC/RP). Los mismos son mayores que en el CASO SI, ya que el control postemergente disminuyó considerablemente la cantidad de semillas de maleza a fin de ciclo. La máxima producción de semillas se alcanzó en el año 2014 con un 9%, siendo 10 veces inferior a la máxima obtenida en el caso previo (93% en 2016).

Por otro lado, como era de esperar, el impacto ambiental se incrementa en este caso debido a que se realizaron más aplicaciones de herbicidas que en el CASO SI. El índice *P* empeora un 84% en los dos primeros años de siembra de trigo y un 7% en los de cebada respecto al caso anterior. Esto sucede porque el diclofop-metil produce consecuencias más negativas al medio ambiente que el pinoxaden. Este hecho también se ve reflejado en el *EIQ*, ya que se observa un aumento del 50% del *EIQ* cuando se aplica dicho herbicida. Los años 2017 y

2018 tienen las mismas consecuencias ambientales que en el CASO SI, dado que en ese período no se aplica un herbicida postemergente al no superarse en ningún momento los 10 individuos/m² de AVEFA en estado vegetativo temprano.

Tabla 2.11: Resultados del CASO SII

CASO SII	2014	2015	2016	2017	2018
Cultivo	Trigo	Cebada	Trigo	Cebada	Trigo
Ing. Venta Cultivo [USD/ha]	621	707	730	737	716
Gastos Cos. y Com. [USD/ha]	-186	-177	-219	-184	-214
Gastos Siembra [USD/ha]	-288	-283	-288	-283	-288
Gastos Limp. Sem. Fijo [USD/ha]	-72	-101	-84	-105	-83
Gastos Limp. Sem. Variable [USD/ha]	0	0	0	0	0
Gastos Control [USD/ha]	-98	-80	-98	-36	-36
MB [USD/ha]	-23	66	41	129	95
VA [USD/ha]	178				
RC/RP	0,84	0,94	0,99	0,98	0,97
Índice <i>T</i>	1,00	1,00	1,00	1,00	1,00
Índice <i>P</i>	0,11	0,64	0,11	0,69	0,69
<i>EIQ</i>	44,14	30,11	44,14	29,38	29,38
Producción de semillas [%]	8,87	2,76	1,78	1,05	1,85
%Semillas con el grano [%]	0,10	0,02	0,02	0,01	0,02
Competencia ponderada	21,96	18,51	1,41	5,14	3,38

A pesar de que los gastos en herbicidas (gastos de control) se incrementaron en un 273% en los años 2014 y 2016 y un 221% en el año 2015 con respecto al CASO SI, las medidas de

control efectuadas lograron disminuir el porcentaje de semillas de la maleza a cosecha del cereal evitando erogaciones por costos de limpieza variable en todos los años. De esta manera, los márgenes brutos alcanzados resultan positivos en la mayoría de los años, excepto en 2014. Éste es el único año en que no se obtienen ganancias debido a que el banco inicial de semillas de AVEFA causó un gran impacto que no se pudo mitigar eficientemente con los controles aplicados. Sin embargo, el *VA* resultó positivo, lo que sugiere que esta estrategia de control sería rentable considerando el horizonte de tiempo analizado.

2.8.3. CASO SIII

En este caso se simula una estrategia combinada de acciones de control químico y manejo cultural. En particular, las fechas de siembra de los cereales (Tabla AIII.3) se atrasaron lo más posible a fin de evitar los picos de emergencia de AVEFA. Además, se utilizó un cultivar de trigo altamente competitivo ($TPLA_T = 1$, $MPRM = 0,20$ y $RP_T = 3,80$) a diferencia de los CASOS SI y SII, donde se consideró un cultivar estándar. Como medida adicional de manejo cultural, se incrementó la densidad de siembra en ambos cereales ($DAC_T = 300$ y $DAC_C = 270$), lo que implica un aumento en los gastos de siembra de ambos cultivos (USD/ha 15 para trigo y USD/ha 2 para cebada). La estrategia de manejo químico fue idéntica a la del CASO SI, sólo aplicaciones de glifosato al barbecho.

La Fig. 2.13 permite comprobar que adoptar una estrategia con control químico y cultural, reduce aproximadamente a la mitad (y en algunos años a un tercio) la densidad de AVEFA en los distintos estados fenológicos que compiten con el cultivo (luego de la fecha de siembra), en comparación con el CASO SI.

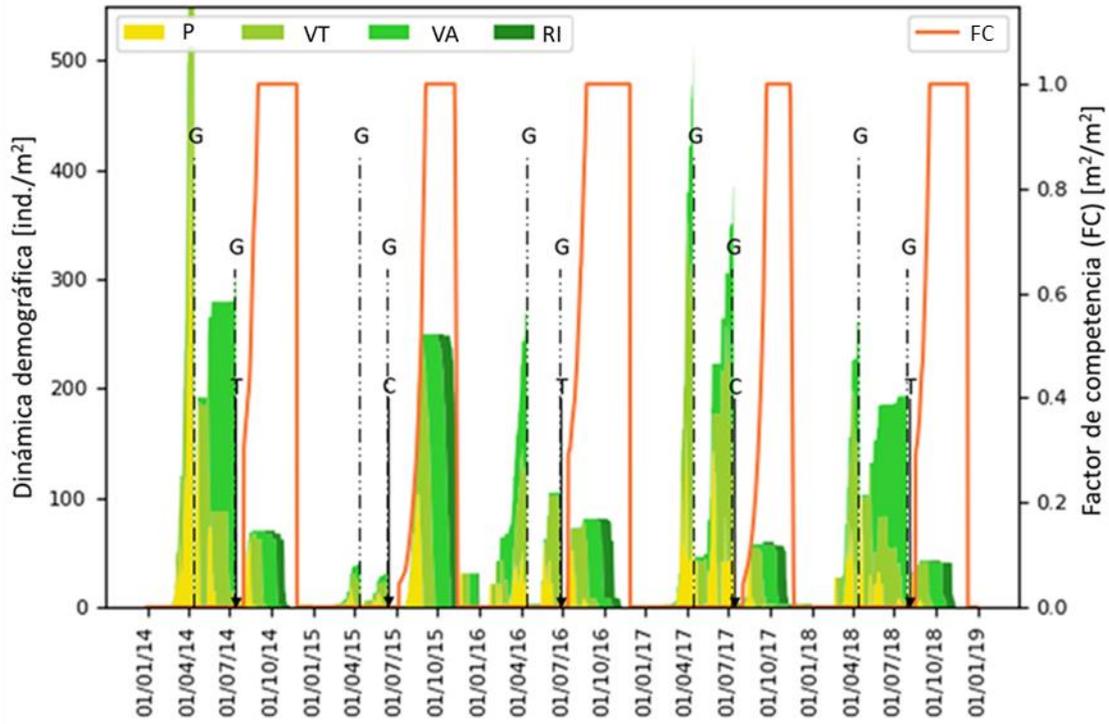


Fig. 2.13: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) en CASO SIII

Comparativamente, el CASO SII, logra un control de malezas más eficiente en todos los años debido a la aplicación de los herbicidas postemergentes. Esto se pone de manifiesto al observar los individuos/m² presentes en cada *EF* luego de la siembra, ya que en la estrategia de control del CASO SIII al menos se duplicaron en comparación con los correspondientes al CASO SII.

En la Tabla 2.12 se detallan los resultados de simular el CASO SIII. Se observa que los rendimientos alcanzados son mayores al 71% del rendimiento potencial del cultivo en todos los años. Es notable el incremento de *RC/RP*, con aumentos que van desde el 40 al 56% con respecto al CASO SI cuando se siembra trigo y del 9 al 16% cuando se trata de cebada. Esta mejora es atribuible a las medidas culturales, especialmente al uso de un cultivar de trigo altamente competitivo.

Tabla 2.12: Resultados del CASO SIII

CASO SIII	2014	2015	2016	2017	2018
Cultivo	Trigo	Cebada	Trigo	Cebada	Trigo
Ing. Venta Cultivo [USD/ha]	667	532	666	656	692
Gastos Cos. y Com. [USD/ha]	-200	-133	-200	-164	-208
Gastos Siembra [USD/ha]	-303	-285	-303	-285	-303
Gastos Limp. Sem. Fijo [USD/ha]	-77	-76	-77	-94	-80
Gastos Limp. Sem. Variable [USD/ha]	0	0	0	0	0
Gastos Control [USD/ha]	-36	-36	-36	-36	-36
MB [USD/ha]	51	2	50	77	65
VA [USD/ha]	155				
RC/RP	0,95	0,71	0,95	0,88	0,98
Índice <i>T</i>	1,00	1,00	1,00	1,00	1,00
Índice <i>P</i>	0,69	0,69	0,69	0,69	0,69
<i>EIQ</i>	29,38	29,38	29,38	29,38	29,38
Producción de semillas [%]	18,80	17,24	34,00	11,85	41,96
%Semillas con el grano [%]	0,19	0,18	0,34	0,10	0,41
Competencia ponderada	40,53	249,06	41,72	52,14	18,00

Los aumentos en los rendimientos con respecto al CASO SI, se traducen en mayores ingresos por la venta del cereal, lo que se refleja en márgenes brutos positivos en todos los años, aunque de menor magnitud que en el CASO SII, a excepción de los años 2014 y 2016. Cabe aclarar que 2015 no produce un alto margen de ganancias por la gran emergencia tardía de AVEFA que tiene lugar esa temporada. Asimismo, el control químico presiembra combinado

con el manejo cultural logró reducir la producción de semillas a un nivel aceptable comercialmente, evitando así los gastos variables por limpieza del cereal.

Como era de esperarse, la implementación de medidas culturales, en reemplazo de los herbicidas postemergentes (CASO SII) redujo el impacto ambiental. Al observar el V_A , se comprueba que es mejor que el CASO SI pero peor que el CASO SII, demostrando que la implementación de medidas culturales combinadas con la aplicación de herbicidas sólo antes de la siembra no alcanza a controlar la maleza con la misma eficiencia que si se utilizan métodos postemergentes.

2.8.4. CASO SIV

En este caso, se simula una estrategia combinada de los CASOS SII y SIII, según los datos de la Tabla AIII.4. Se aplica el mismo criterio de control químico que el simulado en el CASO SII: dos aplicaciones de glifosato en barbecho y una aplicación de diclofop-metil en trigo y pinoxaden en cebada, luego de 20 días de que AVEFA supere los 10 ind/m² en el estado vegetativo temprano (Fig. AIII.2). Asimismo, a estas acciones se le adiciona el manejo cultural descrito en el CASO SIII: tomando las mismas fechas de siembra de los cultivos, empleando un cultivar de trigo altamente competitivo ($TPLA_T = 1$ y $RP_T = 3,80$) y densidades altas de siembra en ambos cereales ($DAC_T = 300$ y $DAC_C = 270$).

La combinación de manejo cultural y control químico en pre y postemergencia demuestra que la cantidad de maleza en todos los años se reduce notablemente. Esto se comprueba al observar la escala utilizada en la Fig. 2.14, que permite verificar que la cantidad de individuos acumulados en los distintos estados fenológicos no supera en ningún caso los 70 individuos/m² luego de la siembra del cereal. Es por ello que esta estrategia resulta ser la que conduce a picos de emergencia de maleza inferiores respecto a los registrados en los casos anteriores.

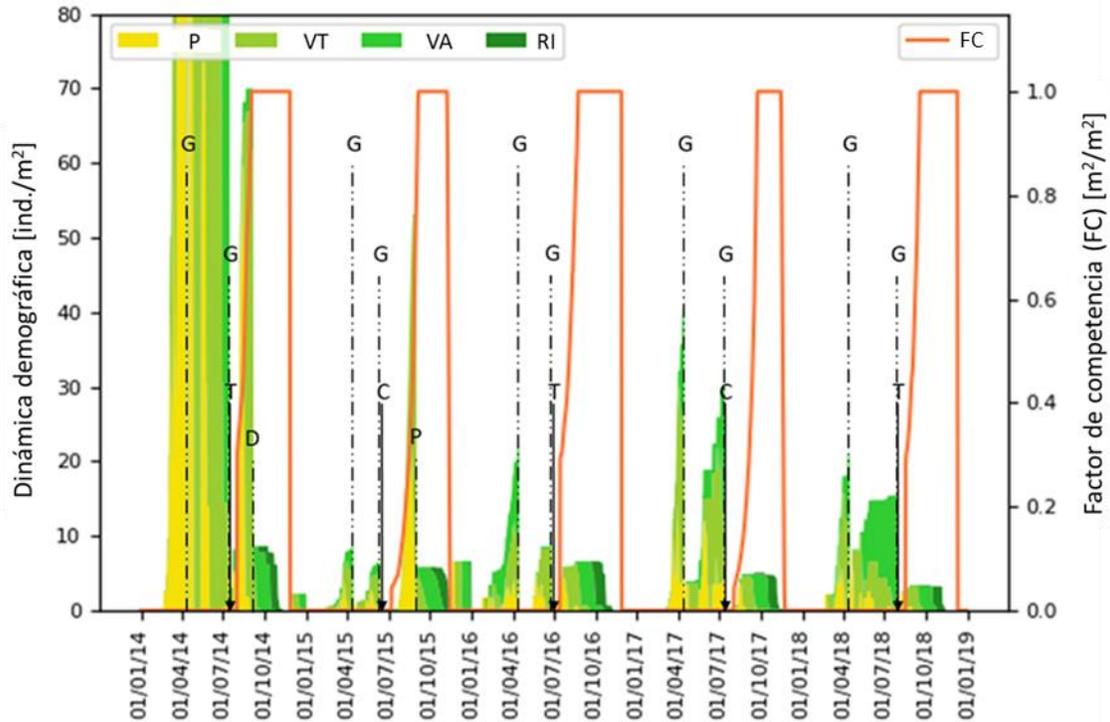


Fig. 2.14: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) en CASO SIV

Los resultados obtenidos (Tabla 2.13) presentan rendimientos superiores al 98% del rendimiento potencial del cultivo. Cabe destacar que, RC/RP es igual al 100% en todos los años en que se sembró trigo, debido a que, en este caso, se trata de un cultivar altamente competitivo con una baja competencia de AVEFA. Esto también se ve reflejado en los márgenes brutos ya que son positivos todos los años y, en muchos de ellos, mayores que los alcanzados en los otros casos.

Es evidente que la estrategia de control implementada es mucho más eficiente que en el resto de los casos, ya que permite competir mejor con la maleza, alcanzando una producción de semillas máxima de sólo un 4% en la primera temporada. Además, esto evita erogaciones por costos variables de limpieza del grano.

Tabla 2.13: Resultados del CASO SIV

CASO SIV	2014	2015	2016	2017	2018
Cultivo	Trigo	Cebada	Trigo	Cebada	Trigo
Ing. Venta Cultivo [USD/ha]	703	735	703	739	703
Gastos Cos. y Com. [USD/ha]	-211	-184	-211	-185	-211
Gastos Siembra [USD/ha]	-303	-285	-303	-285	-303
Gastos Limp. Sem. Fijo [USD/ha]	-81	-105	-81	-105	-81
Gastos Limp. Sem. Variable [USD/ha]	0	0	0	0	0
Gastos Control [USD/ha]	-98	-80	-36	-36	-36
MB [USD/ha]	10	81	72	128	72
VA [USD/ha]	226				
RC/RP	1,00	0,98	1,00	0,99	1,00
Índice <i>T</i>	1,00	1,00	1,00	1,00	1,00
Índice <i>P</i>	0,11	0,64	0,69	0,69	0,69
<i>EIQ</i>	44,14	30,11	29,38	29,38	29,38
Producción de semillas [%]	4,00	0,77	2,78	1,00	3,35
%Semillas con el grano [%]	0,04	0,01	0,03	0,01	0,03
Competencia ponderada	7,74	6,53	3,41	4,42	1,43

En cuanto al riesgo ambiental, a pesar de que éste aumenta con respecto a los CASOS SI y SIII en los años 2014-2015, disminuye en comparación con el CASO SII en 2016. Esto se produce porque el umbral de control establecido para la aplicación selectiva postemergente (10 individuos/m²) no fue superado a partir de 2016, lo que desactivó el uso de este control.

En relación al VA, éste se incrementó un 46% con respecto al CASO SIII y un 27% en relación al CASO SII. Esto confirma que, a pesar de ser una estrategia que implica mayores gastos en

control y un incremento en el costo ambiental en los primeros dos años, en cuanto a beneficios económicos es superior al resto de los casos.

2.8.5. CASO SV

En este caso de estudio se presenta el mismo manejo cultural (trigo altamente competitivo, altas densidades de siembra y fechas de siembra del cultivo teniendo en cuenta la predicción de emergencia de la maleza) y el mismo criterio de aplicación de herbicidas postemergentes (10 ind/m^2 , Fig. AIII.3) que en el CASO SIV. Sin embargo, en esta ocasión, se aplican dos controles mecánicos (arado de disco: L) en presiembra, a diferencia del control químico aplicado en el caso anterior. Los datos propios de esta estrategia se exponen en la Tabla AIII.5.

Este caso logra el mejor control, siendo la cantidad de maleza existente en cada estado fenológico incluso más pequeña que en el CASO SIV (Fig. 2.15) y mejor en cuanto a la eficiencia de control. Esto se debe a que se considera que la labranza tiene una eficiencia de control del 100% sobre todos los estados fenológicos de la maleza, mientras que el glifosato (método aplicado en lugar del control mecánico en el CASO IV), tiene eficiencias algo menores dependiendo del estado fenológico de la planta (99% en plántula, vegetativo temprano y vegetativo avanzando, y 50% en el estado reproductivo inicial). Sin embargo, esto no es suficiente para reducir el uso de herbicidas postemergentes, ya que se requiere de su uso al igual que en el caso anterior, en 2014 y 2015.

La Tabla 2.14 presenta los resultados correspondientes. Se observa que el *RC/RP* alcanzado es mayor al 98% en todos los años. Los rendimientos alcanzados cuando se siembra cebada son apenas superiores al caso anterior (lo cual no se aprecia en los resultados expuestos debido al redondeo). En cuanto al trigo, al igual que en el CASO SIV, se logra el rendimiento potencial (máximo).

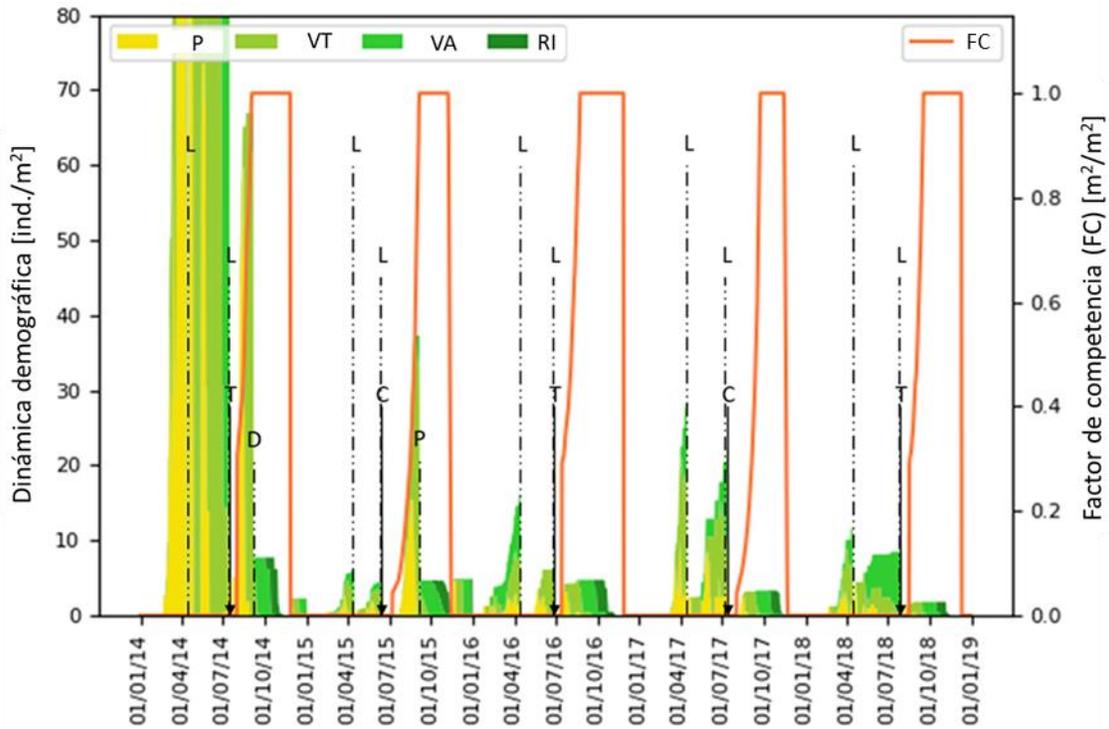


Fig. 2.15: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) en CASO SV

Asimismo, la mayor eficiencia de la labranza en el control de malezas repercute en la producción de semillas, ya que como mucho alcanza un 2,8% respecto de la máxima cantidad de semillas considerada en el modelo, un 70% de la lograda en el CASO SIV. Sin embargo, con ambas estrategias se cumplen los requerimientos de calidad del grano cosechado, por lo cual los gastos de limpieza variable son nulos en los dos casos.

En cuanto al impacto ambiental, el *EIQ* disminuye considerablemente. Sin embargo, este indicador no se podría tomar como única referencia para contrastar estas dos estrategias, debido a que sólo mide el impacto de los controles químicos aplicados, sin considerar los efectos sobre el medio ambiente provocados por la labranza.

Tabla 2.14: Resultados del CASO SV

CASO SV	2014	2015	2016	2017	2018
Cultivo	Trigo	Cebada	Trigo	Cebada	Trigo
Ing. Venta Cultivo [USD/ha]	703	737	703	743	703
Gastos Cos. Y Com. [USD/ha]	-211	-184	-211	-186	-211
Gastos Siembra [USD/ha]	-303	-285	-303	-285	-303
Gastos Limp. Sem. Fijo [USD/ha]	-81	-105	-81	-106	-81
Gastos Limp. Sem. Variable [USD/ha]	0	0	0	0	0
Gastos Control [USD/ha]	-142	-124	-80	-80	-80
MB [USD/ha]	-34	39	28	86	28
VA [USD/ha]	81				
RC/RP	1,00	0,98	1,00	0,99	1,00
Índice <i>T</i>	0,14	0,14	0,14	0,14	0,14
Índice <i>P</i>	0,41	0,95	1,00	1,00	1,00
<i>EIQ</i>	14,77	0,73	0,00	0,00	0,00
Producción de semillas [%]	2,81	0,59	1,93	0,44	1,75
%Semillas con el grano [%]	0,03	0,00	0,02	0,00	0,02
Competencia ponderada	7,17	5,48	2,46	3,03	0,77

En este caso, los índices *P* y *T* permitirían un análisis comparativo más exhaustivo. En el CASO SV, el índice *P* mejora notablemente, siendo superior en los años 2014 y 2015 al alcanzado en el caso anterior e igual al máximo en los años posteriores, debido a que en los años previos sólo se aplican herbicidas postemergentes. Sin embargo, como en esta simulación se realizan dos labranzas por año, el índice *T* empeora considerablemente con respecto al CASO SIV. Por esta razón, teniendo en cuenta ambos índices con igual

ponderación resultaría, en principio, más perjudicial efectuar dos labranzas como método de control presiembra que aplicar dos veces glifosato.

Por otro lado, los márgenes brutos alcanzados con esta estrategia son inferiores a los del CASO SIV en todos los años, llegando incluso a ser negativo en el 2014. Esto se debe a que la labranza es un método de control mucho más caro que la aplicación de glifosato, incrementando así los costos de control. Por ello también el *VA* es inferior al CASO SIV, siendo entonces la estrategia implementada en el caso previo la que mayor rédito económico proporciona. Asimismo, al comparar estos resultados con todos los casos analizados, el *VA* indicaría que esta opción sólo sería mejor que el CASO SI.

2.8.6. Resumen de los casos de estudio

En esta sección se presenta un resumen con los resultados generales de los cinco casos de estudio desarrollados anteriormente. En la Tabla 2.15 se detalla el número de aplicaciones de herbicidas, intervenciones mecánicas y acciones culturales que se realizan durante los cinco años, así como también los indicadores de desempeño económico y medioambiental para cada caso de simulación.

Tabla 2.15: Resumen de los casos de estudio

	CASOS			Desempeño (las flechas indican mejoría)			
	Número	Químico	Cultural	Mecánico	<i>VA</i> (↑)	Índice <i>P</i> (↑)	Índice <i>T</i> (↑)
I	10	0	0	0	-212	3.45	5.00
II	13	0	0	0	178	2.24	5.00
III	10	3	3	0	155	3.45	5.00
IV	12	3	3	0	226	2.82	5.00
V	2	3	3	10	81	4.36	0.70

Respecto al VA , el CASO IV resulta ser el más conveniente debido a que plantea un control cultural durante los cinco años de estudio combinado con control postemergente durante los primeros dos. Tal como se comentó previamente, se justifica realizar gastos en controles químicos posteriores a la siembra del cultivo debido a que, de esa manera, se logran altos rendimientos y baja producción de semillas. Sin embargo, esto ocasiona que el impacto ambiental, medido a través del índice P , sea más alto que en los casos sin aplicaciones de herbicidas postemergentes.

En relación al impacto ambiental provocado por el uso de herbicidas, el CASO V fue la mejor opción debido a que presenta el mayor índice P al realizar tan solo dos aplicaciones químicas en el periodo analizado. Sin embargo, debido a que se implementó un control mecánico presiembra durante los cinco años, el índice T resulta muy cercano a cero, lo que sugiere que esta estrategia podría ser inaceptable debido al riesgo excesivo de erosión del suelo. Asimismo, aunque el VA de este caso es positivo, es uno de los más bajos ya que la realización de labranza es mucho más costosa que el uso de glifosato.

Un caso intermedio entre estos dos extremos es el CASO III, ya que posee un resultado económico favorable con un impacto químico ambiental moderado y ausencia de actividad mecánica en el suelo. Sin embargo, se debe tener en cuenta que pueden existir otras posibles combinaciones de MIM que no se hayan considerado en este capítulo y que podrían lograr mejores equilibrios entre los índices de desempeño analizados. Por ejemplo, la posibilidad de realizar labranza solo una vez durante el barbecho cada año (o solo en algunos años) podría mejorar el índice P en escenarios con muchas aplicaciones químicas, a expensas del empeoramiento de VA e índice T .

2.9. Análisis de Sensibilidad

Debido a que los modelos planteados requieren del ingreso de algunos datos y parámetros que no siempre son fáciles de medir o tienen asociada cierta incertidumbre, se decidió

hacer un análisis de sensibilidad sobre algunos de ellos para estudiar el impacto en las principales variables del sistema.

El análisis de sensibilidad es una técnica que estudia cómo diferentes valores de una variable independiente o parámetro impactan en una variable dependiente. En particular, se decidió estudiar el efecto que ocasiona sobre el VA un cambio en: (i) el porcentaje de semillas de maleza a cosecha, (ii) el banco inicial de semillas, (iii) la tasa de descuento adoptada y (iv) la ocurrencia de resistencia de la maleza al herbicida postemergente. De esta manera, es posible analizar el comportamiento del VA bajo diferentes supuestos de estos parámetros.

2.9.1. Análisis de sensibilidad sobre el porcentaje de semillas de maleza a cosecha

El análisis de los resultados sugiere que uno de los parámetros que más afecta el margen bruto de la actividad es el costo por limpieza de las semillas a cosecha. Debido a que no hay un dato preciso de dicha proporción, se realizó un análisis de sensibilidad para evaluar en qué orden de magnitud este parámetro altera los márgenes brutos logrados a lo largo de los años, representados en el momento actual por medio del VA. A pesar de que la maleza “cosechada” junto con el cultivo es una cantidad muy difícil de establecer (ya que depende de muchos factores tales como el tipo de cosechadora, su velocidad, momento de cosecha, estado de la maleza, etc.), entendemos importante considerar su variabilidad analizando al menos algunos casos extremos. Para ello, se simuló nuevamente los cinco casos anteriores, considerando que la cantidad de semillas de maleza cosechada junto con los cereales ($\%Sem_{Cosec}$) es del 10, 20 y 30% del total de semillas producidas por la maleza. Cabe recordar que el valor empleado en los experimentos anteriores es de 20%. Cuanto mayor sea la cantidad de semillas de AVEFA recolectadas por la cosechadora, se esperaría que los gastos variables de limpieza comiencen a aumentar, por lo que el margen bruto se reduciría y consecuentemente el VA.

Como puede observarse en la Fig. 2.16, en el CASO SI, el VA disminuye notoriamente cuando el porcentaje de semillas de maleza cosechado se incrementa. Recordamos que, en ese caso, la cantidad de maleza a cosecha es la máxima (no hay controles postemergentes) por lo que cualquier ineficiencia de limpieza se traslada directamente a la economía. En el CASO SIII no se produce una caída del VA cuando el $\%Sem_{Cosec}$ es de 10 y 20%, pero sí decae algo cuando el porcentaje de semillas cosechadas junto con el grano es de 30%. Esto se debe a que, para esa estrategia, aunque no se apliquen controles postemergentes, el manejo cultural provoca un menor impacto sobre la población de la maleza, lo que termina trasladándose a costos. En el resto de los casos (SII, SIV y SV), donde se realiza algún tipo de control postemergente y/o alguna práctica cultural, el VA permanece relativamente invariable (decimales no mostrados). Esto se produce ya que existe un mejor control de la maleza y, consecuentemente, una menor producción de semillas al final de cada año que permite que la cosecha posea la calidad exigida para su comercialización, evitando gastos de limpieza variable para los tres valores analizados de $\%Sem_{Cosec}$.

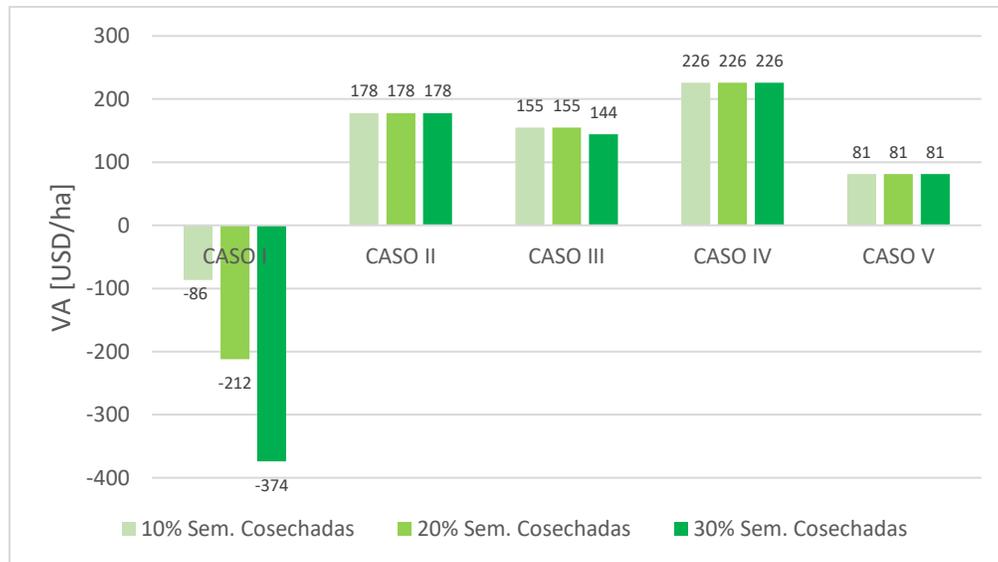


Fig. 2.16: Análisis de sensibilidad sobre el porcentaje de semillas de maleza a cosecha

2.9.2. Análisis de sensibilidad sobre el banco inicial de semillas

El banco inicial de semillas de AVEFA también tiene una gran influencia en el *MB*, ya que se vincula indirectamente con el rendimiento del cultivo y con los costos operativos relacionados con la intensidad y frecuencia de uso de herbicidas y aquellos asociados a la limpieza de semillas.

En la Fig. 2.17 se observa el efecto de la variación de la infestación inicial (2000 semillas/m²) sobre el *VA* para los cinco casos estudiados. En particular, el análisis se realizó incrementando un 75% el banco de semillas inicial (3500 semillas/m²) y disminuyéndolo también un 75% (500 semillas/m²).

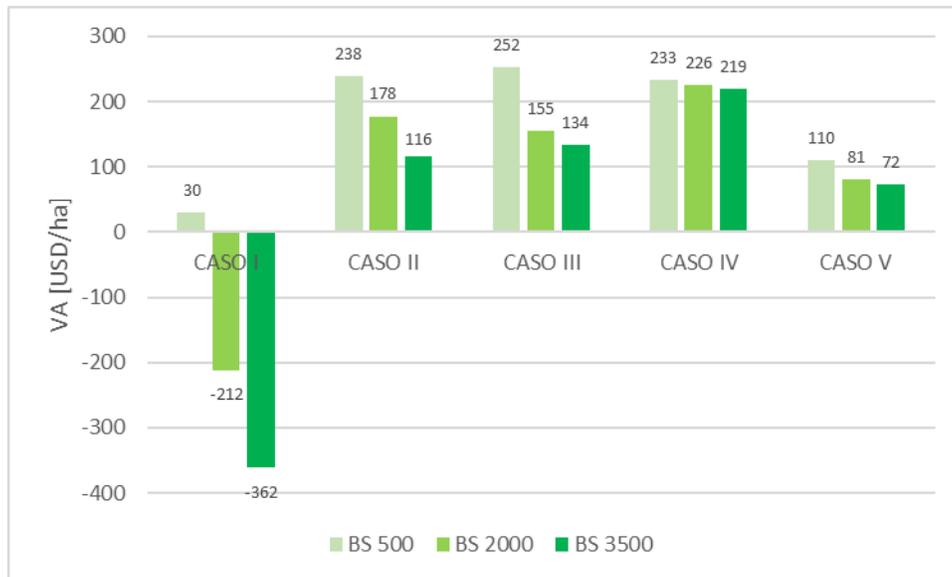


Fig. 2.17: Análisis de sensibilidad sobre el banco inicial de semillas

En este estudio, nuevamente el CASO SI es el más sensible a este parámetro, reduciéndose progresivamente el *VA* a medida que el banco de semillas inicial aumenta, ya que no se cuenta con controles postemergentes o medidas culturales que limiten el impacto de la infestación inicial. Para el CASO SII sucede algo similar, aunque no tan extremo, ya que la caída del *VA* en relación al aumento del *BS* no es tan abrupta debido a la acción de los

controles postemergentes. En el CASO SIII se observa claramente la ventaja del *MIM* sobre el CASO SI, ya que el *VA* decae en mucha menor proporción que en este último aún sin contar con el efecto de los herbicidas postemergentes. A su vez, comparado con el CASO SII, es evidente que el *VA* mejora en mayor medida cuando el banco de semillas disminuye, pero cuando éste aumenta, su caída no es tan importante. En los CASOS SIV y SV, donde se combina la totalidad de las acciones de control posibles, el *VA* permanece con relativa poca variación.

2.9.3. Análisis de sensibilidad sobre la tasa de descuento

Dado que la tasa de descuento utilizada para calcular el *VA* varía de acuerdo al retorno que se espera por realizar la actividad, se realizó un análisis de sensibilidad sobre la misma a fin de comprobar si cambiaba la aceptación o el rechazo de algunas de las estrategias analizadas.

En la Fig. 2.18 se observa el efecto de una tasa de descuento del 5%, 15% y 25% sobre el *VA* para cuatro de los cinco casos estudiados. Recordamos que el valor de referencia empleado en los casos base es 15%.

Como era de esperarse, a medida que la tasa de descuento aumenta, el *VA* disminuye, dado que el dinero en los años futuros “vale” menos en el año actual o año cero. Sin embargo, este análisis permite establecer que, en todos los casos exceptuando el CASO SI, el proyecto podría aceptarse, ya que el *VA* siempre es positivo.

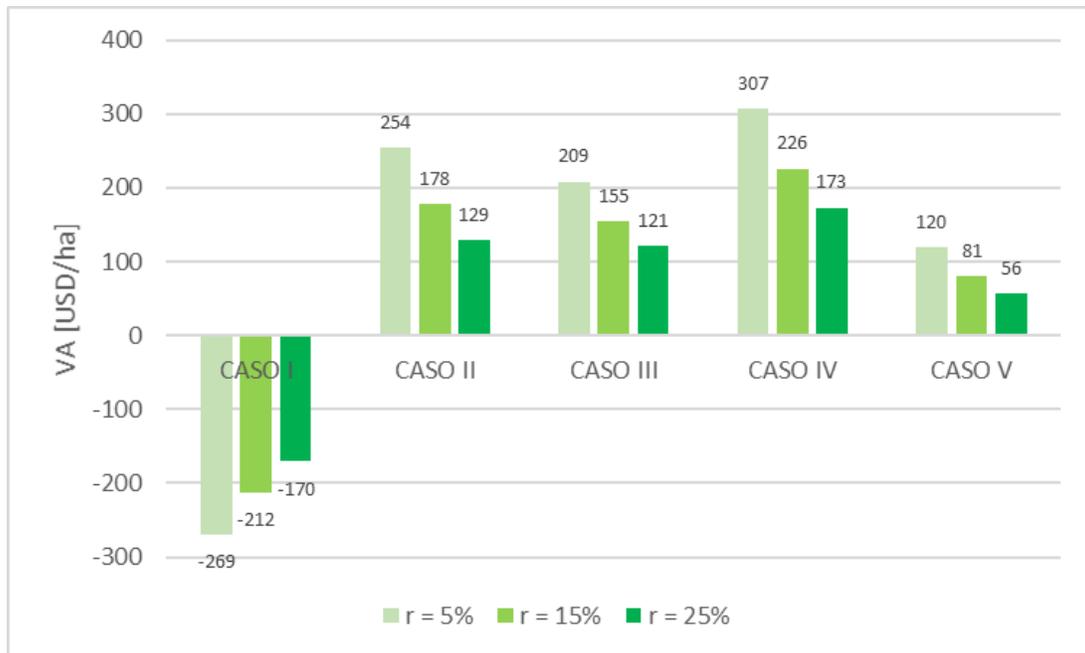


Fig. 2.18: Análisis de sensibilidad sobre la tasa de descuento

2.9.4. Análisis de sensibilidad sobre la ocurrencia de resistencia de la maleza al herbicida postemergente

Como se describió con algún detalle en el capítulo introductorio, un factor que está cobrando cada vez más importancia tecnológica y social es la resistencia de la maleza a los herbicidas utilizados. Por esta razón, se decidió analizar las consecuencias que tendría en el VA una disminución del 30 y 60% en la eficiencia del control (eficiencia media y baja respectivamente) que tienen los herbicidas postemergentes (diclofop-metil y pinoxaden) en los distintos estados fenológicos de la maleza. Actualmente se está observando cierta resistencia de AVEFA a dichos herbicidas, mientras que, hasta el momento, no ha sido detectada para el glifosato. Por tal motivo, la Tabla 2.16 sólo presenta los cambios en la eficiencia de los postemergentes que casualmente tienen impactos similares en los distintos estados fenológicos. Es importante mencionar que dichas eficiencias no se relacionan con el momento de aplicación del postemergente, sino que se asocia a la tolerancia de cada estado fenológico de la maleza al herbicida.

Tabla 2.16: Eficiencia de los métodos de control postemergentes

Eficiencia de control	Resistencia de la maleza	Plántula	Vegetativo Temprano	Vegetativo Avanzado	Reproductivo Inicial
Máxima	Baja	1,00	0,90	0,70	0,20
Media	Media	0,70	0,63	0,49	0,14
Baja	Alta	0,40	0,36	0,28	0,08

En la Fig. 2.19 se presenta gráficamente los resultados del análisis de sensibilidad. Como era de esperarse, en los CASOS SI y SIII no se observan cambios en el VA dado que no se aplicaron postemergentes en estos experimentos. Por el contrario, en el resto de los casos (SII, SIV y SV) el VA cae notoriamente a medida que aumenta la resistencia a los herbicidas (o disminuye la eficiencia del herbicida). Este factor afecta a tal punto que el CASO SII deja de ser económicamente viable cuando la maleza presenta resistencia a los controles químicos postemergentes, mientras que el CASO SV se vuelve inviable cuando la eficiencia de control es baja.

Es importante volver a mencionar que todos los herbicidas postemergentes se aplican solamente si se supera un umbral de 10 individuos/m² en el estado vegetativo temprano, 20 días después de detectada esa densidad. En el CASO SII, sucedió que dicho umbral pasó de superarse sólo en los primeros tres años (2014, 2015 y 2016) cuando no había resistencia al herbicida (eficiencia de control máxima), a necesitar aplicarse los cinco años analizados para eficiencias de control media y baja. Esta erogación de dinero en concepto de gastos de control, provoca que pase de ser un proyecto rentable ($VA > 0$) cuando no hay resistencia, a ser una estrategia que no es recomendable adoptar cuando ésta aparece ($VA < 0$).

Para el CASO SIV sucedió que cuando no existía resistencia, se aplicó postemergentes sólo los dos primeros años (2014 y 2015). En cambio, con resistencia media, se debe aplicar tres años (2014, 2015 y 2016) y con resistencia alta se utilizan herbicidas postemergentes los cinco años. Cabe destacar que éste es el único caso entre los que aplican herbicidas

postemergentes que, aún frente a una población de malezas que presenta alta resistencia, siempre logra un VA positivo.

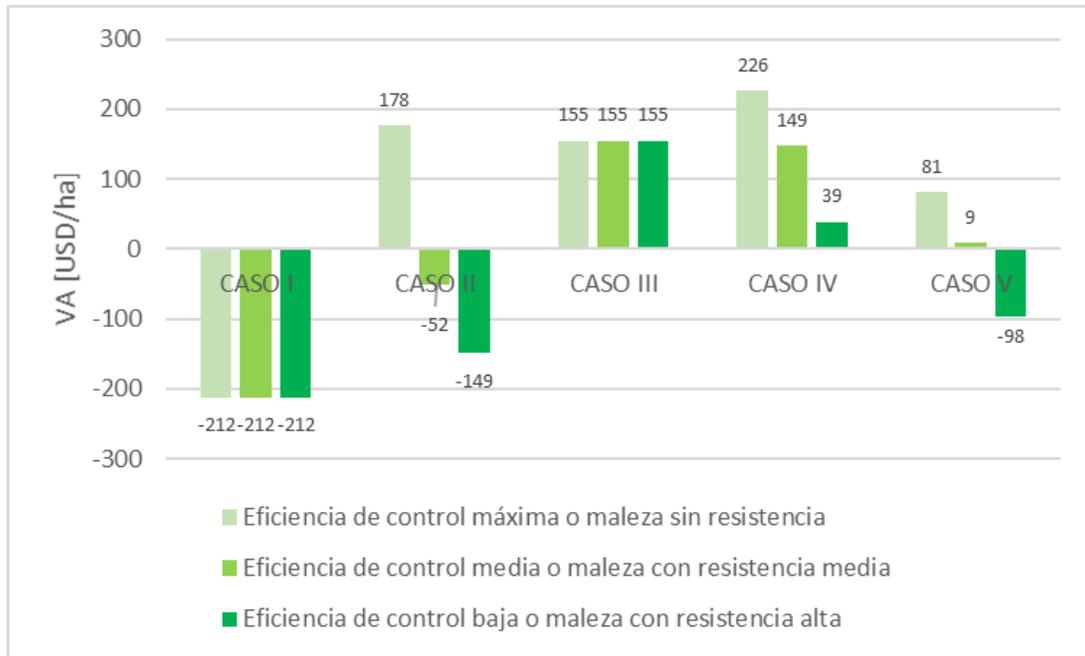


Fig. 2.19: Análisis de sensibilidad sobre la ocurrencia de resistencia de AVEFA al herbicida postemergente

Al igual que en el caso anterior, en el CASO SV se observó que cuando no hubo resistencia fue necesario emplear un método de control postemergente los dos primeros años (2014 y 2015). Sin embargo, cuando se considera una resistencia media se los debe emplear tres años (2014, 2015 y 2016) y para una resistencia alta, se los debe aplicar todos los años simulados. Este caso presenta un VA positivo más pequeño que en el resto de los casos cuando no hay resistencia al herbicida. Esta estrategia sigue siendo recomendable cuando la resistencia es media pero no cuando es alta, ya que se convierte en un proyecto que no daría ganancias debido a que su VA es negativo.

En conclusión, a medida que la resistencia a los herbicidas postemergentes aumenta, el VA disminuye considerablemente. Esto se debe a que se incrementa el banco de semillas cada año, ya que hay una mayor cantidad de malezas que alcanzan su estado reproductivo inicial.

Además, según el criterio de aplicación de postemergentes establecido, es necesario emplearlos en más años que cuando no se encuentra resistencia, provocando mayores gastos en control químico.

CAPÍTULO 3

ALGORITMO DE OPTIMIZACIÓN

En este capítulo se introduce brevemente la optimización no lineal mixto entera multi-objetivo, su formulación matemática y la complejidad relacionada con la presencia de no linealidades y variables binarias, así como también se establecerá la diferencia entre algoritmos determinísticos y metaheurísticos. Posteriormente, se describe la metaheurística Optimización por Enjambre de Partículas (PSO), adoptada como herramienta básica de exploración del espacio de soluciones. Luego, se detalla la metodología propuesta para el manejo de restricciones junto con la técnica “Angle Modulation” para manipular variables binarias. A continuación, se explica la metodología de frente de Pareto adoptada que permite al PSO optimizar modelos con múltiples objetivos, extendiendo aún más sus prestaciones. Por último, se evalúa la eficiencia del optimizador desarrollado al testarlo con funciones *benchmark* de dos y tres objetivos.

3.1. Optimización MINLP-MO

Existen diversos problemas de la vida real que pueden representarse como problemas de optimización. Al hablar de optimización se hace referencia al proceso de encontrar la combinación de variables que minimicen o maximicen uno o más criterios de desempeño o funciones objetivo del sistema, respetando una serie de restricciones de igualdad y desigualdad.

Los problemas de optimización típicamente contienen variables continuas, que son aquellas que pueden tomar cualquier valor dentro de un cierto intervalo, y usualmente representan cantidades medibles. Muchos problemas de optimización también involucran variables discretas, que son variables que pueden tomar valores dentro del conjunto de los números

enteros. Este tipo de optimización que combina variables continuas y discretas se denomina mixto entera y es más compleja de resolver que la versión continua. En particular, en esta tesis se hará uso solamente de variables binarias, que son un tipo de variables discretas que sólo pueden tomar dos posibles valores: cero o uno. Normalmente se utilizan para determinar si se realiza o no una cierta acción, si se elige un producto por sobre otro, etc.

Asimismo, la mayoría de los problemas prácticos son multiobjetivo, es decir, no poseen un único criterio medible por el cual pueda declararse que una solución sea completamente óptima, tal como sucede, por ejemplo, con los modelos agronómicos del tipo que se utiliza en esta tesis. Este tipo de problemas suelen tener dos o más funciones objetivo que se desean optimizar simultáneamente y que, en general, se encuentran en conflicto entre sí. Esta característica provoca que no exista una única solución que optimice simultáneamente todos los objetivos considerados, ya que la mejora en uno de ellos suele dar lugar al empeoramiento de otro (Zhang y col., 2018).

3.1.1. Formulación matemática

En general, un problema de optimización multiobjetivo que minimice NFO funciones objetivo, y que involucre m variables continuas y n variables binarias, puede describirse matemáticamente según la Ec. 3.1:

$$\text{Minimizar } \mathbf{f}(\mathbf{x}, \mathbf{y}) = (f_1(\mathbf{x}, \mathbf{y}), \dots, f_k(\mathbf{x}, \mathbf{y}), \dots, f_{NFO}(\mathbf{x}, \mathbf{y}))$$

Sujeto a:

$$\begin{aligned} \mathbf{h}(\mathbf{x}, \mathbf{y}) &= 0 \\ \mathbf{g}(\mathbf{x}, \mathbf{y}) &\leq 0 \\ \mathbf{x}^{lo} - \mathbf{x} &\leq 0 \\ \mathbf{x} - \mathbf{x}^{up} &\leq 0 \\ \mathbf{y} &\in (0,1) \end{aligned} \tag{3.1}$$

donde $f(\cdot)$ son las funciones objetivo a optimizar; x e y son los conjuntos de variables de optimización continuas y binarias, respectivamente; $h(\cdot)$ y $g(\cdot)$ representan las restricciones de igualdad y desigualdad respectivamente y los parámetros x^{lo} y x^{up} son los límites inferiores y superiores de las variables continuas. El problema (Ec. 3.1) constituye una formulación bastante general del problema mixto-entero no lineal multiobjetivo (MINLP-MO, por sus siglas en inglés).

3.1.2. Complejidad no lineal y combinatoria

Un problema de optimización puede ser muy complejo de resolver cuando éste presenta no linealidades en sus funciones objetivo y/o en sus restricciones. Varias de ellas suelen introducir no-convexidades, lo que generalmente implica que la región factible sea irregular, dando lugar a la presencia de múltiples óptimos locales. Muchas veces resulta muy difícil encontrar la mejor solución entre todas las existentes o incluso, simplemente, una solución factible. A su vez, las variables binarias imponen restricciones de integralidad debido a que su valor solo puede ser cero o uno, lo que conduce a una “complejidad combinatoria” relacionada con la gran cantidad de posibilidades que se podrían enumerar para un número relativamente pequeño de variables binarias. De hecho, el número de posibles combinaciones para n variables binarias es igual a 2^n , resultando enorme aun para n moderado. Por estas razones, resolver problemas de optimización MINLP de gran escala en términos del número de ecuaciones y variables, en tiempos de cómputo compatibles con aplicaciones prácticas, es uno de los mayores desafíos dentro de la matemática aplicada moderna.

Actualmente se encuentra muy desarrollada una amplia gama de plataformas y algoritmos que permiten realizar modelado matemático y optimización. Dentro de las herramientas comerciales más populares y competitivas se encuentran MATLAB¹, gProms² y GAMS³, por

¹ www.mathworks.com/products/matlab.html

² www.psenterprise.com/products/gproms

³ www.gams.com

ejemplo. Sin embargo, ni siquiera estas herramientas permiten encontrar siempre soluciones globalmente óptimas en el caso de los problemas que presentan las complejidades mencionadas anteriormente.

La principal razón es que, tal como enuncia el teorema de “no free lunch” en optimización (Wolpert y Macready, 1997; Ho y Pepyne, 2002), no existe un único algoritmo de aplicación universal que resuelva, de manera igualmente eficiente, todos los diferentes tipos de problemas de optimización. Este teorema expresa que, si un determinado algoritmo alcanza un buen desempeño sobre cierta clase de problemas, entonces tendrá un rendimiento más pobre sobre otro tipo de modelos.

3.1.3. Algoritmos determinísticos y metaheurísticos

Dentro de la gran variedad de opciones que existe para clasificar los diversos algoritmos de optimización numérica, nos centraremos particularmente en establecer las diferencias entre los enfoques determinísticos y los metaheurísticos para abordar el problema 3.1.

La optimización determinística es completamente predictiva. Definidas las entradas del algoritmo (puntos iniciales de las variables y parámetros del algoritmo o *solver*), el procedimiento de búsqueda siempre producirá la misma salida, es decir, convergerá siempre a la misma solución, sin contemplar la existencia del azar ni el principio de incertidumbre. La implementación de este tipo de algoritmos es matemáticamente sofisticada y, bajo ciertas condiciones, puede garantizar la convergencia al óptimo global.

En particular, cuando se trata de modelos no lineales, las técnicas determinísticas dependen en gran medida de un buen valor inicial de sus variables para poder converger a una solución. Además, para tratar con las no-linealidades que podrían estar presentes en la función objetivo y/o en las restricciones, estos algoritmos requieren información de ciertas propiedades matemáticas (como por ejemplo la diferenciabilidad, la continuidad y la convexidad de dichas funciones) lo que implica, por una parte, un gran esfuerzo de cálculo y, por otra, limita la aplicabilidad de los algoritmos. Asimismo, si el modelo involucra variables binarias, éstas se

abordan típicamente con estrategias como las de “Branch and Bound” (Tawarmalani y Sahinidis, 2002), consistentes en “enumeraciones inteligentes” del árbol de opciones que se despliega.

Este tipo de optimización suele ser computacionalmente demandante, por ejemplo, en modelos complejos de mediana/gran escala suele suceder que la memoria se agote o que se alcancen los tiempos de ejecución máximos antes de alcanzar una solución óptima o, incluso, factible. Sin embargo, esta problemática puede sortearse en algunos casos con técnicas de descomposición de los modelos, como por ejemplo las descomposiciones de Benders y lagrangeana (Conejo y col., 2006).

Normalmente, las implementaciones computacionales más competitivas de métodos de optimización determinísticos suelen ser productos propietarios comerciales. Por ejemplo, GAMS, una plataforma comercial muy popular de modelado matemático, posee diferentes *solvers* muy desarrollados para resolver cada clase de problemas: CONOPT y MINOS para problemas no lineales (NLP); Cplex y Gurobi para problemas mixto-entero lineales (MILP) y BARON y DICOPT para problemas mixto-entero no lineales (MINLP), entre otros.

Por su parte, las metaheurísticas se encuentran dentro del grupo de los algoritmos no determinísticos que se caracterizan por contar con elementos aleatorios para guiar la exploración. Estas técnicas resuelven de manera aproximada un rango muy amplio de diferentes problemas, contando con la gran ventaja de que no suelen necesitar de adaptaciones particulares para abordarlos.

Estas metodologías (Boussaid y col., 2013) parten de un punto inicial, o conjunto de puntos iniciales, en el espacio de búsqueda y lo van mejorando por medio de reglas usualmente bastante sencillas que incorporan elementos estocásticos. Dichas reglas suelen estar inspiradas en procesos naturales (físicos y biológicos) que, en muchos casos, permiten alcanzar soluciones cercanas al óptimo global.

A diferencia de los métodos determinísticos, en las metaheurísticas no es necesario explicitar un punto inicial adecuado para lograr un rendimiento eficiente, pero sí se debe establecer un buen equilibrio entre la exploración de la región de búsqueda y la explotación de los puntos

más prometedores. Otra ventaja que poseen es que, en su proceso para encontrar la solución, sólo suelen requerir de los valores de las funciones objetivos y de las restricciones. Esto resulta muy práctico, por ejemplo, cuando es necesario resolver modelos con funciones discontinuas, ya que no se precisa de ningún esfuerzo de modelado o de programación adicional para tratarlos, a diferencia de los algoritmos determinísticos para los que típicamente deben efectuarse reformulaciones.

Sin embargo, las metaheurísticas cuentan con una gran desventaja cuando se trata de modelos que presentan restricciones. Se ha observado una baja performance en la resolución de este tipo de problemas, en particular en presencia de restricciones de igualdad, ya que se limita notablemente la eficiencia de exploración del algoritmo al reducirse rápidamente la región factible del problema. Habitualmente esta limitación se traslada a la necesidad de grandes esfuerzos de cómputo para hallar soluciones de aceptable calidad en problemas fuertemente restringidos.

A pesar de sus limitaciones, las metaheurísticas basadas en poblaciones han cobrado gran importancia (Boussaid y col., 2013; Halim y col., 2020) en los últimos años. Adicionalmente, Woon y Rehbock (2010) sugieren el enfoque heurístico para abordar los problemas de optimización mixto-entera.

En las secciones siguientes (3.2 a 3.5) se comentan los detalles del algoritmo de exploración que se diseñó e implementó computacionalmente para abordar el problema de optimización del MIM presentado en el capítulo anterior. Debido a que el diseño de un algoritmo MINLP-MO como el propuesto involucra una gran cantidad de posibilidades, se procura ir justificando en cada caso tanto la metodología adoptada como la parametrización correspondiente.

3.2. Optimización continua por enjambre de partículas (PSO)

En la actualidad, entre las metaheurísticas más populares se encuentran los “algoritmos genéticos”, las “colonias de hormigas” y los “enjambres de partículas” (Boussaid y col., 2013; Halim y col., 2020). En esta tesis se decidió utilizar la optimización por enjambre de partículas

(PSO por sus siglas en inglés) como metodología base de optimización continua, por ser de relativamente sencilla implementación y a la vez, porque se ha reportado un buen rendimiento en diversas aplicaciones (Marini y Walczak, 2015). Estas características han sido corroboradas por experiencia propia (Damiani y col., 2020). Además, se consideró su gran flexibilidad para ser hibridada y extendida, ya que esta particularidad permitiría ampliar aún más su rango de aplicaciones al incorporarle técnicas que admitan manipular múltiples objetivos y variables binarias, entre otras.

Todas estas cualidades la tornan una metodología atractiva para optimizar modelos complejos como lo son los agronómicos de simulación cultivo-maleza que motivan este proyecto.

PSO pertenece a la familia de las metaheurísticas descritas anteriormente y fue propuesta por Kennedy y Eberhart (1995). Está inspirada en la conducta de comunidades de individuos cuando buscan alimentos, por ejemplo, cardúmenes de peces, bandadas de aves o enjambres de insectos. En esta técnica, cada individuo forma parte de una población de posibles soluciones o soluciones candidatas que se mueven en el espacio de búsqueda guiándose a través de reglas sencillas. Éstas consideran la mejor posición local encontrada por cada individuo y la mejor posición global, hallada por todo el enjambre a medida que recorre la región de búsqueda.

La mejor posición local se refiere a la “memoria autobiográfica” de cada individuo, es decir, al “recuerdo” de su propia experiencia. La misma se relaciona con el ajuste de la velocidad con que cada partícula se mueve debido a la “nostalgia simple”, es decir, a la tendencia de cada partícula a regresar a aquel lugar que más la satisfizo. En cambio, la mejor posición global es como el conocimiento publicitado, que se refiere a una norma o estándar grupal que cada individuo trata de lograr.

El mejor global y el mejor local se van actualizando cada vez que se descubren nuevas y mejores posiciones. Asimismo, la velocidad y posición de las partículas se modifican iterativamente hasta que se cumple algún criterio de terminación, que suele estar asociado a la convergencia, o simplemente consistir en un cierto número de iteraciones o tiempo máximo

de búsqueda. En la Fig. 3.1 se esquematiza este proceso, los puntos representan las partículas, las flechas sus respectivas velocidades y la estrella el óptimo buscado.

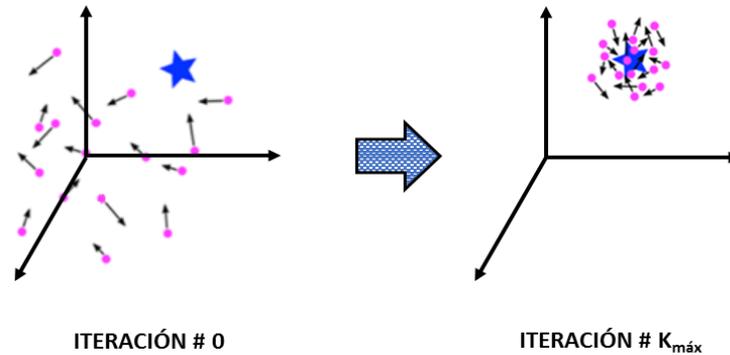


Fig. 3.1: Descripción gráfica del PSO

En el PSO es muy importante lograr un buen balance entre la exploración y la explotación del espacio de búsqueda para conseguir así un algoritmo con una buena tasa de convergencia al óptimo global. La exploración es necesaria para descubrir nuevas regiones y evitar la convergencia prematura. Por otro lado, la explotación actúa mejorando las soluciones encontradas hasta el momento.

A lo largo del tiempo esta técnica se ha ido mejorado con aportes de distintos investigadores. Por ejemplo, se han propuesto variaciones en su parametrización, combinación con otras metaheurísticas y diferentes tipos de hibridaciones, entre otras. Algunos ejemplos notables de mejoras en el PSO básico son: Gou y col. (2017), Luo y col. (2018) y Zhou y col. (2020) para abordar la convergencia global (especialmente en espacios de búsqueda complejos y restringidos) y Shokrian y High (2014), Aguilera-Rueda y col. (2016) y Ang y col. (2020), para manipular restricciones, una de las principales debilidades de esta metodología.

A pesar de que el PSO es computacionalmente intensivo, porque necesita evaluar muchas veces la función objetivo y las restricciones hasta alcanzar la convergencia, se lo ha empleado para resolver diferentes sistemas de escala realista para varias disciplinas. Por ejemplo, Chen y col. (2017) presentaron un modelo lineal mixto-entero para optimizar con el PSO la cadena

de suministro de la industria de celdas solares. Lang y Zhao (2016) también propusieron un modelo basado en esta técnica para la programación de producción en la industria petrolera. Montain y col. (2015) lo utilizaron como un motor de optimización multiobjetivo para un modelo fisiológico de interés médico. Por otro lado, Adams y Seider (2008) informaron sobre el uso de PSO para la optimización dinámica de procesos químicos complejos. Asimismo, Erbeyoglu y Bilge (2016) aplicaron esta metaheurística al problema de mezclado, un sistema desafiante de la industria del petróleo. En Elbes y col. (2019) se presenta una revisión de aplicaciones de PSO en ingeniería, especialmente en aplicaciones relacionadas con redes. Por su parte, Ding y col. (2019) aplicaron este algoritmo para la identificación de parámetros y en la optimización de sistemas de potencia. Yuen y col. (2020) desarrollaron un PSO multiobjetivo para optimizar el problema del tráfico señalizado. Incluso, Zemmal y col. (2020) utilizaron esta metaheurística para clasificar datos médicos.

Todas estas aplicaciones del PSO indican que posee un gran potencial para resolver diversos problemas de optimización, tanto de interés académico como práctico. Woon y Rehbock (2010) sugieren el enfoque heurístico para abordar los problemas de optimización mixto-entera, éste es el caso de los modelos abordados en esta tesis.

A continuación, se presenta la formulación matemática de este algoritmo de optimización para variables continuas, así como también su parametrización.

3.2.1. Formulación matemática

Teniendo en cuenta que el espacio de búsqueda es de dimensión D y que el enjambre se compone de N partículas, entonces las posiciones de las partículas en el espacio de búsqueda se pueden representar con la matriz x (Ec. 3.2).

$$\mathbf{x} = x_{ij} = \begin{bmatrix} x_{11} \dots x_{1j} \dots x_{1D} \\ x_{i1} \dots x_{ij} \dots x_{iD} \\ \vdots \\ \vdots \\ x_{N1} \dots x_{Nj} \dots x_{ND} \end{bmatrix} \quad \forall i \in [1, N], \forall j \in [1, D] \quad (3.2)$$

La posición de cada partícula x_{ij} , en su movimiento de búsqueda de la solución óptima, se va actualizando en cada iteración k según la trayectoria dada por la Ec. 3.3:

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} t^k \quad \forall i \in [1, N], \forall j \in [1, D] \quad (3.3)$$

siendo k la iteración actual, v_{ij} la velocidad de la partícula "i" a lo largo de la dimensión "j"; t es la fracción de tiempo que arbitrariamente se asume igual a la unidad.

La velocidad que adopta cada una de las partículas, para avanzar de una solución a otra, se establece con la Ec. 3.4.

$$v_{ij}^{k+1} = w^k v_{ij}^k + c_1 r_{1ij} (p_{ij}^k - x_{ij}^k) + c_2 r_{2ij} (q_j - x_{ij}^k) \quad (3.4)$$

$$\forall i \in [1, N], \forall j \in [1, D]$$

donde p_{ij} es el mejor personal, esto es la mejor posición alcanzada por ese individuo a lo largo de su recorrido; q_j es el mejor social, es decir, la mejor solución encontrada por todo el enjambre hasta el momento. Los símbolos w , c_1 , c_2 , r_{1ij} y r_{2ij} representan parámetros cuya función se describe más abajo.

La velocidad se compone de tres términos:

- *Inercia o impulso* (wv_{ij}): conserva un registro de la orientación previa, evitando que las partículas cambien radicalmente la dirección que traían;
- *Componente cognitivo* ($c_1r_{1ij}(p_{ij} - x_{ij})$): considera la predisposición de la partícula de regresar a la mejor posición que encontró anteriormente;
- *Componente social* ($c_1r_{1ij}(q_j - x_{ij})$): establece la capacidad de cada partícula para guiarse por la mejor posición encontrada por toda la población durante la búsqueda.

La Fig. 3.2 muestra un esquema de cómo los tres términos que componen la velocidad influyen en la determinación de la nueva posición de una partícula.

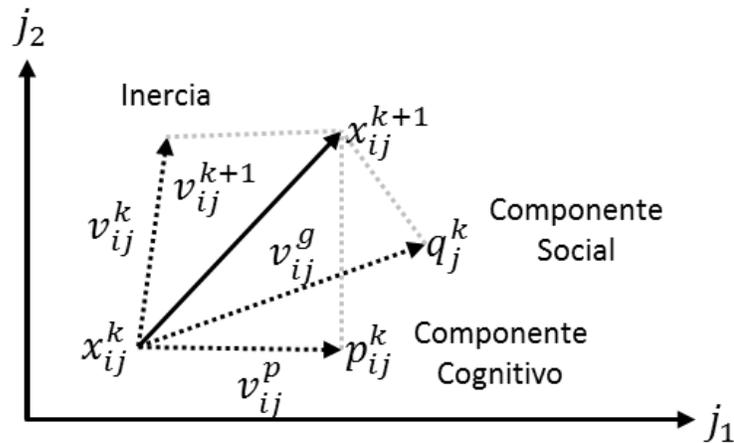


Fig. 3.2: Descomposición de la velocidad

3.2.2. Elementos y parametrización del PSO

Definir los parámetros del PSO es una parte muy importante en la implementación del optimizador debido a que éstos guían el comportamiento de las partículas; su selección está directamente relacionada con la eficiencia del algoritmo para resolver determinados problemas.

La cantidad de bibliografía que abarca la parametrización del PSO es bastante numerosa. Cleghorn y Engelbrecht (2018) proporcionan un análisis riguroso sobre diversos aspectos prácticos de la selección de parámetros. A continuación, se describen los principales elementos del algoritmo con énfasis en el efecto de los diferentes parámetros.

Actualización de las partículas: PSO sincrónico y asincrónico

Según el momento en que se efectúa la actualización de la memoria local (p) y global (q), el PSO puede ser sincrónico o asincrónico. En el primer caso, todos los individuos del enjambre se mueven en paralelo y comparten información. Luego de que, en cada iteración, se evalúe la función objetivo de todas las partículas, se actualiza el mejor local y global. De esta manera, todo el enjambre se guía por el mismo p y q . Por el contrario, en el PSO asincrónico, en cada iteración, cada partícula se mueve de acuerdo al mejor global y local encontrado por sus predecesores. En este caso la población posee diferentes guías.

Si se analiza el rendimiento general de ambos tipos de PSO, no existen diferencias significativas para una gran variedad de problemas (Cleghorn y Englebrecht, 2018). En particular, en esta tesis se optó por programar el PSO sincrónico por su potencial para poder ser ejecutado en paralelo en múltiples procesadores, lo que posibilitaría en el futuro la aceleración de las ejecuciones.

Topologías PSO

La topología, también denominada estructura social o vecindad, determina la manera en que las partículas se comunicarán entre sí. Este parámetro influye en la velocidad y en el grado en que el enjambre se dirige hacia una determinada región afectando, en consecuencia, la performance del PSO. Si bien existen diversas estructuras sociales, no se ha comprobado que exista una que sea superior a las otras en todos los problemas de optimización.

Según Kennedy (1999) una de las topologías más implementadas es la estrella (o “gbest” o mejor global), ya que reporta un buen rendimiento en una amplia gama de problemas y es la que se utilizó en esta tesis. Con esta configuración, cada una de las partículas se guía por la mejor solución encontrada por toda la población. En este caso, el PSO suele converger más rápido que en otras estructuras sociales, con la desventaja de una mayor posibilidad de quedar atrapado en soluciones locales.

Criterios de terminación

Los criterios de terminación son los que determinan el momento en que la optimización finaliza. Establecer la manera en que un algoritmo termine de iterar es muy importante para impedir que acabe prematuramente la optimización o que, por el contrario, consuma excesivos tiempos de cómputo. Normalmente, los criterios de terminación más utilizados (Jain y col., 2001) son:

- *Máximo número de iteraciones*: el algoritmo se ejecuta hasta que supera el máximo número de iteraciones especificado.
- *Máximo tiempo de ejecución*: consiste en finalizar la búsqueda del algoritmo si éste supera el tiempo máximo establecido por el usuario.
- *Grado de avance del algoritmo*: el algoritmo se ejecuta hasta que no existe una mejoría notoria en la solución.

Habitualmente suelen adoptarse dos o más criterios de terminación con el fin de lograr una buena convergencia en un tiempo de ejecución adecuado. En este trabajo se implementó solamente el máximo número de iteraciones (igual a 2500) para que el PSO finalice su optimización. Esta selección se realizó en base a que en Damiani y col. (2020) se reportaron buenos resultados adoptando este método. Además, de esta manera el algoritmo se ejecuta la misma cantidad de veces en todos los casos de estudio, permitiendo una comparación más fehaciente de la performance o eficacia del algoritmo a igualdad de iteraciones.

Tamaño del enjambre (N)

Este factor tiene una gran influencia en la robustez y en los tiempos de ejecución del algoritmo. Generalmente, un enjambre muy pequeño suele ocasionar una convergencia local. Por otro lado, una población muy grande permite una mayor exploración del espacio de búsqueda, pero demanda mayor esfuerzo computacional, ya que la convergencia es más lenta. Es importante seleccionar convenientemente este parámetro para establecer un buen balance entre la exploración de nuevas regiones y la explotación en un sector particular.

Si bien algunos autores (Mussi y col., 2011) proponen un tamaño de población según la cantidad de variables del problema (por ejemplo $N = 10 + \sqrt{D}$), otros como Marini y Walczak (2015), indican que para una cantidad de partículas mayor a 50, el rendimiento del PSO suele ser insensible independientemente de la dimensión del problema. Para todos los casos a resolver en esta tesis se adoptó $N = 100$ lo que, sobre la base de nuestra propia experiencia, proporciona una adecuada exploración del espacio de búsqueda.

Posición inicial (x_{ij}^0)

La posición inicial de cada individuo que conforma el enjambre se originará aleatoriamente según una distribución uniforme (U) comprendida entre el límite inferior (x_{ij}^{lo}) y superior (x_{ij}^{up}) de cada variable (Ec. 3.5).

$$\mathbf{x} = x_{ij} = U(x_{ij}^{lo}, x_{ij}^{up}) \quad \forall i \in [1, N], \forall j \in [1, D] \quad (3.5)$$

Esta inicialización aleatoria permite que toda la población ocupe lo más uniformemente posible la región de búsqueda, favoreciendo la exploración, lo que contribuye a aumentar la probabilidad de que el algoritmo encuentre el óptimo global.

Velocidad inicial (v_{ij}^0)

Una forma intuitiva y popular de iniciar la velocidad es simplemente asignarle un valor aleatorio entre sus límites inferiores y superiores. No obstante, en esta tesis se decidió inicializar la velocidad en cero, ya que consideramos que con la Ec. 3.5 y el tamaño del enjambre se alcanza una distribución inicial satisfactoria de la población en la región factible.

Velocidad máxima (v_j^{max})

Este parámetro se establece para evitar que los individuos se alejen excesivamente de los límites explicitados por la caja ($x_j^{lo} \leq x_{ij} \leq x_j^{up}$). Por esta razón, la velocidad máxima definida por la Ec. 3.6, se incorpora al algoritmo con el fin de restringir la velocidad.

$$\begin{cases} \text{Si } v_{ij}^{k+1} > v_j^{max} \text{ entonces: } v_{ij}^{k+1} = v_j^{max} \\ \text{Si } v_{ij}^{k+1} < -v_j^{max} \text{ entonces: } v_{ij}^{k+1} = -v_j^{max} \end{cases} \quad \forall i \in [1, N], \forall j \in [1, D] \quad (3.6)$$

donde v_j^{max} es la velocidad máxima de la dimensión "j".

Los límites en la velocidad disminuyen las oscilaciones producidas por cada individuo que atraviese los límites de caja establecidos para cada variable. De esta manera, se evita explorar zonas muy lejanas a la región factible, mejorando la convergencia del PSO. A pesar de que no resulta fácil definir v_j^{max} , muchos autores la calculan según la Ec. 3.7.

$$v_j^{max} = 0,90 \frac{(x_j^{up} - x_j^{lo})}{2} \quad \forall j \in [1, D] \quad (3.7)$$

donde x_j^{up} es el límite superior de la partícula y x_j^{lo} el inferior.

Peso de inercia (w)

Este parámetro controla el movimiento de cada individuo, ya que modula el efecto de la velocidad previamente calculada, constituyendo parte del nuevo valor de la velocidad (Ec. 3.4). Junto con la velocidad máxima, el peso de inercia impide que el enjambre diverja. Si el valor de w es mayor a uno, se tiende más hacia la exploración global, mientras que, si es menor a uno, se favorece más a la explotación local.

Para establecer este factor también se han planteado diversas fórmulas (Marini y Walzac, 2015; Bansal y col., 2011). Muchos autores reportaron que con aquella que lo fija en un valor constante a lo largo de todas las iteraciones consiguieron muy buenos resultados en diversos modelos. Es por ello que en este trabajo se utilizó $w = 0,75$, comprobándose que alcanzaba una buena performance.

Factores r_{1ij} y r_{2ij}

Estos parámetros constituyen dos matrices de números aleatorios que presentan una distribución uniforme entre 0 y 1. En consecuencia, incorporan un componente estocástico a los términos cognitivo y social de la velocidad.

Constantes de aceleración (c_1 y c_2)

Ambas constantes regulan las contribuciones relativas de los componentes social y cognitivo de la velocidad, controlando cuánto se desplaza cada individuo del enjambre hacia esas soluciones. Según varios autores, cuando c_1 y c_2 toman valores pequeños, se forman patrones sinusoidales en el recorrido de las partículas. Se ha verificado que, para muchos problemas, se consiguen exploraciones eficientes cuando tanto c_1 como c_2 toman un valor de 1,50.

3.3. PSO: tratamiento de restricciones

La gran mayoría de los problemas de optimización poseen restricciones de igualdad y desigualdad que limitan la región factible. Sin embargo, las ecuaciones de actualización de posición (Ec. 3.3) y velocidad (Ec. 3.4) que describen al PSO no poseen un tratamiento explícito de las restricciones, debido a que tanto q como p se refieren implícitamente a soluciones factibles. Por lo tanto, para optimizar problemas con restricciones se han propuesto numerosos métodos para posibilitar su manipulación y mejorar la eficiencia del algoritmo en la localización de soluciones factibles.

Las restricciones de igualdad son mucho más complicadas de tratar porque producen una región factible más pequeña que las de desigualdad. Una forma de evitarlas consiste en utilizarlas para explicitar algunas variables en función de las restantes y de esa forma trabajar en un “espacio reducido”. Si bien esta técnica es muy efectiva cuando es posible aplicarla, involucra la reformulación del problema original (Damiani y col., 2020).

En el último tiempo, las técnicas para tratar restricciones cobraron mucha importancia en el campo de la optimización global estocástica. Una revisión de las metodologías más utilizadas para este propósito en algoritmos evolutivos se proporciona en Miranda-Varela y Mezura-Montes (2018). Entre los métodos más populares se encuentran los que separan los objetivos de las restricciones, los de penalización, los algoritmos de reparación y los que poseen representaciones y operadores especiales. En el PSO se puede incorporar la gran mayoría de ellas sin dificultades especiales.

Cada una de las metodologías cuenta con sus ventajas y desventajas siendo, en general, muy eficientes para una cierta gama de problemas y poco para otras. El desafío consiste en seleccionar un enfoque que sea lo más general posible y produzca buenos resultados para la familia de problemas abordada.

Una de las técnicas más populares es aquella que tiene en cuenta una función de penalidad, debido a que resulta muy intuitiva y es sencilla de implementar. La misma consiste en transformar un problema de optimización con restricciones en uno no restringido al añadir a

la función objetivo un término de penalidad que depende de la magnitud y el número de violaciones a las restricciones presentes. Sin embargo, este método cuenta con la desventaja de tener que optar por un “peso” adecuado para las penalizaciones. Dicha elección no es fácil ni universal, por lo tanto, el “peso óptimo” resulta ser problema-dependiente.

En esta tesis se decidió adoptar el método de Zhang y Rangaiah (2012) para manipular las restricciones del PSO. Estos autores proponen una técnica muy práctica, que evita la reformulación o reducción de restricciones y es mucho menos dependiente de la elección de nuevos parámetros.

Zhang y Rangaiah (2012) plantean agrandar temporalmente la región factible al relajar las restricciones de igualdad y desigualdad (Fig. 3.3). A medida que las partículas comienzan a ingresar a esa región relajada, ésta empieza a disminuir hasta convertirse en la región factible original, es decir, la que tiene en cuenta todas las restricciones del problema original.

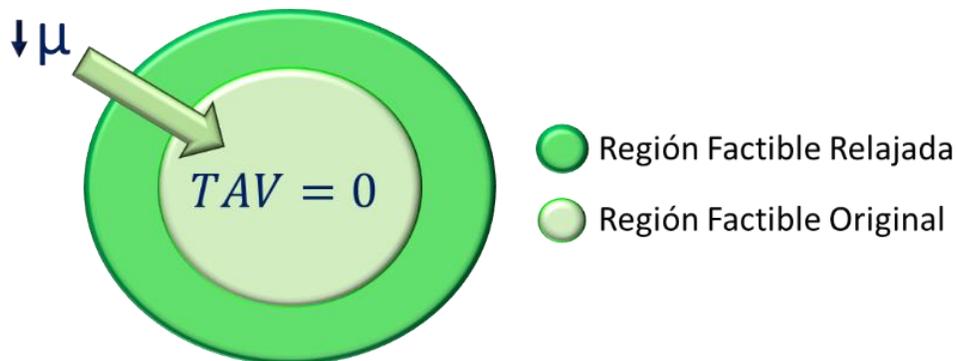


Fig. 3.3: Relajación de la región factible para el tratamiento de restricciones

Esta técnica incorpora la variable TAV (Violación Absoluta Total, por sus siglas en inglés) que integra las violaciones a las restricciones de cada partícula (Ec. 3.8). Es importante mencionar que TAV trata como restricciones de desigualdad los límites mínimos y máximos de cada variable del problema, es decir, las restricciones “de caja”.

$$TAV_i = \sum_{s=1}^{m_1} |h_s(\mathbf{x})| + \sum_{s=1}^{m_2} \max(0, g_s(\mathbf{x})) + \sum_{j=1}^D \max(0, (x_j^{lo} - x_{ij}^k)) + \sum_{j=1}^D \max(0, (x_{ij}^k - x_j^{up})) \quad \forall i \in [1, N], \forall j \in [1, D] \quad (3.8)$$

donde $h_s(\mathbf{x})$ representa las restricciones de igualdad; m_1 es la cantidad total de restricciones de igualdad; $g_s(\mathbf{x})$ son las restricciones de desigualdad; m_2 es la cantidad total de restricciones de desigualdad; x_j^{lo} y x_j^{up} son el límite inferior y superior respectivamente, en la dimensión “j”.

Una solución es temporalmente factible si el TAV de ese individuo es menor que un dado valor de relajación de las restricciones (μ) en la iteración k . Es decir, si $TAV_i < \mu^k$, la solución se considera factible a los fines de la exploración. De esta forma, esta técnica para el manejo de restricciones permite que la población se dirija progresivamente hacia la región factible, favoreciendo la exploración del espacio de búsqueda al admitir violaciones transitorias de las restricciones.

Si bien existen diversas maneras de definir μ , en esta tesis se implementó la Ec. 3.9 en base a una versión modificada de la ecuación presentada por Zhang y Rangaiah (2012). Según dicha ecuación, el valor de este parámetro va disminuyendo dinámicamente según la cantidad de partículas que se consideran factibles (F_F) respecto de la población total del enjambre (N).

$$\mu^{k+1} = \mu^k \left(1 - \frac{F_F}{N}\right) \quad (3.9)$$

Con el fin de establecer qué partícula reemplazará al mejor global y al mejor local en cada iteración del PSO, según el criterio de factibilidad comentado, se establece que:

- Una solución factible es preferible a una infactible.
- Entre dos soluciones factibles, aquella que alcanzó un mejor valor de la función objetivo es la preferida.
- Entre dos soluciones infactibles, se selecciona la que posee menor TAV_i .

La elección de este tratamiento se debió principalmente a su generalidad e independencia de parámetros de ajuste.

En conclusión, para desarrollar la herramienta de optimización básica para este trabajo de investigación, el PSO planteado por Marini y Walczak (2015), se tomó como base para la implementación propia del optimizador. El mismo se modificó de acuerdo a la técnica de manejo de restricciones ya comentada de Zhang y Rangaiah (2012) con algunas modificaciones.

La implementación del PSO se testeó optimizando diferentes funciones *benchmark* de distinta complejidad, típicamente utilizadas en estudios de optimización estocástica, para evaluar el rendimiento de este tipo de algoritmos (Damiani y col., 2020). El set de problemas se componía de diversos modelos con distintos números de ecuaciones y variables, diferentes tipos de no linealidades, y restricciones de distinta dificultad.

Los resultados obtenidos indican un buen rendimiento general en todos los problemas investigados. En la mayor parte de los casos, se alcanzó el óptimo global, mientras que en los restantes se lograron soluciones subóptimas factibles.

3.4. PSO: tratamiento de variables binarias

Existen muchos métodos para resolver problemas con variables binarias empleando metaheurísticas. Crawford y col. (2017) los clasificaron en dos grandes grupos: (i) binarización en dos pasos y (ii) transformación de los operadores continuos a binarios. El primer grupo permite trabajar con la metaheurística continua sin necesidad de modificar los operadores, sólo le agrega un par de pasos a cada iteración para transformar la solución continua en una binaria. Por el contrario, la otra categoría comprende aquellas metodologías que deben redefinir el espacio de búsqueda, reformulando así sus operadores.

Una técnica muy utilizada, que pertenece al primer grupo de la clasificación mencionada, es la de redondeo genérico. Es muy popular debido a su simplicidad y bajo costo computacional. Como el nombre lo indica, la misma consiste en relajar la variable binaria durante la

optimización y redondear el valor final al entero más cercano. Este enfoque tiene la ventaja de que solo es necesario agregar a la metaheurística elegida una etapa de redondeo, que puede realizarse en cada iteración o al final de la optimización. Sin embargo, la desventaja de esta técnica es que puede suceder que, al momento de redondear la solución, ésta pase de ser factible a infactible.

Para evitar dicho inconveniente, en esta tesis se optó por implementar la técnica “Angle Modulation”, propuesta por Pampara y col. (2005), que también pertenece al primer grupo. Se la eligió debido a su sencillez y facilidad para ser incorporada al PSO, así como también por su aplicación exitosa, reportada sobre problemas de diferente dificultad.

Este método utiliza el PSO para optimizar cuatro coeficientes en el espacio continuo que luego, al introducirse en una función trigonométrica simple (Ec. 3.10), genera la solución al problema binario original.

Con esta metodología se optimiza un problema continuo de solo cuatro variables, sencillo de resolver, en vez de abordar el problema binario original con la complejidad combinatoria asociada.

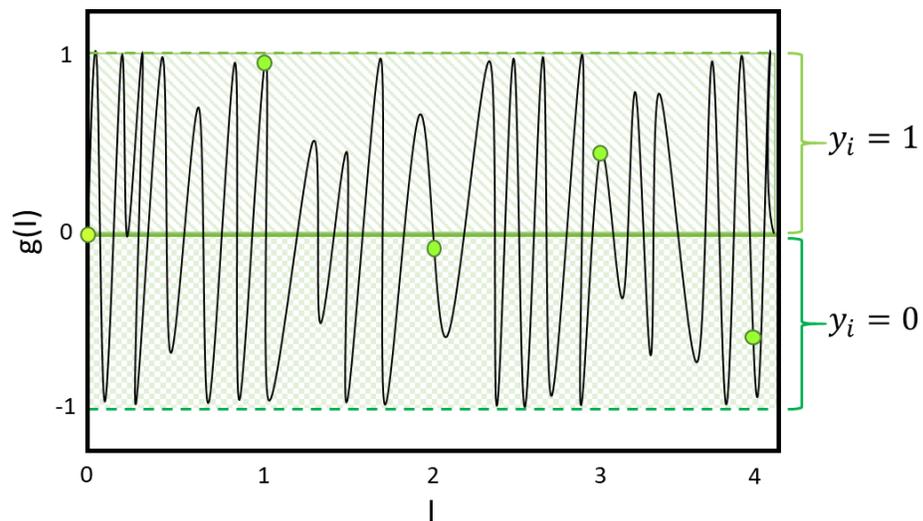
$$g(I) = \sin(2\pi(I - a) \times b \times \cos(A)) + d \quad \text{donde } A = 2\pi \times c(I - a) \quad (3.10)$$

Los coeficientes a, b, c, d son los valores continuos a optimizar que controlan la forma de la función sinusoidal $g(I)$: a controla el desplazamiento horizontal de toda la función, b influye en la frecuencia de onda del sin y del cos amplificada, c afecta la frecuencia de onda del cos y d controla el desplazamiento vertical de $g(I)$. I es un intervalo que se divide en tantos subintervalos regulares como cantidad de variables binarias (n_b) sean requeridas.

En cada iteración, el PSO propuesto manipula todas las variables continuas del modelo, las propias del problema a resolver más los cuatro coeficientes de la función trigonométrica con los que luego se calcula $g(I)$ (Ec. 3.10). A partir de $g(I)$ se puede determinar el valor de cada variable binaria y_i según la relación dada por la Ec. 3.11.

$$\begin{cases} \text{Si } g(I_i) > 0 \rightarrow y_i = 1 \\ \text{Si } g(I_i) \leq 0 \rightarrow y_i = 0 \end{cases} \quad \forall i \in [1, n_b] \quad (3.11)$$

Por ejemplo, en la Fig. 3.4 se representa la solución de un problema que consta de 5 variables binarias. El optimizador determina a, b, c y d . Luego, con estos valores y a través de la Ec. 3.10, se establece $g(I)$: $g(0) = 0, g(1) = 0,95, g(2) = -0,10, g(3) = 0,40$ y $g(4) = -0,35$. Con estos valores, es posible especificar las variables binarias Y_i de acuerdo a si $g(I_i)$ resulta mayor o menor e igual a cero (Ec. 3.11): $y_0 = 0$ ($g(0) \leq 0$), $y_1 = 1$ ($g(0) > 0$), $y_2 = 0$ ($g(0) \leq 0$), $y_3 = 1$ ($g(0) > 0$) e $y_4 = 0$ ($g(4) \leq 0$).



Solución: $y_0 = 0$ $y_1 = 1$ $y_2 = 0$ $y_3 = 1$ $y_4 = 0$

Fig. 3.4: Función generada para valores específicos de a, b, c, d

En conclusión, la técnica “Angle Modulation” proporciona una forma sencilla de generar conjuntos arbitrariamente grandes de variables binarias de manera compatible con la mecánica de un optimizador de variables continuas como lo es PSO. A su vez, la función sinusoidal permite ir preservando una cierta “memoria” de aquellas soluciones más

promisorias a lo largo de la búsqueda. Estas razones la convierten en una alternativa atractiva para optimizar los modelos de simulación que motivan este trabajo.

3.5. PSO: tratamiento de múltiples objetivos

Al igual que para el tratamiento de binarias, en este caso también existe una amplia variedad de métodos para resolver problemas multiobjetivo (Ngatchou y col., 2005) entre los que se destacan los que combinan todos los objetivos en uno solo, aquellos que le asignan distintas prioridades a cada objetivo y los que se basan en la eficiencia de la curva de Pareto.

Tradicionalmente, la técnica multiobjetivo más usada debido a su sencillez consiste en agregar todos los objetivos ponderados en una sola función objetivo. De esta manera, el problema vuelve a ser mono-objetivo y su solución es única. Sin embargo, de esta forma, el programador debe establecer, más o menos arbitrariamente, qué peso tendrá cada uno de los objetivos en la función combinada.

Otra opción es resolver el problema multiobjetivo manteniendo una única función objetivo que represente a uno de los criterios, mientras que los restantes se tratan como restricciones en el modelo. En este caso, el programador debe definir qué objetivo se optimizará y cuáles tratará como restricciones.

Para evitar algunas de las desventajas de los métodos anteriores se han desarrollado metodologías alternativas para tratar múltiples objetivos en conflicto (Ngatchou y col., 2005). Una familia de métodos se basa en que el algoritmo de optimización encuentre y exponga muchas de las soluciones pertenecientes a la región donde al mejorar uno de los objetivos empeoran los restantes. De esta manera, el usuario puede observar, evaluar y comparar las diferentes soluciones y decidir cuál de ellas aceptar, según su conocimiento, al priorizar en ese momento cierto objetivo en detrimento de los demás (Selçuklu y col., 2020).

Dicha frontera, denominada frente de Pareto, representa un conjunto de soluciones, cada una de las cuales es mejor que las restantes en al menos uno de los objetivos optimizados. Este

frente es una curva en caso de problemas de optimización bi-objetivo y una superficie en caso de problemas tri-objetivo (Harkouss y col., 2018).

Dado que esta técnica permite sistematizar en gran medida el procedimiento de cálculo reduciendo a la vez la subjetividad y arbitrariedad en el tratamiento de los diferentes objetivos, se decidió implementarla en esta tesis. Además, contar con una “lista” de posibles soluciones de diferentes características se entiende como un resultado más compatible con el problema de MIM que se aborda en esta tesis, que el hecho de proporcionar simplemente una única solución “óptima” de acuerdo a algún objetivo combinado de difícil interpretación.

Para poder establecer el frente de Pareto, es necesario primero definir los términos “soluciones dominadas” y “soluciones no dominadas”, los cuales se utilizan para ordenar las distintas soluciones encontradas.

Se dice que una solución S_1 domina a otra solución S_2 si se satisfacen dos condiciones (en problemas de minimización de todos los objetivos):

- La solución S_1 no es peor que S_2 en todos los objetivos. Es decir, se debería cumplir que: $f_k(S_1) \leq f_k(S_2)$ para todo $k = \{1 \dots N_{FO}\}$.
- La solución S_1 es estrictamente mejor que S_2 al menos en un objetivo. Esto quiere decir que $f_k(S_1) < f_k(S_2)$ para al menos un objetivo $k = \{1, \dots, N_{FO}\}$.

En otras palabras, esta definición indica que la solución S_1 se considera un óptimo de Pareto si es igualmente buena en todos los objetivos y mejor en al menos uno de ellos. De esta manera, entre dos soluciones existen tres posibilidades:

- S_1 domina a S_2 ;
- S_1 es dominada por S_2 ;
- S_1 y S_2 son no dominadas entre sí.

Por ejemplo, en la Fig. 3.5 se representa un problema de minimización de dos objetivos con cuatro soluciones (S_1, S_2, S_3 y S_4). La solución S_4 empeora en los dos objetivos con respecto a S_2 , por eso se considera que S_4 es dominada por S_2 o que S_2 domina a S_4 . En cambio, S_1 mejora en la Función Objetivo 2 con respecto a S_2 , pero empeora con respecto a la Función Objetivo 1, por eso nada se puede decir acerca de si S_1 domina a S_2 o viceversa, por lo cual estas

soluciones son no dominadas entre sí. Lo mismo ocurre con S_3 . Por estas razones, el frente de Pareto se conforma por las soluciones no dominadas S_1 , S_2 y S_3 (sin tener en cuenta a S_4 dado que es dominada por S_2).

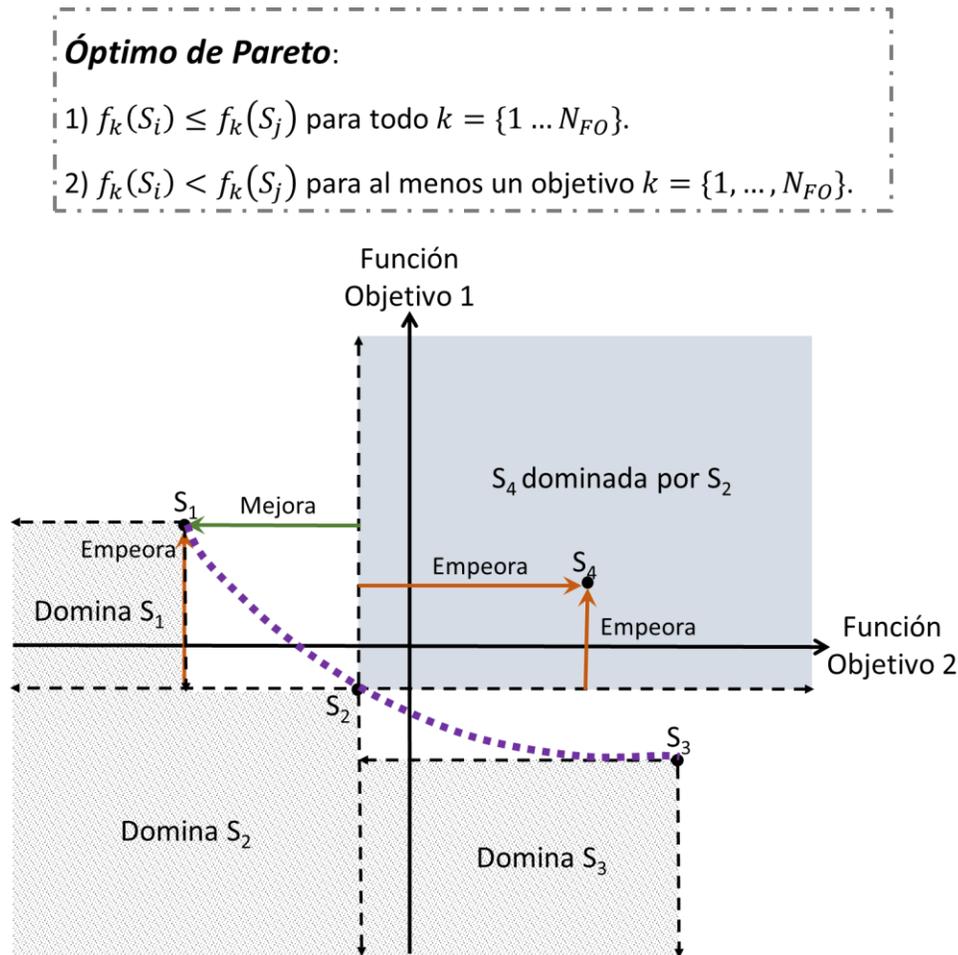


Fig. 3.5: Soluciones dominadas y no dominadas: conformación del frente de Pareto

Las características del PSO, en particular el hecho de que va desplegando una población de soluciones en cada iteración, lo vuelve idóneo para implementar la técnica de frontera de Pareto sin requerir grandes esfuerzos de programación adicionales. De esta manera es posible aumentar su campo de aplicación para resolver problemas de múltiples objetivos.

Una vez que el PSO identifica las soluciones no dominadas de acuerdo a las consideraciones establecidas en la sección anterior, éstas se almacenan en un archivo externo (A). Sin embargo, es necesario limitar la cantidad de soluciones que puede contener ese archivo para que no crezca indefinidamente, consuma excesiva memoria o enlentezca la optimización. La dimensión de A es especificada por el usuario, pero se requiere un criterio para determinar qué soluciones se descartan.

Comúnmente, la metodología más utilizada para ordenar las soluciones del archivo externo es la que considera la distancia de hacinamiento que existe entre ellas (Raquel y Naval, 2005). Esta técnica prioriza las soluciones más representativas de cada sector del frente de Pareto para lograr la mayor diversidad, mediante la eliminación de las soluciones que se encuentran más agrupadas.

El cálculo de la distancia de hacinamiento (dh) se basa en el pseudocódigo de la Fig. 3.6. En primer lugar, se obtiene la cantidad de soluciones no dominadas presentes en el archivo externo y se inicializa la distancia de hacinamiento en cero. Posteriormente, se clasifica el conjunto de soluciones según valores de función objetivo en orden ascendente. Luego, se establece el valor de dh como la distancia promedio entre las dos soluciones vecinas. A las soluciones límite, que son aquellas que tienen el menor y mayor valor de la función objetivo, se les asigna, arbitrariamente, un valor infinito en la distancia de hacinamiento para que siempre queden seleccionadas. Este proceso se realiza para cada función objetivo del problema de optimización. Finalmente, se calcula el valor de la distancia de hacinamiento de cada solución, como la suma de todos los dh de cada función objetivo.

Una vez obtenida la distancia de hacinamiento para cada partícula, se las ordena de mayor a menor en el archivo externo A . Si resulta que éste supera el límite de partículas establecido, entonces se eliminan tantas soluciones de la parte inferior de A como sea necesario para cumplir con la dimensión especificada para éste. De esta manera, sólo permanecen las partículas que mayor diversidad aportan, en cuanto a su valor en las funciones objetivo.

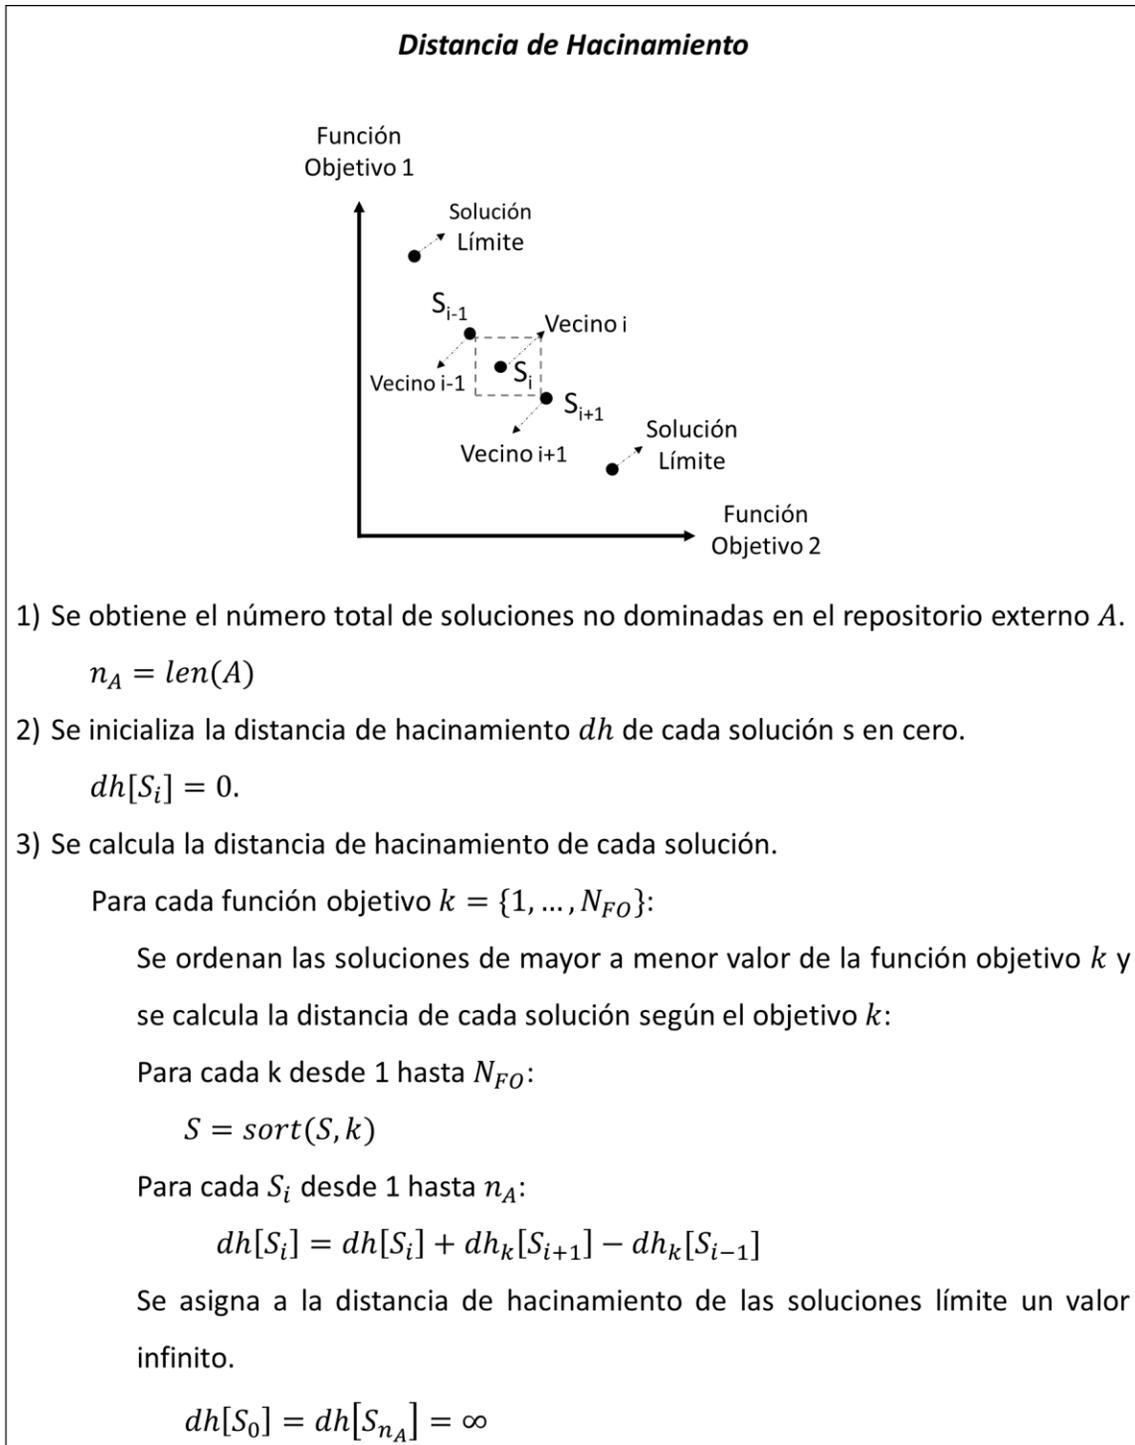


Fig. 3.6: Pseudocódigo del cálculo de la distancia de hacinamiento

Cabe recordar que el mejor global (q) en el PSO original representa el mejor valor alcanzado por todo el enjambre. Sin embargo, en una optimización multiobjetivo, no existe una única solución a seguir, y q podría tomar el valor de cualquiera de las soluciones no dominadas guardadas en A . Como ya se comentó, la selección del mejor global es un paso muy importante del algoritmo, ya que afecta su capacidad de convergencia. Cuando se tiene más de un objetivo, la selección del mejor global también influye en la diversidad de soluciones no dominadas que se encuentran.

Raquel y Naval (2005) proponen seleccionar el mejor global entre las soluciones no dominadas que posean los valores más altos de distancia de hacinamiento, de esta manera se promueve el movimiento del enjambre hacia los puntos más dispersos entre sí. Además, para asegurar dicho esparcimiento entre las soluciones, estos autores plantean que se elijan diferentes guías. Para ello, cada partícula asigna a q una de las soluciones elegidas aleatoriamente dentro del 10% de las que conforman la parte superior del archivo externo (una vez que éste ya se ordenó de mayor a menor dh). De esta manera, se logra que la búsqueda sea conducida por aquellas soluciones que se encuentren en el área menos concurrida del espacio objetivo.

Por otro lado, para determinar el mejor local (p) sólo es necesario comparar la nueva solución encontrada en esa iteración (x) con la guardada en p . Si x domina a p , entonces se actualiza el mejor local, si no, mantiene su valor.

3.6. Implementación propia del algoritmo PSO MINLP-MO

El algoritmo desarrollado en esta tesis se estableció de acuerdo al PSO básico introducido anteriormente (sección 3.2), al que se le incorporó la técnica de manejo de restricciones también explicada (sección 3.3). Para ello, fue necesario adicionar el cálculo de TAV , que representa la magnitud de las violaciones a las restricciones de cada solución encontrada por cada partícula del enjambre. Este índice es evaluado en el mismo momento que la función objetivo.

Luego, se anexó a este PSO la metodología de “Angle Modulation” (sección 3.4) para poder resolver problemas con variables binarias (\mathbf{y}). Como se comentó oportunamente, independientemente de la cantidad de variables binarias que se encuentre presente en el modelo a optimizar, esta técnica sólo suma 4 variables continuas (\mathbf{x}) al problema y un paso más al esquema del PSO. Ese nuevo paso se corresponde con la actualización de las variables binarias, basada en la determinación de la función trigonométrica $g(I)$ y su correspondiente relación con la asignación de valores a cada variable binaria (y_i).

Por último, con el fin de tratar problemas multiobjetivo se incorporó la propuesta descrita en la sección 3.5, basada en la identificación de la frontera de Pareto. La misma añade un eslabón más de cálculo al PSO, ya que se deben determinar cuáles son las soluciones no dominadas del enjambre y ordenarlas de mayor a menor distancia de hacinamiento en el archivo externo A . Asimismo, esta técnica influye en la identificación del mejor local (\mathbf{p}) y el mejor global (\mathbf{q}), debido a que ahora no sólo su elección se basa en el criterio de factibilidad, sino también en el de no dominancia de las soluciones.

En la Fig. 3.7 se muestra un diagrama de flujo que integra todos los elementos descritos en esta implementación propia del PSO, la cual permite abordar problemas MINLP multiobjetivo con restricciones. A su vez, En la Fig. 3.8 se proporciona el pseudocódigo correspondiente.

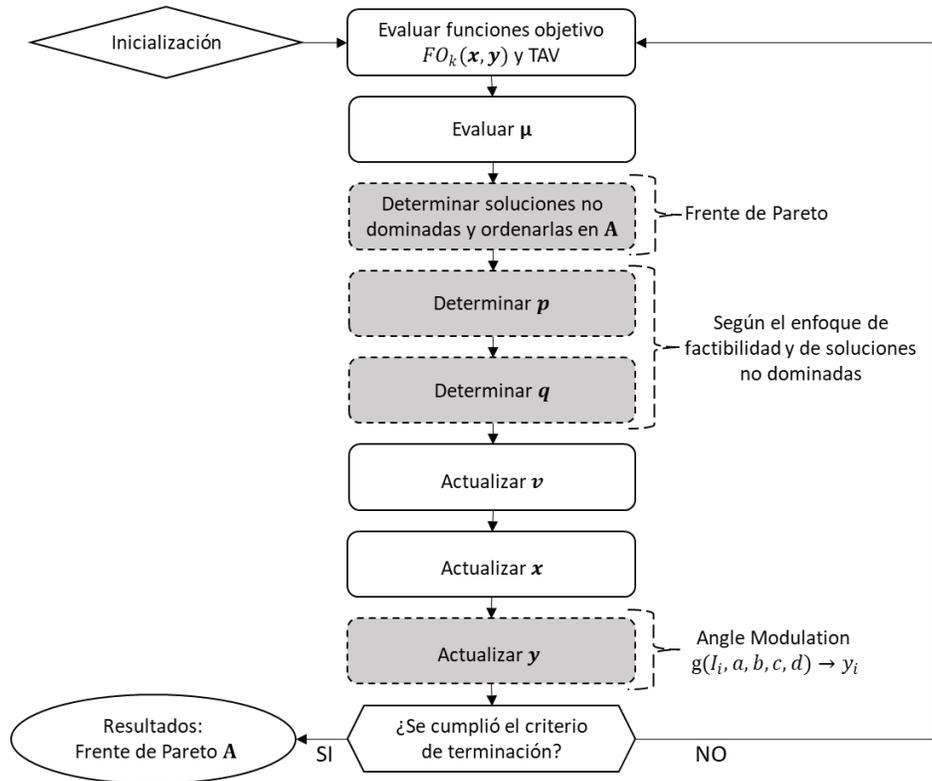


Fig. 3.7: Esquema del PSO con variables continuas, binarias y multiobjetivo

1. Inicialización de cada partícula del enjambre:
 - a. Inicializar la posición aleatoriamente: $x_{ij}^0 = U(x_{ij}^{lo}, x_{ij}^{up})$ donde $x_{ij}^0 = [a, b, c, d, x_1, \dots, x_D]$
 - b. Calcular $g(I_i) = \sin(2\pi(I_i - a) \times b \times \cos(A)) + d$, donde $A = 2\pi \times c(I_i - a)$.
 - c. Determinar las variables binarias: $\left\{ \begin{array}{l} Si \ g(I_i) > 0 \rightarrow y_i = 1 \\ Si \ g(I_i) \leq 0 \rightarrow y_i = 0 \end{array} \right\} \forall i \in [1, n_b]$
 - d. Inicializar la velocidad en cero: $v_{ij}^0 = 0$
 - e. Inicializar la mejor posición local: $p_{ij}^0 = x_{ij}^0$.
 - f. Calcular el valor de la función $f_{N_{obj}}(x_i)$ y de $TAV_i(x_i)$.
 - g. Determinar las soluciones no dominadas del óptimo de Pareto: S_i .
 - h. Ordenar S_i según su dh en orden decreciente.
 - i. Almacenar S_i en el archivo externo A .
 - j. Determinar el mejor global: $q_i = U(10\%A)$.
 - k. Calcular el valor de relajación inicial: $\mu^0 = Promedio(TAV)$.
2. Repetir hasta que se cumpla el/los criterios de terminación elegidos:
 - a. Actualizar la velocidad de cada partícula:

$$v_{ij}^{k+1} = w^k v_{ij}^k + c_1 r_{1ij} (p_{ij}^k - x_{ij}^k) + c_2 r_{2ij} (q_j - x_{ij}^k)$$
 - b. Actualizar la posición de cada partícula:

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1}$$
 - c. Calcular $g(I_i) = \sin(2\pi(I_i - a) \times b \times \cos(A)) + d$, donde $A = 2\pi \times c(I_i - a)$.
 - d. Determinar las variables binarias: $\left\{ \begin{array}{l} Si \ g(I_i) > 0 \rightarrow y_i = 1 \\ Si \ g(I_i) \leq 0 \rightarrow y_i = 0 \end{array} \right\} \forall i \in [1, n_b]$
 - e. Evaluar el valor de las funciones objetivo $f_{N_{obj}}(x_i^{k+1})$ y de $TAV_i(x_i^{k+1})$.
 - f. Determinar las soluciones no dominadas del óptimo de Pareto: S_i .
 - g. Ordenar S_i según su dh en orden decreciente.
 - h. Almacenar S_i en el archivo externo A .
 - i. Evaluar el valor de relajación: $\mu^{k+1} = \mu^k \left(1 - \frac{FF}{N}\right)$,
 - j. Actualizar el mejor local: $p_{ij} = x_{ij}^{k+1}$.
 - k. Actualizar el mejor global: $q_i = U(10\%A)$.
3. Frente Pareto = A .

Fig. 3.8: Pseudocódigo del PSO con variables continuas, binarias y multiobjetivo

Por su parte, en la Fig. 3.9 se muestra un esquema de los datos necesarios para optimizar un cierto problema, detallando las herramientas de programación utilizadas (Python y Excel). Para ello es necesario que se especifiquen tanto los parámetros de cada modelo a optimizar, como los correspondientes al PSO propiamente dicho.

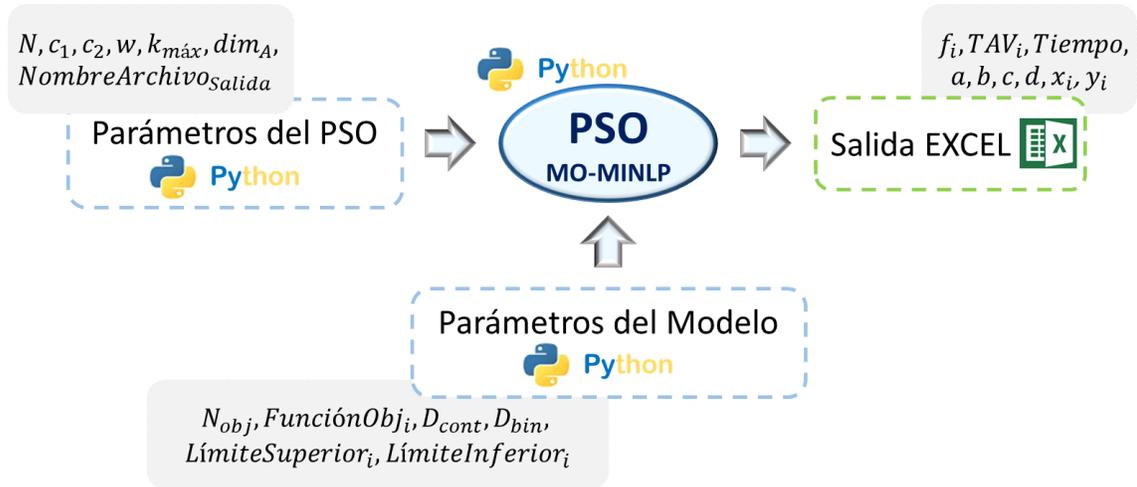


Fig. 3.9: Esquema ingreso/salida PSO

Los primeros son propios de cada problema, debiendo explicitarse el número de funciones objetivo (N_{obj}), la ecuación matemática de cada una de ellas ($Funci\acute{o}nObj_i$), las variables continuas (D_{cont}) y binarias (D_{bin}), así como los límites inferiores y superiores de las primeras ($L\acute{i}miteInferior_i$ y $L\acute{i}miteSuperior_i$).

Los parámetros del PSO son establecidos por el usuario al momento de optimizar el modelo. De esta manera, se brinda cierta flexibilidad a la optimización, ya que se pueden realizar distintas pruebas modificando cualquiera de estos valores para mejorar la eficiencia del algoritmo. En este caso, el usuario debe fijar la cantidad de partículas que componen el enjambre (N), las constantes de aceleración (c_1 y c_2), el peso de inercia (w), el número de iteraciones máximas ($k_{m\acute{a}x}$), la dimensión del archivo externo A (dim_A) y el nombre del archivo Excel ($NombreArchivoSalida$) en donde se volcarán los resultados de la optimización. Como

se mencionó oportunamente, todos estos parámetros poseen valores por defecto que fueron seleccionados como adecuados sobre la base de múltiples experimentos realizados.

Se decidió que los resultados del PSO se resuman en una planilla Excel, ya que es una herramienta muy práctica y conocida, con la cual pueden realizarse distintos análisis. Este archivo muestra el valor de las funciones objetivo (f_i), de la violación a las restricciones (TAV_i), de las constantes de la función trigonométrica (a, b, c, d) y de las variables continuas (x_i) y binarias (y_i) de cada solución presente en el archivo externo A que conforma el frente de Pareto. Asimismo, también se registra el tiempo total ($Tiempo$) que tarda el optimizador en realizar el número máximo de iteraciones fijado por el usuario.

3.7. Testeo del PSO

Como ya se mencionó, la implementación del PSO continuo con tratamiento de restricciones descrita en este capítulo se testeó en trabajos previos (Damiani y col., 2020) optimizando diversas funciones *benchmark* muy utilizadas en estudios de optimización estocástica. Estos problemas cuentan con diferentes números de ecuaciones y variables, algunos poseen no linealidades, múltiples soluciones y restricciones de igualdad y/o desigualdad de distinta dificultad. Se concluyó que el optimizador logra un buen rendimiento general en los problemas con y sin restricciones, alcanzando soluciones factibles en todos los casos y, en general, el óptimo global reportado en la literatura.

Para evaluar el rendimiento del PSO respecto de la identificación de la frontera de Pareto, se tomaron ocho problemas NLP pequeños, habitualmente utilizados en la bibliografía en estudios multiobjetivo, los cuales cuentan con dos o tres funciones objetivo y distintas restricciones. Este análisis se presenta a continuación. Para establecer la calidad de la solución encontrada, se optó por realizar una comparación gráfica entre los frentes de Pareto obtenidos con nuestro optimizador y el reportado en la literatura.

En todos los casos, se utilizaron los siguientes parámetros del PSO: cantidad de partículas (N) = 100, constante de aceleración cognitiva (c_1) = 1,5, constante de aceleración social (c_2) = 1,5, peso de inercia (w) = 0,75, iteraciones máximas ($k_{m\acute{a}x}$) = 5000 y la dimensión del archivo externo A (dim_A) = 100.

A continuación, se describen cuatro problemas con dos funciones objetivo: MO1 (Binh y Korn,1997), MO2 (Chankong y Haimes, 2008), MO3 (Schaffer, 1984) Y MO4 (Schaffer, 1984). Para cada uno de ellos se presenta su formulación, el frente de Pareto obtenido de la literatura (indicado con rombos celestes) y el hallado por el PSO propio (marcado con círculos verdes).

MO1

Minimizar:

$$f_1 = 4x_1^2 + 4x_2^2$$

$$f_2 = (x_1 - 5)^2 + (x_2 - 5)^2$$

St:

$$g_1 = (x_1 - 5)^2 + x_2^2 - 25 \leq 0$$

$$g_2 = -(x_1 - 8)^2 - (x_2 + 3)^2 + 7,7 \leq 0$$

$$0 \leq x_1 \leq 5, 0 \leq x_2 \leq 3$$

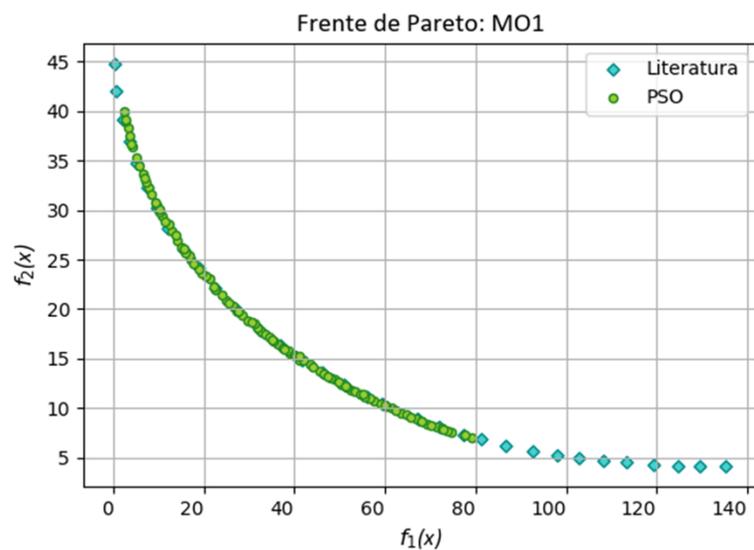


Fig. 3.10: Frente de Pareto MO1 literatura vs PSO

MO2

Minimizar:

$$f_1 = 2 + (x_1 - 2)^2 + (x_2 - 1)^2$$

$$f_2 = 9x_1 - (x_2 - 1)^2$$

St:

$$g_1 = x_1^2 + x_2^2 - 225 \leq 0$$

$$g_2 = x_1 - 3x_2 + 10 \leq 0$$

$$-20 \leq x_1, x_2 \leq 20$$

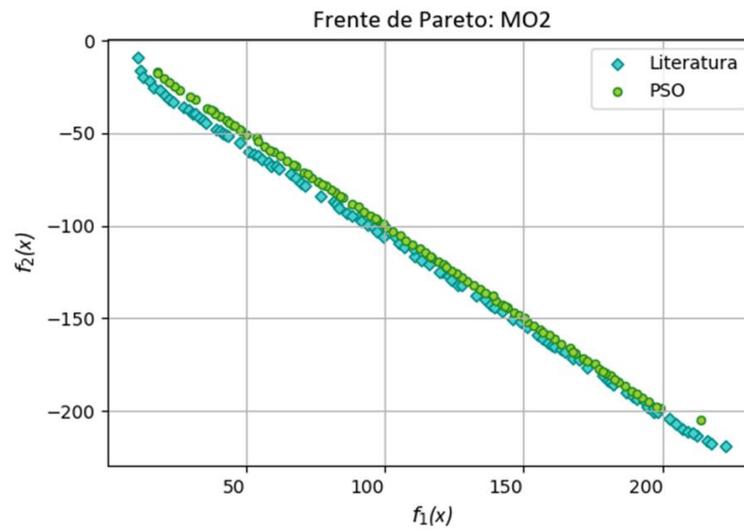


Fig. 3.11: Frente de Pareto MO2 literatura vs PSO

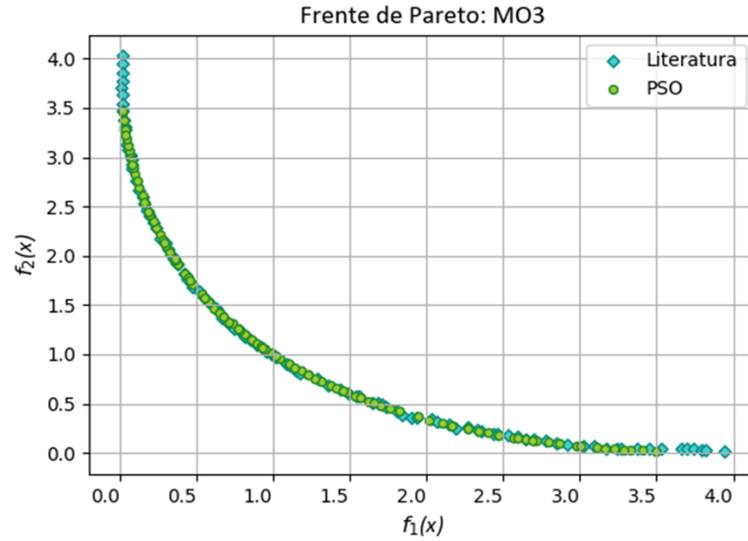
MO3

Minimizar:

$$f_1 = x_1^2$$

$$f_2 = (x_1 - 2)^2$$

$$-100 \leq x_1 \leq 100$$



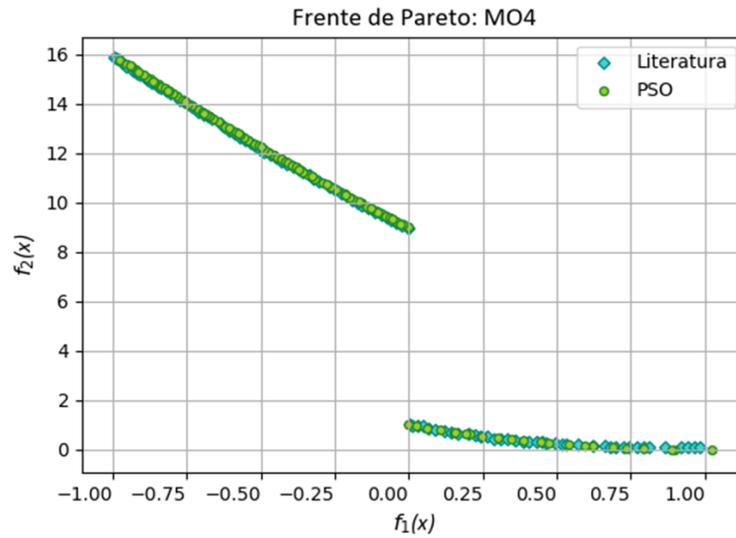
MO4

Minimizar:

$$f_1 = \begin{cases} -x_1 & \text{si } x_1 \leq 1 \\ x_1 - 2 & \text{si } 1 < x_1 \leq 3 \\ 4 - x_1 & \text{si } 3 < x_1 \leq 4 \\ x_1 - 4 & \text{si } x_1 > 4 \end{cases}$$

$$f_2 = (x_1 - 5)^2$$

$$-5 \leq x_1 \leq 10$$



Los problemas definidos a continuación poseen tres funciones objetivo: MO5 (Coello y col., 2007), MO6 (Coello y col., 2007), MO7 (Kaveh y Mahdavi, 2019) Y MO8 (Kaveh y Mahdavi, 2019). En estos casos se compara el frente de Pareto, reproducido por medio de un gráfico de dispersión, de los resultados extraídos de la bibliografía (izquierda) con los obtenidos de la optimización con el PSO MINLP-MO (derecha).

MO5

Minimizar:

$$f_1 = \frac{(x_1 - 2)^2}{2} + \frac{(x_2 + 1)^2}{13} + 3$$

$$f_2 = \frac{(x_1 + x_2 - 3)^2}{36} + \frac{(-x_1 + x_2 + 2)^2}{8} - 17$$

$$f_3 = \frac{(x_1 + 2x_2 - 1)^2}{175} + \frac{(2x_2 - x_1)^2}{17} - 13$$

$$-400 \leq x_1, x_2 \leq 400$$

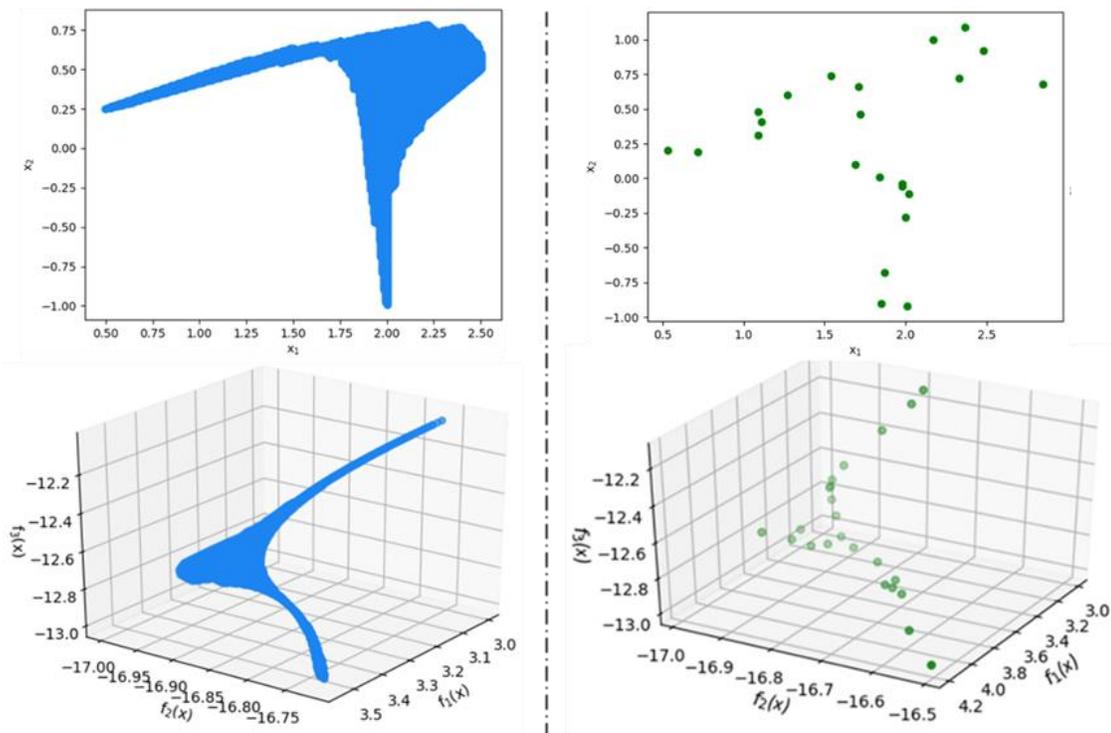


Fig. 3.14: Frente de Pareto MO5 literatura vs PSO

MO6

Minimizar:

$$f_1 = 0,5(x_1^2 + x_2^2) + \text{sen}(x_1^2 + x_2^2)$$

$$f_2 = \frac{(3x_1 - 2x_2 + 4)^2}{8} + \frac{(x_1 - x_2 + 1)^2}{27} + 15$$

$$f_3 = \frac{1}{(x_1^2 + x_2^2 + 1)} - 1,1e^{(-x_1^2 - x_2^2)}$$

$$-30 \leq x_1, x_2 \leq 30$$

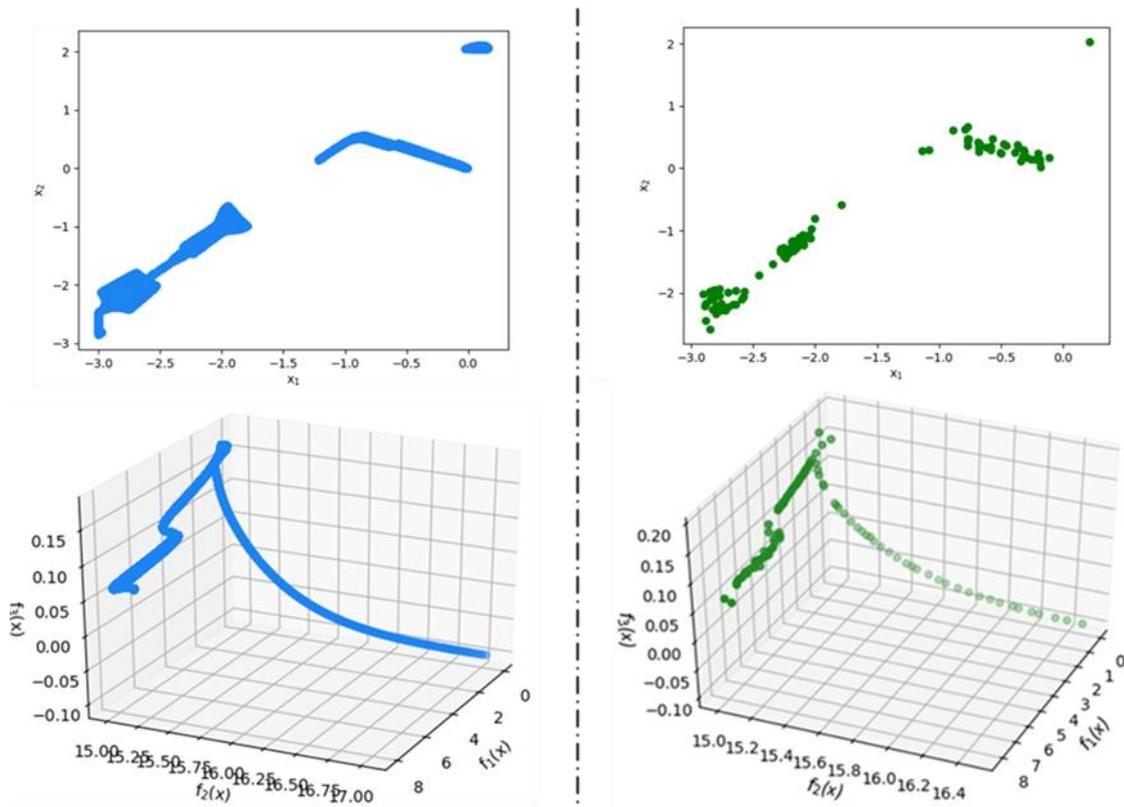


Fig. 3.15: Frente de Pareto MO6 literatura vs PSO

MO7

Minimizar:

$$f_1 = (1 + m) \cos(x_1(\pi/2)) \cos(x_2(\pi/2))$$

$$f_2 = (1 + m) \cos(x_1(\pi/2)) \text{sen}(x_2(\pi/2))$$

$$f_3 = (1 + m) \text{sen}(x_1(\pi/2))$$

$$m = \sum_{j=3}^{j=12} (x_j - 0,5)^2$$

$$0 \leq x_j \leq 1 \quad j = 1, 2, 3 \dots 12$$

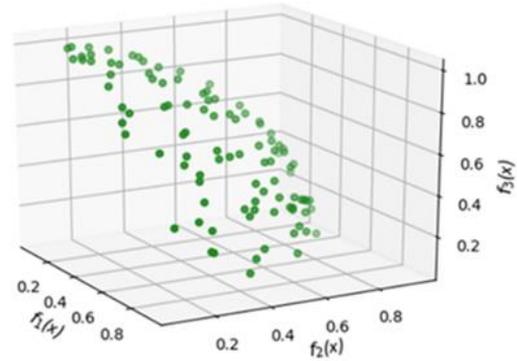
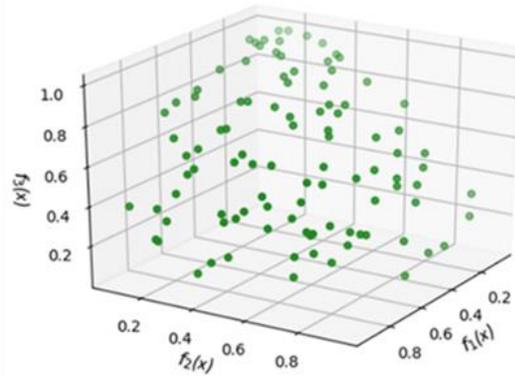
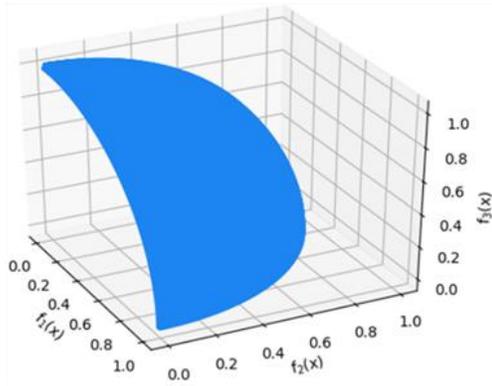
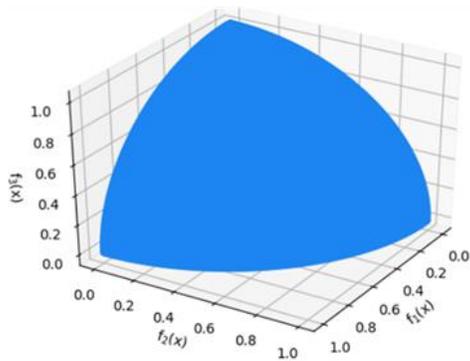


Fig. 3.16: Frente de Pareto MO7 literatura vs PSO

MO8

Minimizar:

$$f_1 = (1 + m) \cos(x_1^\pi(\pi/2)) \cos(x_2^\pi(\pi/2))$$

$$f_2 = (1 + m) \cos(x_1^\pi(\pi/2)) \operatorname{sen}(x_2^\pi(\pi/2))$$

$$f_3 = (1 + m) \operatorname{sen}(x_1^\pi(\pi/2))$$

$$m = \sum_{j=3}^{j=12} (x_j - 0,5)^2$$

$$0 \leq x_j \leq 1 \quad j = 1, 2, 3 \dots 12$$

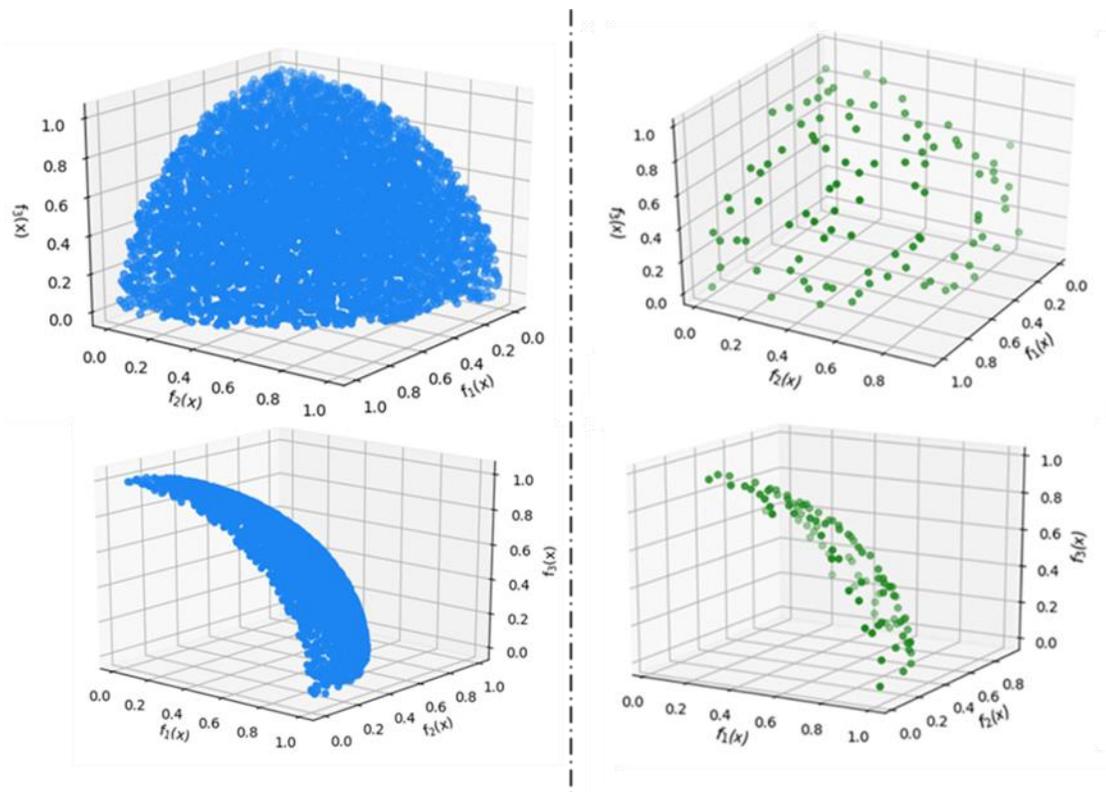


Fig. 3.17: Frente de Pareto MO8 literatura vs PSO

En los ocho casos de estudio presentados, las figuras que comparan los frentes de Pareto propios con los “reales” (literatura) son muy similares. Asimismo, en cada problema, las soluciones presentes en el archivo externo *A* poseen un valor de *TAV* igual a cero (datos no mostrados), lo que indica que todas ellas son factibles, ya que no violan ninguna restricción.

Estos resultados indican que la optimización de los distintos problemas *benchmark* de múltiples objetivos con el PSO implementado logra un buen desempeño general, tanto en problemas con dos y tres funciones objetivo, con y sin restricciones adicionales a los límites de cada variable. Por estas razones, sumado a evidencia generada en trabajos previos, entendemos que el PSO MINLP-MO desarrollado cumple con el propósito de resolver problemas no-lineales multiobjetivo que motivan esta tesis.

CAPÍTULO 4

OPTIMIZACIÓN DEL SISTEMA CULTIVO – MALEZA

En este capítulo se presentan estudios de optimización empleando el algoritmo presentado en la sección anterior en combinación con el modelo de simulación del Capítulo 2. Primeramente, se proporciona una descripción de los parámetros que, en la simulación del modelo del cultivo – maleza, son datos de entrada y que, en los estudios de optimización, se manipulan como variables. Luego, se presentan los resultados de la optimización de cuatro casos de estudio, empleando diversas funciones objetivo. En cada caso se describe con cierto detalle desde el punto de vista agronómico, aquellas soluciones más relevantes en términos de cada uno de los indicadores de desempeño analizados.

4.1. Esquema de optimización

Con el fin de emplear el modelo propuesto (Capítulo 2) para explorar sistemáticamente el extenso espacio de posibles opciones de manejo, en este capítulo se lo vincula con el algoritmo MINLP-MO basado en PSO (Capítulo 3) para diseñar un sistema de soporte a la toma de decisiones agronómicas.

Como se observa en la Fig. 4.1, el problema de optimización se resuelve independizando el *solver* del modelo de simulación cultivo-maleza. Esta completa separación entre el modelo agronómico y el algoritmo utilizado para optimizarlo, permite modificar el primero o incluso reemplazarlo, sin alterar el funcionamiento del segundo y viceversa. La metodología descrita en el Capítulo 3 se utiliza para proponer configuraciones del conjunto de variables de decisión que alimenten al simulador para optimizar una cierta función objetivo o combinación de funciones objetivo, calculadas a través del modelo de simulación. Con las

salidas provistas por el modelo agronómico, el PSO propone nuevos valores para las variables de entrada al modelo cultivo-maleza con el objetivo de mejorar los resultados.

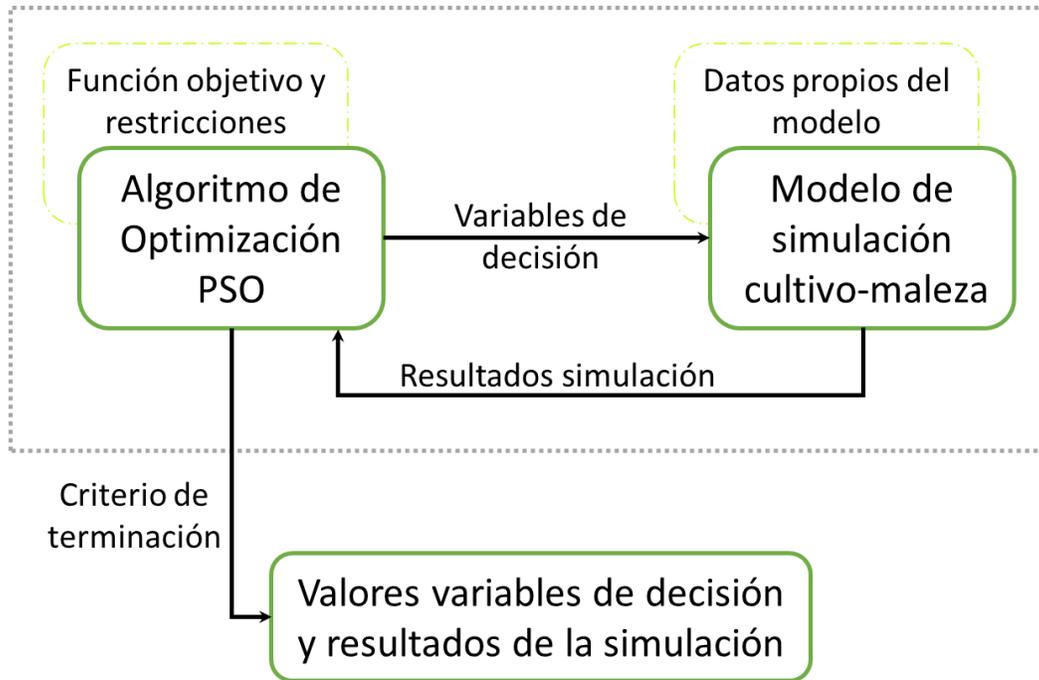


Fig. 4.1: Sistema de asistencia a la toma de decisiones agronómicas

El ciclo que conecta el PSO con el modelo de simulación se repite sucesivamente hasta que se cumple el criterio de terminación del algoritmo (definido en nuestro caso como un máximo número de iteraciones). En ese momento, se obtienen los resultados finales del optimizador con la mejor combinación de variables que minimicen (o maximicen) la/s función/es objetivo adoptadas, junto con toda la información agronómica, económica y medioambiental resultante de simular el sistema cultivo-maleza con dichas variables.

Para poder llevar a cabo la optimización con esta estructura, fue necesario adaptar el modelo de simulación descrito en el Capítulo 2. En particular, un subconjunto de parámetros que, a los fines del modelo de simulación, son datos fijos y únicos, al momento de optimizar, se transforman en variables de decisión.

4.1.1. Variables de decisión

Las variables de decisión representan las magnitudes que son controladas y determinadas por el optimizador. Éstas, idealmente, deben ser capaces de describir completamente las decisiones que puedan ser tomadas y todas las variantes que existan.

En esta tesis se decidió que el algoritmo debía seleccionar qué cultivo sembrar, cuándo y con qué densidad de siembra, qué método de control aplicar y en qué momento. Además, en el caso de que se optara por trigo, especificar si es conveniente que sea un cultivar estándar o uno altamente competitivo.

Estos factores representan las variables de decisión que pueden ser continuas, si son números reales comprendidos entre un límite inferior y superior, o binarias, si valen uno o cero cuando se trata de acciones que se ejecutan o no, respectivamente.

Variables de decisión continuas

Una variable continua es aquella que puede adoptar cualquier valor que se encuentre comprendido en un intervalo predeterminado. Éstas se suelen utilizar para representar magnitudes físicas.

El modelo agronómico está compuesto por diez variables continuas por cada partícula del enjambre y por cada ciclo agronómico (año calendario) que se desea optimizar. La estructura de variables continuas es una matriz 3D, tal como muestra la Fig. 4.2. Por ejemplo, para el caso que se pretenda optimizar el modelo agronómico en un horizonte de cinco años y con un tamaño del enjambre de 100 partículas, el número de variables continuas asciende a 5000 ($10 \cdot 100 \cdot 5$).

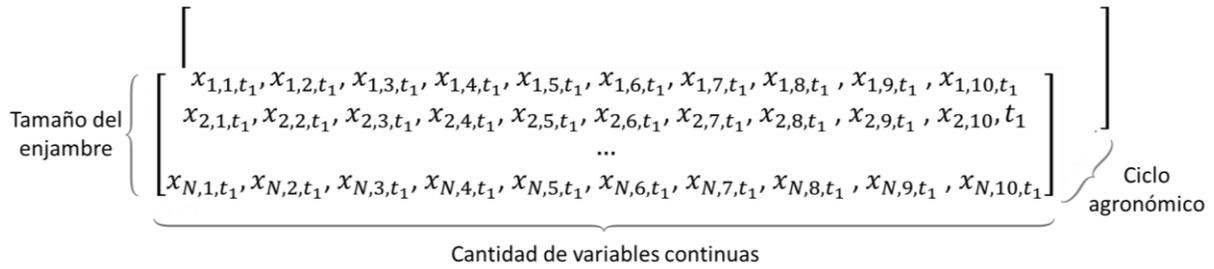


Fig. 4.2: Estructura de las variables continuas

En la Fig. 4.3 se esquematiza qué representa cada una de las diez variables correspondientes a cada partícula del enjambre de manera general en el ciclo agronómico t_1 .

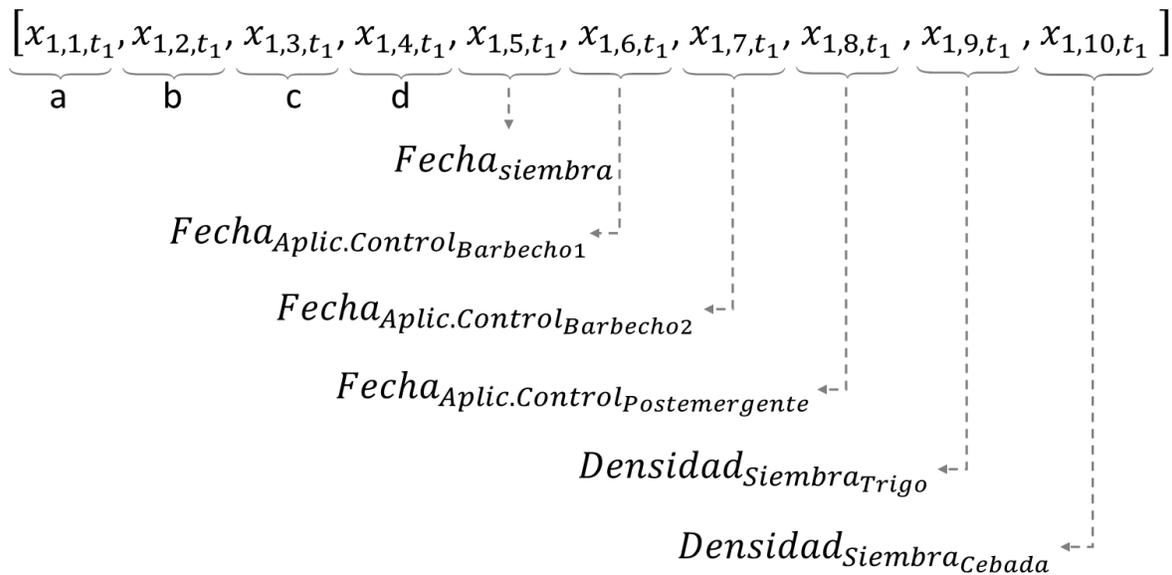


Fig. 4.3: Representación de las variables continuas

Las primeras cuatro se corresponden con las constantes a , b , c y d necesarias para implementar el método “Angle Modulation” descrito en la sección 4 del Capítulo 3, el cual permite determinar el valor de las variables binarias del modelo que se explican más adelante. La fecha de siembra del cultivo y de los métodos de control, así como la densidad de siembra de los cereales, se explicarán con más detalle a continuación:

Fecha de siembra de los cultivos

La fecha de siembra de los cultivos se establece a partir de la fecha de referencia 1 de julio (01/07), a la cual se le suma una variable continua que indica el número de días anteriores o posteriores a esa fecha en que puede realizarse la siembra. En el caso de trigo, esta variable puede adoptar valores entre -30 y +30 días. De esta manera, el rango de fechas en las que se puede sembrar este cereal queda comprendido entre los meses de junio y julio (01/06 al 31/07). Para el caso de cebada, el límite inferior es de -19 días ya que, para la zona bajo estudio, se recomienda que las variedades de este cereal se siembren típicamente a partir del 11 de junio. El límite superior se mantiene en +30 días (31/07). Si bien el número de días con respecto a la fecha de siembra de referencia es un número entero, en la práctica se la trata como una variable continua entre sus límites inferior y superior redondeada al entero más cercano. En la Fig. 4.4 se esquematiza el período en el que podría sembrarse trigo o cebada cada año del periodo considerado.

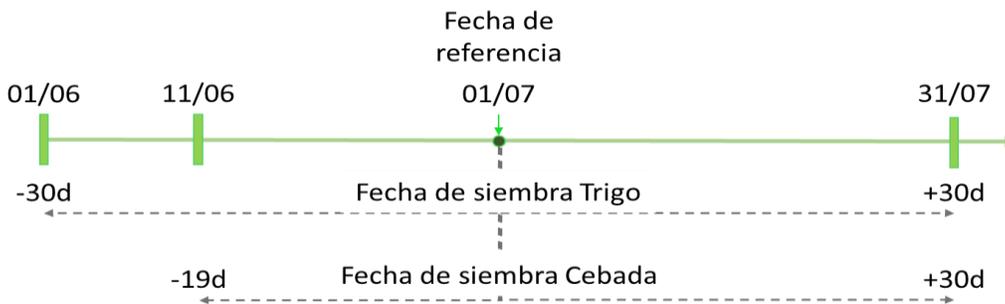


Fig. 4.4: Esquema de las fechas de siembra según el tipo de cultivo

En esta tesis, como sólo se tiene en cuenta un único cultivo anual (cebada o trigo), se implementó una sola variable continua para determinar la fecha de siembra. Sin embargo, si se quisieran agregar dos cultivos en el año (por ejemplo, un cereal de invierno y un cultivo de verano), se debería incorporar otra variable continua. Por ende, de ser necesario, se deberían implementar tantas variables continuas como nuevos cultivos se consideren, para determinar con ellas las distintas fechas de siembra.

Fecha de aplicación de los controles de malezas

La fecha de aplicación de los distintos controles de maleza depende de si éstos se emplean durante el barbecho (periodo anterior a la siembra) o si son postemergentes. Para representarlas se incorporaron tres variables continuas.

Dos de ellas se utilizan para asignar las fechas de aplicación en barbecho. La primera puede tomar un valor comprendido entre -90 y -80 días de la fecha de siembra para indicar la realización de un control al inicio del barbecho (barbecho largo), medida habitual en la práctica agronómica. La segunda aplicación varía en un rango que va desde los días -14 a -1 de la de la fecha de siembra del cultivo (barbecho corto). Este control, relativamente próximo a la fecha de siembra, se efectúa para minimizar la competencia durante el establecimiento del cultivo.

Por otro lado, como sólo se estableció la posibilidad de un solo control postemergente para cada cultivo, la fecha en que se lo aplica (en caso de ser seleccionado) se modela con otra variable continua. La misma posee límites inferior y superior de 20 y 90 días respectivamente, posteriores a la fecha de siembra del cereal.

En la Fig. 4.5 se presenta un esquema con los rangos para determinar las fechas de aplicación de los controles de maleza presiembra y postemergentes.

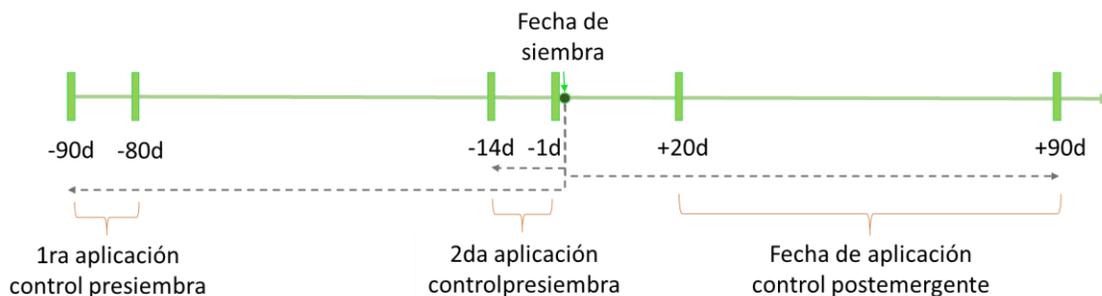


Fig. 4.5: Esquema de las fechas de aplicación de control de malezas

Densidad de siembra

Se incluyeron dos variables continuas más al modelo para representar la densidad de siembra de cada cereal ya que la misma difiere según el cultivo. En el caso de trigo, la variable continua puede variar entre 200 y 400 plantas/m². En cambio, para cebada los límites establecidos son 250 y 280 plantas/m².

La densidad de siembra se utiliza para ayudar a controlar las malezas. Una mayor densidad de semillas está asociada a un aumento del factor de competencia del cereal sobre la maleza, incrementando la competencia interespecífica. Esta estrategia no afecta el rendimiento del cereal, sino que se la utiliza como un método de control cultural. Cabe recordar que, si la densidad de siembra se acrecienta, también lo hacen los gastos de siembra (Ecs. 2.21a y 2.21b del Capítulo 2) repercutiendo directamente en el margen bruto de la actividad. Por esta razón es necesario establecer un buen balance entre los costos que acarrea esta acción y los beneficios relacionados con el control de malezas.

Variables de decisión binarias

El modelo agronómico posee cinco variables binarias, cuya estructura se presenta en la Fig. 4.6.

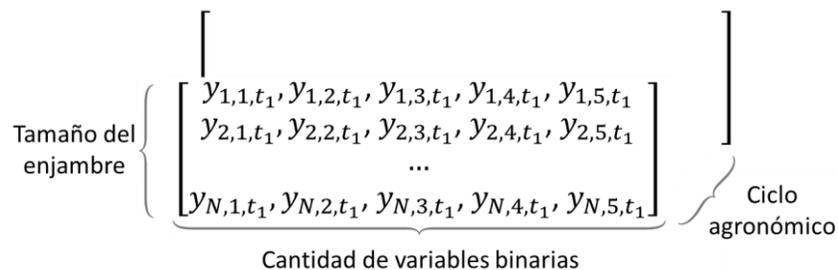


Fig. 4.6: Estructura de las variables binarias

En la Fig. 4.7 se exhibe un resumen esquemático de las tres categorías de decisiones binarias que se toman para la temporada t_1 : tipo de cultivo, método de control y cultivar de trigo. Las mismas se explicarán en detalle a continuación.

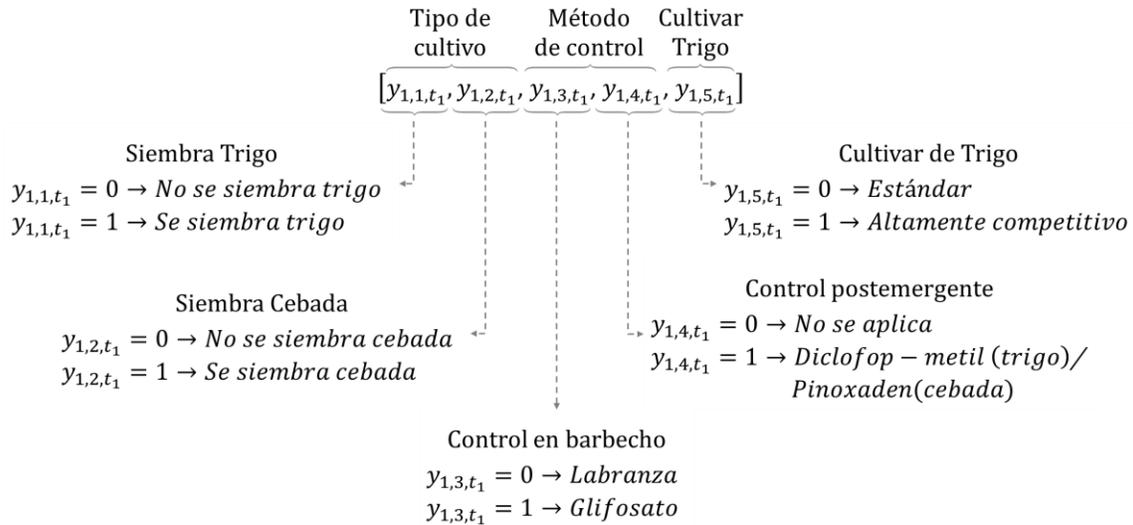


Fig. 4.7: Representación de las variables binarias

Tipo de cultivo

Se prevé que existan tantas variables binarias como cultivos simulados por el horizonte de tiempo a analizar. En el caso estudiado en esta tesis se consideran solo dos cultivos de invierno (trigo y cebada) en un periodo de cinco años (10 variables binarias en total). Sin embargo, esta configuración permitiría fácilmente incorporar otros cultivos mediante el agregado de nuevas variables binarias. Por ejemplo, si se consideran 3 cultivos para elegir en una planificación de 10 años, se tendrán 30 variables binarias en total (3 cultivos \cdot 10 años).

De esta manera, si la variable resulta igual a uno, significa que se siembra ese cultivo ese año y, si es igual a cero, no se lo elige. El algoritmo recorre en orden estas variables hasta

que detecta la primera que vale uno. A continuación, establece automáticamente que el resto valga cero ese año. De esta forma se logra verificar de una forma simple la restricción que impone la siembra de un único cultivo cada año, que es la práctica habitual en la zona analizada.

Métodos de control

En esta tesis se contempla la posibilidad de control mecánico (labranza) y tres controles químicos (glifosato, pinoxaden y diclofop-metil), aunque podrían incluirse más en un futuro siguiendo exactamente la misma mecánica.

En primer lugar, se utilizó una variable binaria para representar el control en barbecho que se podría realizar mediante labranza o glifosato. Tal como se simuló en los casos de estudio del Capítulo 2, en la optimización se contemplaron dos aplicaciones de glifosato o dos labranzas entre la cosecha de un cultivo y la siembra del siguiente cultivo. De esta manera, si la variable binaria resulta igual a cero significa que se aplica dos veces glifosato y, por el contrario, si es igual a uno se realizan dos labranzas antes de la siembra del cultivo.

Es importante recordar que las dos acciones de control que se realizan en barbecho son medidas que no solo se toman para controlar la *Avena fatua* L., sino que también tiene en cuenta otros factores. Por ejemplo, con el primer control (barbecho largo) se intenta evitar que otras especies de malezas consuman agua o produzcan semillas. En cambio, con el segundo (barbecho corto o presiembra) se trata de impedir la competencia temprana de las malezas con el cultivo a punto de ser sembrado.

Asimismo, se prevé la posibilidad de aplicar un herbicida postemergente, que podría ser diclofop-metil si se siembra trigo o pinoxaden si se trata de cebada. Para representar esta decisión se incorporó otra variable binaria que, cuando vale cero, significa que no se emplea el control y, si es igual a uno, se realiza una aplicación del herbicida recomendado para el tipo de cereal sembrado.

En conclusión, se encuentran programadas dos variables binarias más por año para representar la posibilidad de elegir entre estas cuatro opciones de control. Cabe aclarar que siempre existe algún control en barbecho (presiembrado), mientras que puede suceder que no se aplique ningún herbicida postemergente.

Cultivar de trigo

En la optimización del modelo agronómico se consideró también la opción de elegir entre un cultivar de trigo estándar y uno altamente competitivo. La diferencia entre ambos cultivares es que el estándar tiene una mayor pérdida de rendimiento por maleza ($MPRM$) aunque, potencialmente, alcanza un área foliar máxima ($TPLA_{m\acute{a}x}$) y un rendimiento potencial (RP) del cereal mayor que el cultivar altamente competitivo.

Para tal fin se sumó una quinta variable binaria, con la cual se establece que, si adopta un valor igual a cero, se siembra un cultivar de trigo estándar ($MPRM = 0,6$, $TPLA_{m\acute{a}x} = 6$, $RP = 4$) y si es igual a uno, un cultivar de trigo altamente competitivo ($MPRM = 0,2$, $TPLA_{m\acute{a}x} = 1$, $RP = 3,8$). Los costos de cosecha y el valor de venta del grano de ambos cultivares son iguales, por lo que el optimizador debería seleccionar un cultivar altamente competitivo priorizando un mayor control de malezas o uno estándar que permita enfocarse más en un mayor rendimiento.

4.2. Casos de estudio

En esta sección se presentan diversos experimentos de optimización, en los cuales el modelo agronómico presenta los mismos parámetros utilizados en los estudios de simulación del Capítulo 2 (Tabla 2.8). Cada caso difiere en las funciones objetivo y/o

restricciones seleccionadas. De esta manera, se busca encontrar las mejores soluciones de acuerdo a distintos intereses e ilustrar el empleo de la herramienta como DSS.

En todos los casos el horizonte de tiempo considerado corresponde al período 2014-2018, con los datos climáticos y perfiles de emergencia de la maleza detallados oportunamente.

Recordamos que en la optimización ya no es necesario que el usuario elija qué cultivo sembrar, ni defina su fecha y densidad de siembra, ni el tipo de cultivar, ya que dichos parámetros ahora son optimizados por el PSO para hallar su mejor valor.

A continuación, se presenta cada caso propuesto describiendo las funciones objetivo utilizadas y los resultados obtenidos por el algoritmo al realizar la optimización del modelo agronómico. Los mismos se alcanzaron luego de 11 h de ejecución en una computadora Intel(R) Core (TM) i7-3537U CPU @ 2.00GHz 2.50GHz con una memoria RAM de 8GB. Los parámetros del PSO para todas las optimizaciones realizadas en este capítulo son: cantidad de partículas (N) = 100, constante de aceleración cognitiva (c_1) = 1,50, constante de aceleración social (c_2) = 1,50, peso de inercia (w) = 0,75, iteraciones máximas ($k_{m\acute{a}x}$) = 2500 y la dimensión del archivo externo A (dim_A) = 20.

4.2.1. CASO OI

En este caso se optimizó el modelo agronómico en base a tres funciones objetivo (F) dadas por la Ec. 4.1. La primera (f_1) es el indicador económico, basado en el valor actual (VA) a lo largo del periodo de tiempo adoptado. Las funciones objetivo f_2 y f_3 son el índice de labranza (*Índice T*) y el de herbicidas (*Índice P*), respectivamente. Estos indicadores se incluyen con el propósito de evaluar las consecuencias medioambientales del manejo propuesto. Cabe recordar que, cuanto mayor es el valor de estos índices, menor es el impacto ambiental producido por los controles.

$$\text{Min } F \begin{cases} f_1 = -VA \\ f_2 = -\text{Índice } T \\ f_3 = -\text{Índice } P \end{cases} \quad (4.1)$$

El frente de Pareto obtenido al optimizar el modelo agronómico del CASO OI, se compone de doce soluciones como se muestra en la Fig. 4.8. Con el fin de presentar los resultados de una manera más amigable para su análisis, estas soluciones también se exponen en la Fig. 4.9, exhibiendo a través de líneas el VA y a través de gráficos de barra los índices de herbicidas (índice P) y de labranza (índice T).

Dichos resultados se obtuvieron luego de 11,23 h de cómputo.

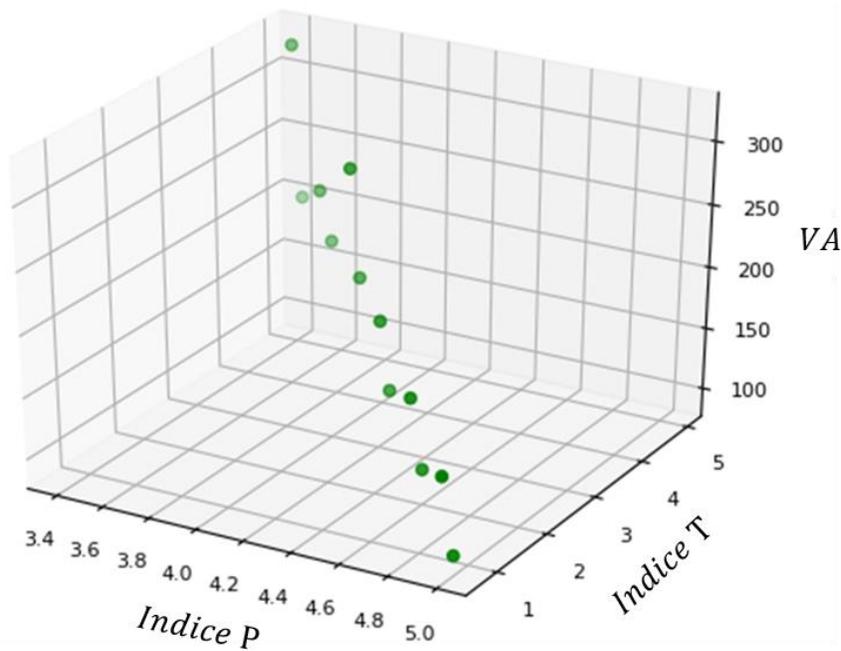


Fig. 4.8: Frente de Pareto CASO OI

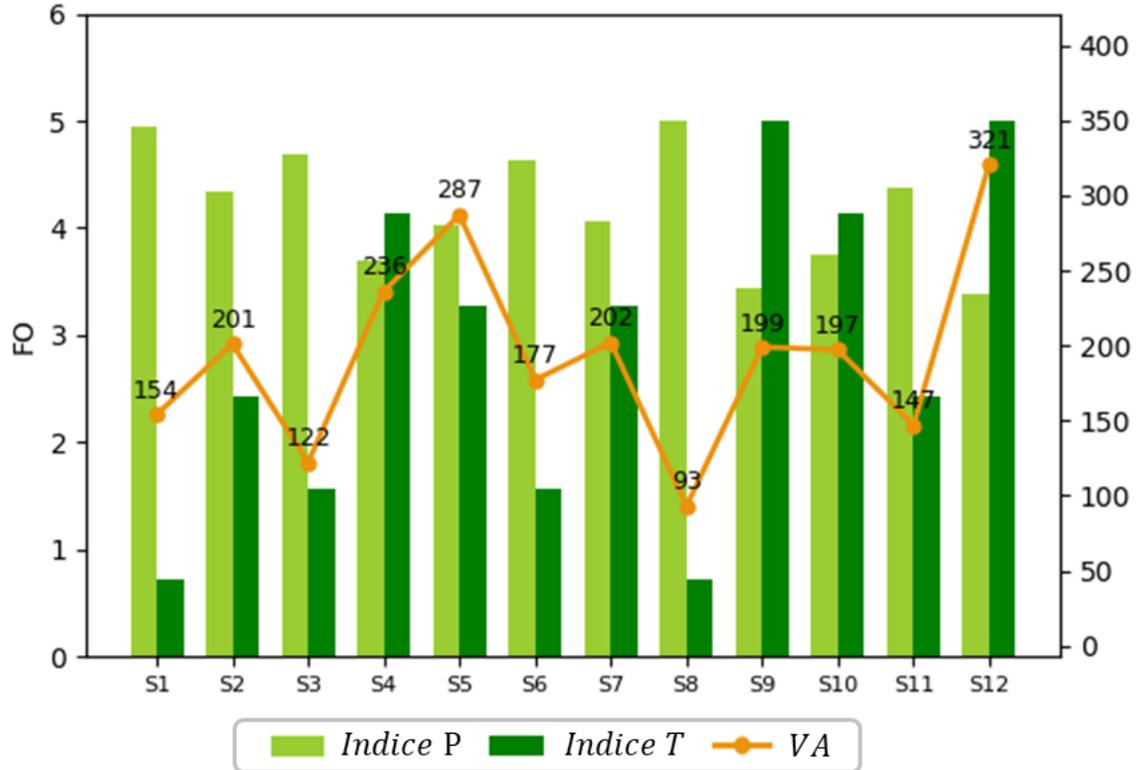


Fig. 4.9: Resultados optimización CASO OI

El archivo de salida del PSO, que cuenta con los valores de todas las variables optimizadas, se encuentra en la Tabla AIV.1 del Anexo IV. Para poder visualizar mejor la información, se la resumió excluyendo las fechas de siembra del cultivo y aplicación de los métodos de control en la Tabla 4.1. En columna “Sol.” se identifica cada una de las soluciones (S) del frente de Pareto; en “Cultivo” se especifica si se siembra cebada (C), trigo estándar (T-E) o trigo altamente competitivo (T-AC); en “ ρ_s ” se detalla la densidad de siembra del cultivo en [ind/m²]; la columna “Control” se divide en “Pre.” que hace referencia al control de malezas presiembrado que puede ser labranza (L) o glifosato (G) y “Post.” que define el control postemergente que puede ser diclofop-metil (D) si se siembra trigo o pinoxaden (P) si se trata de cebada.

El VA promedio de todas las soluciones es de 195 USD/ha. Cabe recordar que, el CASO SIV de simulación (Cap. 2), donde se realizó manejo cultural y se aplicó un criterio para el control químico post-emergente, arrojó un VA de 226 USD/ha con valores totales (cinco

años) de los índices P y T de 2,82 y 5,00, respectivamente. Si bien se consideró que dicha estrategia de control era la más atractiva entre las opciones de simulación analizadas, la herramienta de optimización permite descubrir nuevas y mejores alternativas, como por ejemplo la solución S12 que alcanza un VA mayor (321 USD/ha) con un menor impacto ambiental (índice P de 3,39 y T de 5,00).

Por otro lado, el promedio del índice de herbicidas (índice P) del CASO OI es de 4,19, superior en la mayoría de las soluciones individuales a los CASOS SI y SIII de simulación (Cap. 2) que alcanzan un índice P de 3,45 (a excepción de S9 y S12). Esto se debe a que la mitad de las soluciones no proponen aplicación de herbicidas postemergentes y, además, muchas alternan el uso de glifosato con la realización de labranzas en el control presiembra.

En cuanto al índice T , las distintas soluciones del frente de Pareto (Fig. 4.9), proporcionan un promedio de 2,86. Recordamos que en los casos de simulación SI al SIV del Cap. 2, este índice siempre es igual a 5,00 ya que no se realizan labranzas en ningún año, mientras que en el CASO SV (Cap. 2) es de 0,71 porque se la utiliza en los cinco años como control presiembra. Debido al alto costo de la labranza y al elevado impacto por erosión, la estrategia SV no resulta conveniente ni económica ni medioambientalmente. Sin embargo, con la optimización se descubren nuevas combinaciones de manejo que intercalan labranzas con herbicidas, además de la variabilidad de la rotación de los cultivos y medidas culturales que permiten obtener mejores valores de VA e índices medioambientales. Por ejemplo, si comparamos la solución S9 y S12, ambas tienen un índice T de 5,00, como en el CASO SV del Cap. 2, pero las dos logran un mayor VA (199 USD/ha y 321 USD/ha respectivamente) a costa de un mayor impacto ambiental por la aplicación de herbicidas postemergentes (3,43 y 3,39 respectivamente contra 4,36 de CASO SV de simulación).

En la Tabla 4.1, se observa que el plan de manejo correspondiente a las diferentes soluciones propone la siembra de cebada en cuatro o más de los cinco años del horizonte de planeamiento, a excepción de S2 que establece dos siembras de trigo. Esto podría asociarse a la mayor capacidad competitiva de la cebada frente al trigo. La cebada logra una competencia más temprana con la maleza y, a su vez, genera rápidamente condiciones de alta competencia en un mayor período de tiempo. Cabe recordar que se parte de un banco

inicial de AVEFA grande (2000 semillas/m²) por lo que parece lógico que se asigne gran parte del período, en particular al inicio, cultivos más competitivos para reducir la infestación de la maleza. En particular, en 2014, cuando la infestación de malezas es la mayor, se propone siempre la siembra de cebada.

En lo que respecta a trigo, sólo tres soluciones proponen sembrarlo (S2, S4 y S6). En S2 se elige trigo altamente competitivo en 2015, cuando la competencia con la maleza es mayor, y en 2018 selecciona un cultivar estándar. Por otro lado, S4 y S6 siembran solo una vez trigo a lo largo de los cinco años del horizonte de planeamiento (en 2017 y 2015 respectivamente), y en ambos casos optan por trigo estándar.

En relación al control presiembra, la mayoría de las soluciones alternan entre labranzas y control químico. Sin embargo, en aquellas soluciones que aplican glifosato en cuatro o cinco de los años de estudio (S4, S9, S10 y S12) se obtienen mejores *VA* que cuando se realiza esa misma cantidad de labranzas (S1, S3, S6 y S8). Estos resultados eran esperables, ya que la labranza reiterada no sólo es una medida que provoca un gran impacto ambiental relacionado con la erosión del suelo, sino que también es mucho más costosa y su eficiencia respecto del control de la maleza apenas supera en un 1% a la del glifosato.

Asimismo, se puede apreciar que seis de las doce soluciones (S3, S7, S8, S9, S10 y S11) no recomiendan la aplicación de herbicidas postemergentes, controlando la maleza únicamente con medidas culturales (tipo de cultivo a sembrar, fecha de siembra y densidad) combinado con herbicidas presiembra. Sin embargo, es evidente que estas opciones priorizan un menor impacto ambiental frente a la obtención de un rédito económico, ya que los *VA* alcanzados varían entre 93 y 202 USD/ha, siendo un rango más bajo, en líneas generales, que las soluciones que aplican un control postemergente, cuyo *VA* se encuentra entre 154 y 321 USD/ha. Las seis soluciones que aplican un control postemergente (S1, S2, S4, S5, S6 y S12) solo lo hacen una vez y siempre en el primer año de estudio (2014), cuando la infestación de malezas es la mayor.

Tabla 4.1: Resultados del CASO OI

Sol.	VA	Índice T	Índice P	2014				2015				2016				2017				2018			
				Cultivo	ρ_S	Control		Cultivo	ρ_S	Control		Cultivo	ρ_S	Control		Cultivo	ρ_S	Control		Cultivo	ρ_S	Control	
						Pre.	Post.																
S1	154	0,71	4,95	C	262	L	P	C	251	L	-	C	255	L	-	C	268	L	-	C	268	L	-
S2	201	2,43	4,33	C	267	L	P	T-AC	261	G	-	C	262	L	-	C	267	L	-	T-E	280	G	-
S3	122	1,57	4,69	C	259	G	-	C	269	L	-	C	268	L	-	C	264	L	-	C	264	L	-
S4	236	4,14	3,70	C	255	L	P	C	250	G	-	C	251	G	-	T-E	310	G	-	C	261	G	-
S5	287	3,28	4,02	C	275	G	P	C	260	G	-	C	253	L	-	C	274	L	-	C	267	G	-
S6	177	1,57	4,64	C	254	L	P	T-E	233	L	-	C	250	L	-	C	267	G	-	C	266	L	-
S7	202	3,28	4,06	C	277	G	-	C	270	G	-	C	265	G	-	C	276	L	-	C	262	L	-
S8	93	0,71	5,00	C	275	L	-	C	268	L	-	C	276	L	-	C	274	L	-	C	274	L	-
S9	199	5,00	3,43	C	274	G	-	C	259	G	-	C	270	G	-	C	254	G	-	C	265	G	-
S10	197	4,14	3,75	C	268	G	-	C	267	G	-	C	266	G	-	C	251	G	-	C	259	L	-
S11	147	2,43	4,37	C	253	G	-	C	269	G	-	C	271	L	-	C	261	L	-	C	272	L	-
S12	321	5,00	3,39	C	260	G	P	C	270	G	-	C	270	G	-	C	261	G	-	C	258	G	-

A continuación, se describirán en detalle a través de las figuras que representan la dinámica poblacional de AVEFA y el factor de competencia de los cultivos, las soluciones del frente de Pareto que alcanzaron los mayores VA , índice T e índice P .

Dentro del conjunto de soluciones, S12 presenta el mayor VA (321 USD/ha). Esta estrategia establece siembra de cebada en todo el horizonte de planeamiento. Como control presiembra se selecciona siempre glifosato, motivo por el cual se alcanza el máximo valor del índice T (5,00), ya que nunca se realiza control mecánico. En cuanto al control postemergente, solo se propone una aplicación de un herbicida en el primer año (2014), cuando la infestación de malezas es la más alta. Debido a que se aplican controles químicos pre y postemergentes, el índice P es el peor (más bajo) del frente de Pareto, pero permite un control más eficiente de AVEFA, ya que en competencia con el cultivo (por debajo de la curva FC) nunca supera los 50 ind/m² (Fig. 4.10).

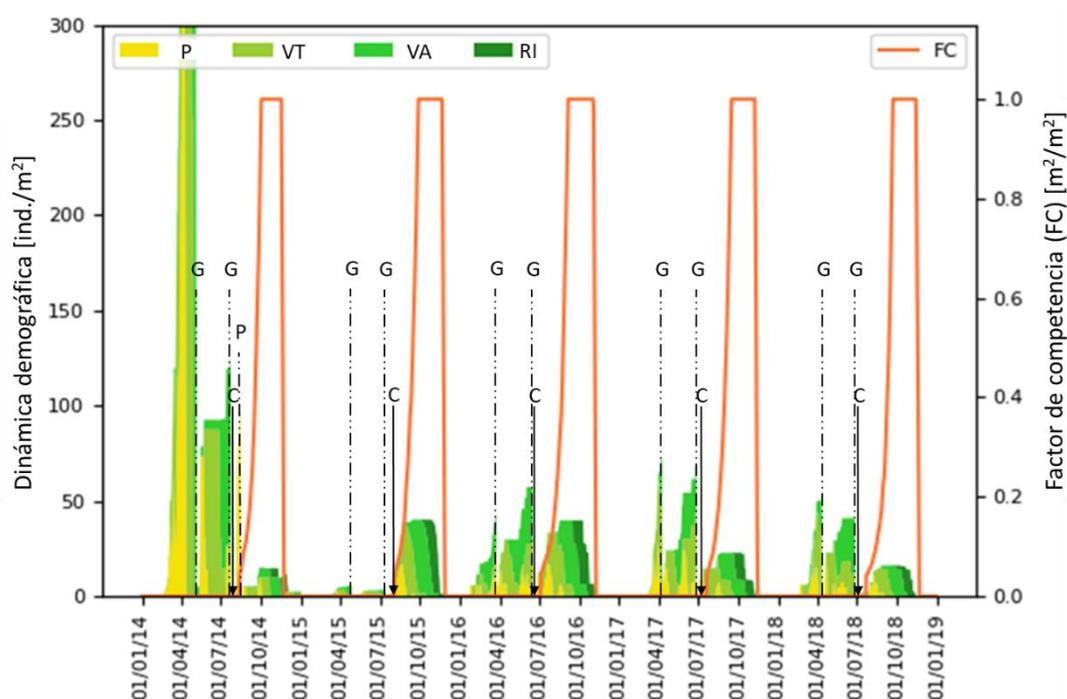


Fig. 4.10: Dinámica poblacional de AVEFA (P : Plántula, VT : Vegetativo Temprano, VA : Vegetativo Avanzado, RI : Reproductivo Inicial) y factor de competencia (FC) de S12 – CASO OI.

Al igual que S12, S9 alcanza el mejor índice T (porque nunca se realiza labranza en presiembra) y también propone siembra de cebada en todos los años analizados. La principal diferencia radica en que S9 no aplica control postemergente, por eso su índice P es algo mejor que el de S12. Esta estrategia de control resulta ser más deficiente que la anterior, lo cual se evidencia en la Fig. 4.11, en donde la dinámica poblacional de la maleza alcanza picos cercanos a los 240 ind/m² en competencia con el cereal. Esta es la razón por lo cual S9 logra sólo el 62% del mejor VA del frente de Pareto.

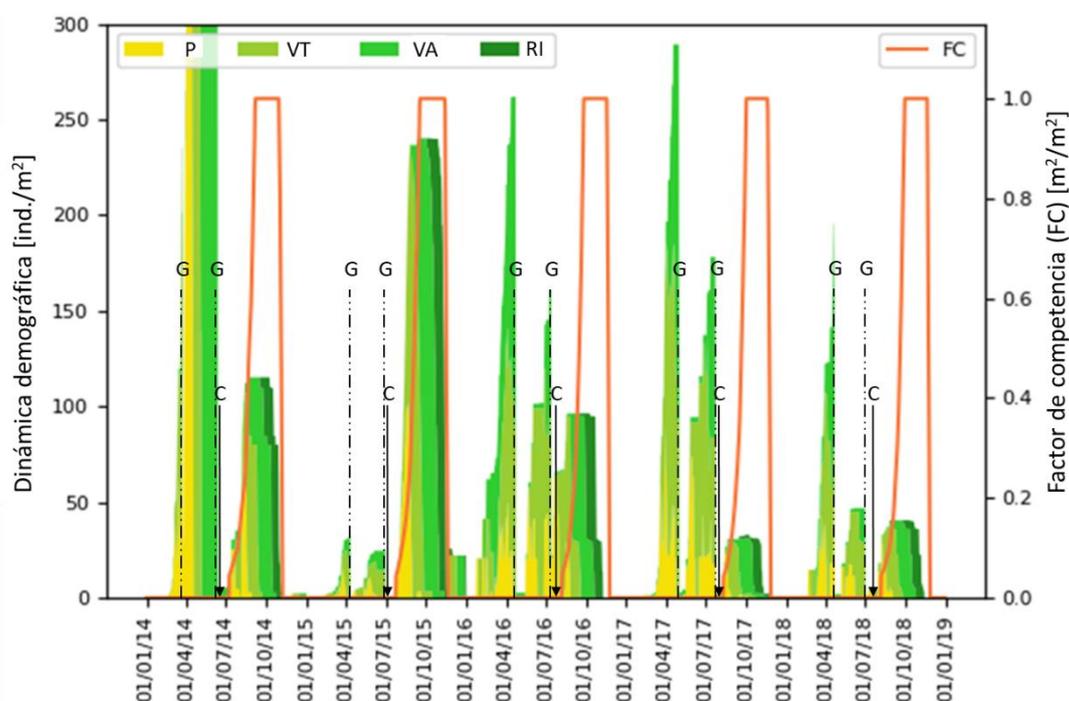


Fig. 4.11: Dinámica poblacional de AVEFA (P : Plántula, VT : Vegetativo Temprano, VA : Vegetativo Avanzado, RI : Reproductivo Inicial) y factor de competencia (FC) de S9 – CASO OI.

Por su parte, S8 logra el mejor (máximo) índice P , dado que solo realiza labranzas como control presiembra y no aplica controles postemergentes. La Fig. 4.12 demuestra que esta estrategia de control es mejor que S9, dado que los picos de maleza alcanzan un máximo de 200 ind/m² (en competencia con cebada) en 2015, lo que evidencia que las fechas establecidas para el control y la siembra, junto con la densidad de siembra, son más adecuadas que las de la solución anterior. Sin embargo, el costo del control

mecánico es más elevado que el de control químico en presiembra, por lo que repercute directamente en el margen bruto de cada año, y conlleva a que S8, dentro de todo el frente de Pareto, sea la solución que consigue el menor VA .

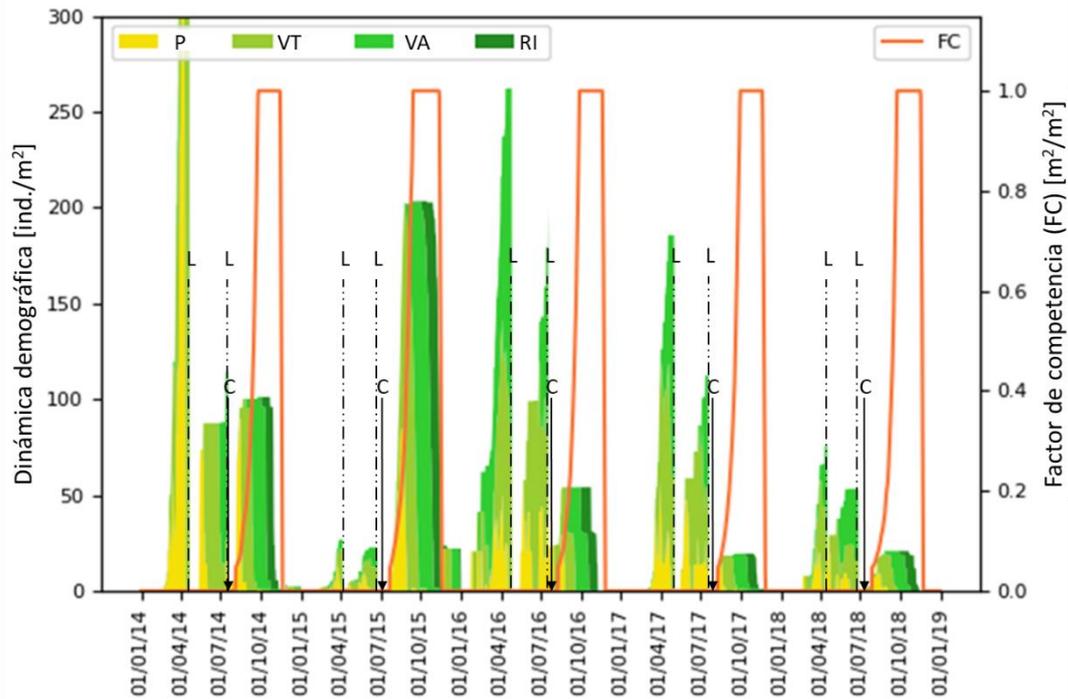


Fig. 4.12: Dinámica poblacional de AVEFA (P : Plántula, VT : Vegetativo Temprano, VA : Vegetativo Avanzado, RI : Reproductivo Inicial) y factor de competencia (FC) de S8 – CASO OI.

4.2.2. CASO OII

Para evitar que el suelo se agote y que las enfermedades que afectan a un tipo de cultivo se propaguen, en la práctica se recurre a realizar rotación de cultivos. En el modelo de simulación no se encuentran programadas las consecuencias perjudiciales relacionadas a los monocultivos por lo que, en la optimización previa, las soluciones reportaron siembra de cebada en la mayoría de los años, que resulta lo más conveniente para controlar AVEFA. Para forzar al sistema a que realice algún grado de rotación entre los dos cultivos programados, en este nuevo caso se modificó el problema de optimización OI al añadirle la restricción h_1 (Ec. 4.2) que restringe a dos la posibilidad de siembra de

cebada dentro de los cinco años analizados, aunque no obliga a que los cultivos se siembren intercaladamente. Este análisis busca evitar un monocultivo de cinco años y evaluar las estrategias que presentaría la optimización del modelo agronómico considerando la misma cantidad de siembras de trigo y cebada que en los casos de simulación analizados en el Capítulo 2, aunque variando cómo se realizaría su rotación, además de su fecha de siembra y densidad, los controles presiembra y postemergente y sus momentos de aplicación.

$$\begin{array}{l} \text{Min } F \quad \left\{ \begin{array}{l} f_1 = -VA \\ f_2 = -\text{Índice } T \\ f_3 = -\text{Índice } P \end{array} \right. \quad (4.2) \\ \text{Sujeto a:} \\ h_1 = \text{Cantidad siembra}_{\text{cebada}} - 2 = 0 \end{array}$$

Con esta modificación, el frente de Pareto obtenido para el CASO OII contiene dieciséis soluciones que se presentan en las Figs. 4.13 y 4.14, encontradas por el PSO al ejecutarse durante un período de 11,72 h.

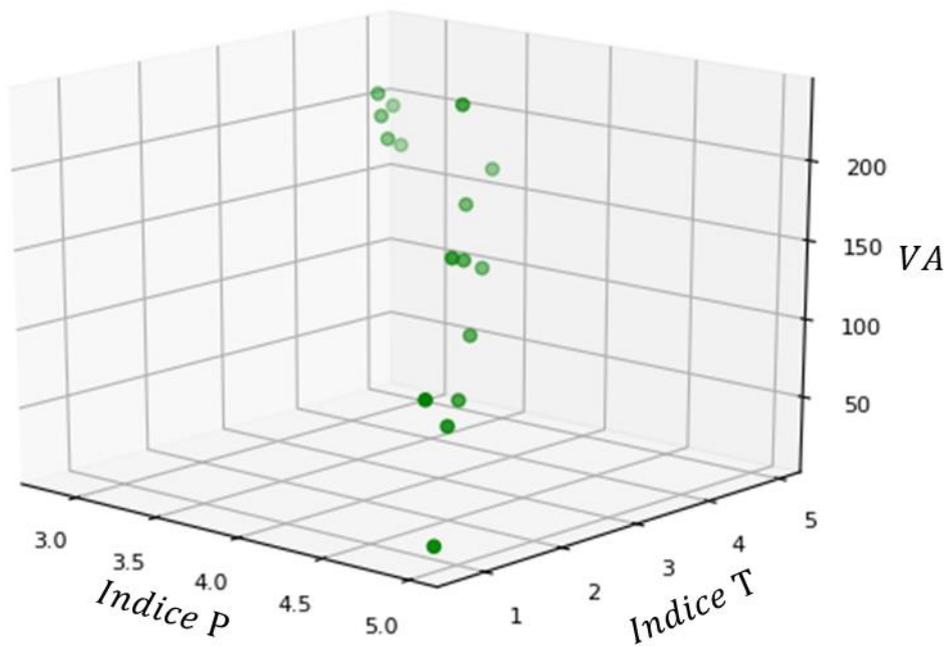


Fig. 4.13: Frente de Pareto CASO OII

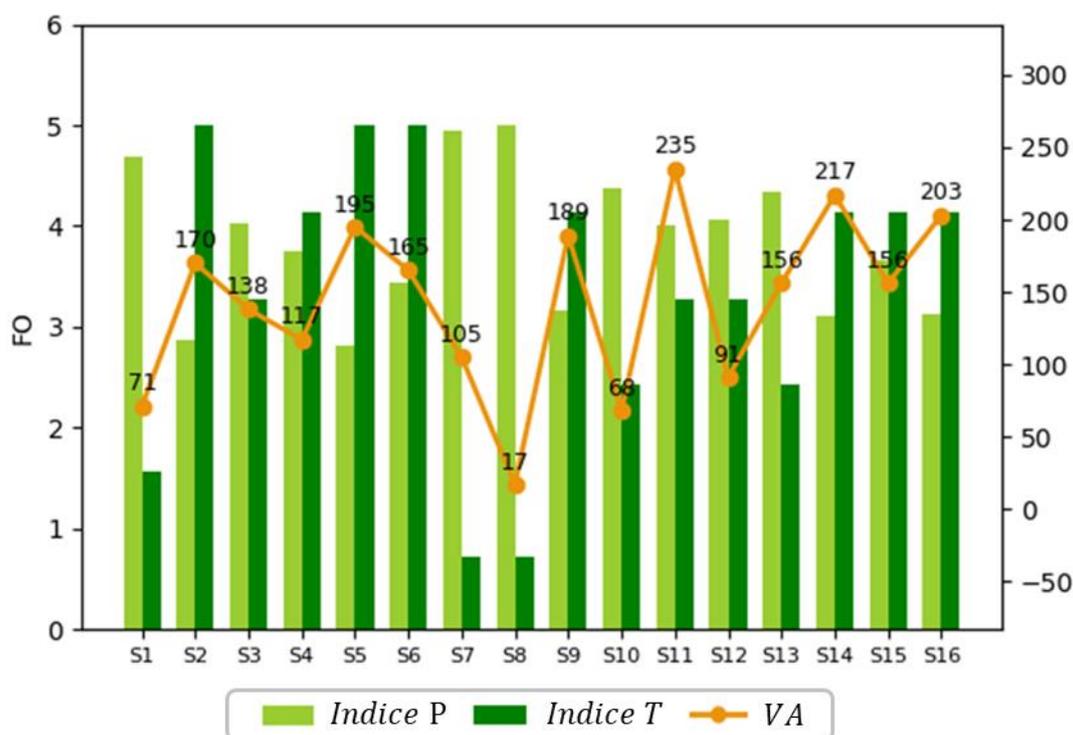


Fig. 4.14: Resultados optimización CASO OII

El hecho de forzar la selección de cultivos por medio de la Ec. 4.2 afecta naturalmente la calidad de las soluciones frente a las del CASO OI. Esto se debe a que, como se concluyó anteriormente, la cebada logra una mejor competencia con la maleza, aumentando el rendimiento final del cultivo y, por ende, el margen bruto de cada año. En cambio, en este caso, la imposición de siembra de trigo (en tres de los cinco años de estudio) reduce los márgenes brutos.

A pesar de que, al estar más restringido, las soluciones en este caso son necesariamente “peores” que las de optimización OI, como se detalla a continuación, algunas de las estrategias encontradas siguen superando los resultados de las simulaciones propuestas en el Capítulo 2.

El VA promedio del frente de Pareto del CASO OII es de 143 USD/ha. En todas las soluciones el valor obtenido es mayor al CASO SI (Cap. 2) que no posee control postemergente, ni MIM. A su vez, existen cinco soluciones que presentan mejorías en el VA respecto al CASO SII (Cap. 2) que no plantea MIM pero sí control postemergente (S5, S9, S11, S14 y S16), y otras nueve que superan al CASO SIII (Cap. 2) al realizar MIM sin control postemergente (S2, S5, S6, S9, S11, S13, S14, S15 y S16).

Sólo una solución (S11) presenta una mejora económica respecto al CASO SIV del Capítulo 2 que logró el mejor *VA* de dicho capítulo con MIM y control postemergente. La mayoría de las soluciones (a excepción de S1, S8 y S10) superan económicamente al CASO SV (Cap. 2) que utiliza labranza como control presiembra.

Con respecto a los índices medioambientales, el promedio del índice de herbicidas es de 3,83 mientras que el de labranza es de 3,34. Los valores del índice *P* son en general peores respecto del CASO OI (9,5 % en promedio). Sin embargo, el índice *T* mejoró en promedio un 17%. Esto sugiere que estas estrategias, comparadas con el frente de Pareto del caso previo, priorizan más un control presiembra mecánico que químico.

A pesar de notarse una disminución importante del *VA*, no se observa una variación dramática del impacto ambiental global (considerando ambos índices) respecto de las soluciones de OI, por lo cual, de acuerdo a un enfoque meramente económico no se recomendaría llevar a cabo este tipo de acciones. Sin embargo, considerando que el modelo no cuenta con la simulación de las ventajas de la rotación de cultivos, estas propuestas no deberían descartarse.

La Tabla 4.2 expone la planificación agronómica resultante de cada solución que conforma el frente de Pareto OII, mientras que en el Anexo IV, Tabla AIV.2, se detallan las fechas de siembra y aplicación de los controles. En general, se puede observar que la mayoría de las soluciones propone que se siembre cebada el primer año (S1, S3, S4, S7, S8, S10, S11, S12, S13, S14, S15 y S16). Esto se atribuye a que este cereal, al competir mejor con la maleza que el trigo, prevalece cuando la infestación de AVEFA es máxima. Reforzando esta idea, en tres de las soluciones restantes (S5, S6 y S9), se propone emplear un cultivar altamente competitivo de trigo frente al estándar, debido también a su mayor capacidad competitiva en un año de altísima infestación. Solo en una de las soluciones (S2) se recomienda un cultivar de trigo estándar, relativamente poco competitivo, el primer año del periodo estudiado (2014).

Por su parte, los controles presiembra propuestos por las soluciones son bastante variados, aunque en general prevalece el uso de barbecho químico en gran parte de los años simulados. Existen ocho soluciones que proponen en cuatro años o más el uso de glifosato (S2, S4, S5, S6, S9, S14, S15 y S16), tres soluciones que sugieren en cuatro años o más la realización de labranzas (S1, S7 y S8) y cinco soluciones que aplican más

equitativamente los dos tipos de métodos (S3, S10, S11, S12 y S13). Nuevamente sucede que las estrategias que presentan una mayor cantidad de labranzas conducen, en general, a *VA* más bajos (especialmente S1 y S8).

Respecto de los controles postemergentes, en esta ocasión también ocurre que en seis de las dieciséis soluciones (S1, S4, S6, S8, S10 y S12) no se recomienda su aplicación, presentando *VA* más bajos (entre 17 USD/ha y 165 USD/ha). Otras seis propuestas (S2, S3, S7, S9, S11 y S13) establecen una sola aplicación de un herbicida postemergente en el primer año (2014), el de mayor infestación de malezas. Por otro lado, cuatro estrategias (S5, S14, S15 y S16) establecen dos controles postemergentes, todas realizan el primero en 2014, mientras que dos de ellas aplican el segundo control en 2018 y las dos restantes en 2016, alcanzando buenos valores de *VA* (superiores a 156 USD/ha) a pesar de los gastos asociados a estas aplicaciones.

Tabla 4.2: Resultados del CASO OII

Sol.	VA	Índice T	Índice P	2014				2015				2016				2017				2018			
				Cultivo	ρ_S	Control Pre. Post.		Cultivo	ρ_S	Control Pre. Post.		Cultivo	ρ_S	Control Pre. Post.		Cultivo	ρ_S	Control Pre. Post.		Cultivo	ρ_S	Control Pre. Post.	
S1	71	1,57	4,69	C	254	L	-	T-AC	250	G	-	T-E	306	L	-	C	267	L	-	T-AC	210	L	-
S2	170	5,00	2,86	T-E	303	G	D	C	265	G	-	C	273	G	-	T-E	299	G	-	T-E	356	G	-
S3	138	3,28	4,02	C	258	G	P	C	269	G	-	T-E	326	L	-	T-E	254	L	-	T-AC	300	G	-
S4	117	4,14	3,75	C	250	G	-	C	277	G	-	T-AC	306	G	-	T-AC	288	G	-	T-AC	360	L	-
S5	195	5,00	2,81	T-AC	260	G	D	T-AC	268	G	-	C	258	G	-	T-E	242	G	-	C	263	G	P
S6	165	5,00	3,43	T-AC	310	G	-	T-AC	254	G	-	T-AC	326	G	-	C	269	G	-	C	272	G	-
S7	105	0,71	4,95	C	252	L	P	T-E	322	L	-	C	259	L	-	T-E	216	L	-	T-E	242	L	-
S8	17	0,71	5,00	C	262	L	-	C	268	L	-	T-E	277	L	-	T-E	348	L	-	T-E	298	L	-
S9	189	4,14	3,17	T-AC	386	G	D	T-E	299	L	-	C	273	G	-	C	266	G	-	T-AC	262	G	-
S10	68	2,43	4,37	C	267	L	-	T-AC	304	G	-	C	262	G	-	T-E	342	L	-	T-AC	237	L	-
S11	235	3,28	4,01	C	269	L	P	T-AC	295	G	-	T-E	293	G	-	C	257	G	-	T-E	301	L	-
S12	91	3,28	4,06	C	265	G	-	T-AC	290	L	-	C	266	G	-	T-AC	244	G	-	T-AC	301	L	-
S13	156	2,43	4,33	C	272	G	P	T-AC	353	L	-	T-E	333	G	-	T-AC	234	L	-	C	265	L	-
S14	217	4,14	3,11	C	275	G	P	T-AC	389	G	-	C	266	G	-	T-E	272	G	-	T-E	254	L	D
S15	156	4,14	3,65	C	269	L	P	T-E	343	G	-	C	265	G	P	T-AC	235	G	-	T-E	283	G	-
S16	203	4,14	3,13	C	269	G	P	C	275	G	-	T-E	310	G	D	T-E	269	G	-	T-AC	253	L	-

A continuación, se presenta la dinámica poblacional de AVEFA y el factor de competencia de las soluciones que poseen el mayor VA (S11), el mejor índice T (S5) y el mejor índice P (S8) del frente de Pareto.

La solución S11 logra el mejor VA de toda la frontera de Pareto. La misma plantea siembra de cebada en el primer año (2014) y trigo altamente competitivo en el segundo (2015). A partir del tercer año, se selecciona trigo estándar, a excepción del 2017 que se opta por cebada. En cuanto al control, en presiembra se alterna entre labranza y glifosato y en postemergencia se establece sólo una aplicación de herbicida en 2014. Esto repercute en que tanto el índice P como el índice T se vean afectados moderadamente en comparación con el resto de las soluciones del frente de Pareto, pero permite un control efectivo de la maleza ya que, en el período de competencia con el cereal, AVEFA no supera los 25 ind/m² en ningún año (Fig. 4.15).

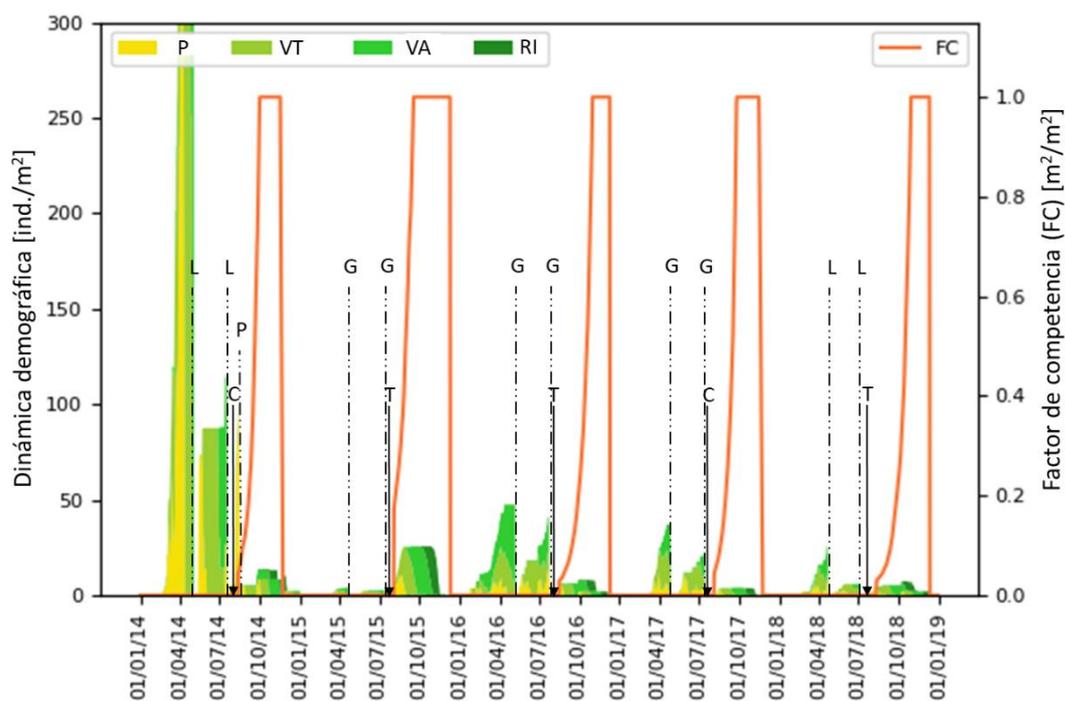


Fig. 4.15: Dinámica poblacional de AVEFA (P : Plántula, VT : Vegetativo Temprano, VA : Vegetativo Avanzado, RI : Reproductivo Inicial) y factor de competencia (FC) de S11 – CASO OII

Respecto del impacto mecánico, tanto S2 como S5 y S6 alcanzan los mejores valores del índice T ($T=5,00$), es decir, la ausencia completa de labranzas. De las tres soluciones, se analizará S5 ya que logra el mejor VA y el peor índice P . Ésta, a diferencia de la mayoría de las otras soluciones del frente de Pareto, establece en los primeros dos años la siembra de trigo altamente competitivo en vez de cebada para controlar el período de mayor infestación. En cuanto al control en barbecho, se propone siempre el uso de glifosato, mientras que se realizan dos aplicaciones de herbicida postemergente en el primer y último año analizado (2014 y 2018). Esta intensidad de aplicaciones explica que el índice P sea de 2,81, el peor de toda la frontera de Pareto desde el punto de vista del impacto químico. Sin embargo, el mayor control postemergente no es suficiente para impedir el avance de la maleza tal como en el caso anterior ya que, en competencia con el cultivo, esta alcanza los 60 ind/m² en su mayor pico en 2015 (Fig. 4.16). Esto también provoca que el rendimiento de los cereales sea menor que en S11, resultando que el VA sea de 195 USD/ha, un 83% del mejor del frente de Pareto.

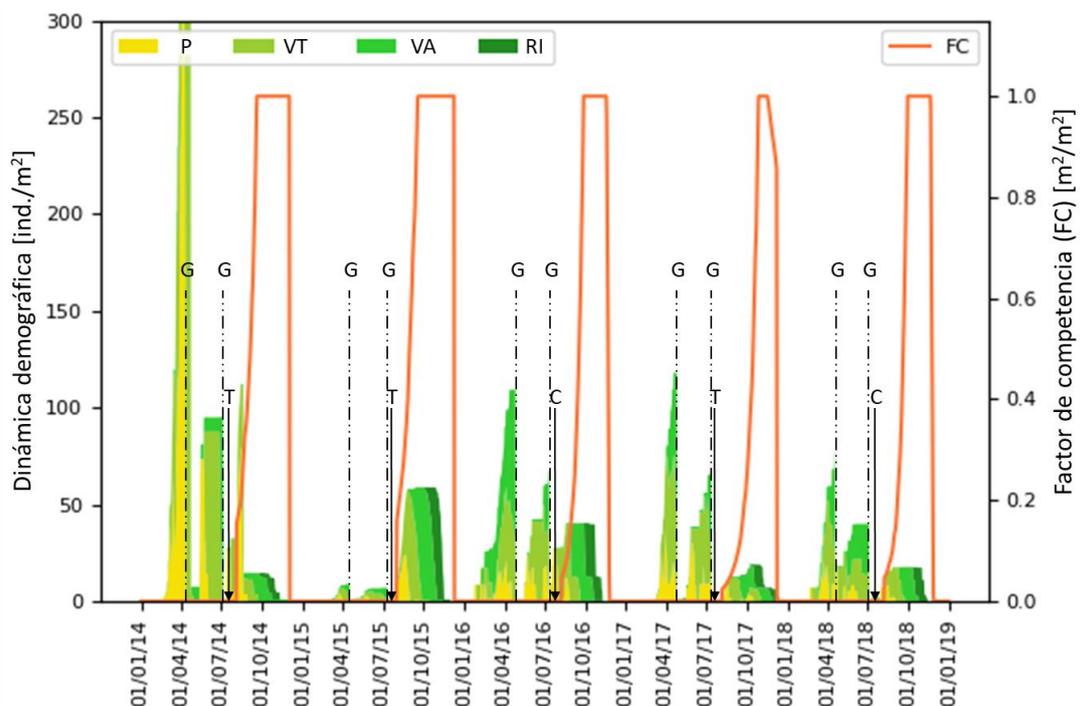


Fig. 4.16: Dinámica poblacional de AVEFA (P : Plántula, VT : Vegetativo Temprano, VA : Vegetativo Avanzado, RI : Reproductivo Inicial) y factor de competencia (FC) de

En lo que concierne al impacto químico, S8 posee el máximo índice P ya que no recomienda control químico presembrado ni postemergente en ningún año. Esta solución propone realizar labranzas antes de la siembra en todo el horizonte de planeamiento lo que, como ya se mencionó, conduce a mayores costos que el barbecho químico y a un índice T posiblemente inaceptable desde el punto de vista de la erosión del suelo. En cuanto a la rotación de cultivos, selecciona cebada en los dos primeros años de análisis, dejando la siembra de trigo para los ciclos con menor competencia con la maleza (2016-2018), optando por un cultivar estándar con mayor rendimiento potencial. La Fig. 4.17 confirma que esta estrategia es la que peor control presenta del frente de Pareto, ya que los picos de maleza en sus diferentes estados fenológicos son de los más altos (en presencia del cultivo, AVEFA alcanza picos de hasta 230 ind./m² en 2015). Esto repercute directamente en el VA de la actividad siendo, con el 7,4% respecto de la mejor de todas las soluciones, el más bajo de la frontera de Pareto.

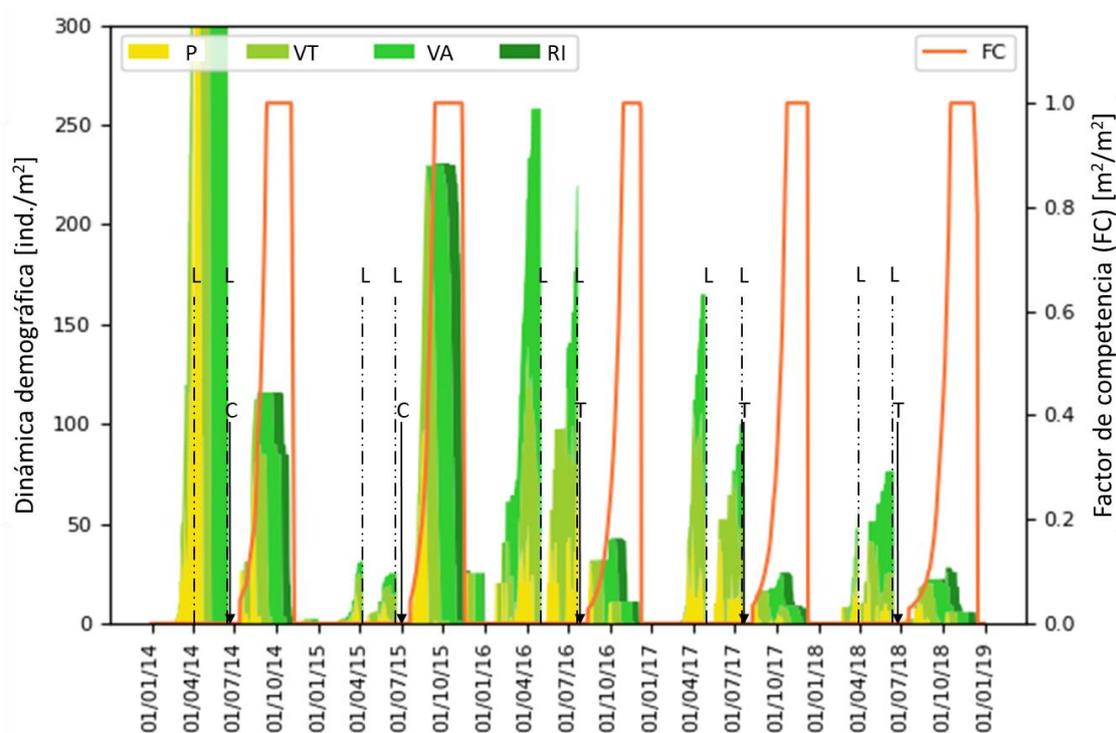


Fig. 4.17: Dinámica poblacional de AVEFA (P : Plántula, VT : Vegetativo Temprano, VA : Vegetativo Avanzado, RI : Reproductivo Inicial) y factor de competencia (FC) de

4.2.3. CASO OIII

Dado que el banco inicial de semillas es muy difícil de determinar y posee una gran incertidumbre (motivo por el cual se realizó el análisis de escenarios en el Capítulo 2), en este caso se analiza cuáles serían las distintas alternativas propuestas por el PSO-MINLP frente a una infestación inicial todavía mayor que la analizada en los casos anteriores. Las funciones objetivo son las mismas que en el CASO OI (minimizar $-VA$, $-\text{Índice } T$ e $-\text{Índice } P$) y no posee ningún tipo de restricciones, pero la diferencia con los otros casos radica en que ahora se incrementa el banco inicial de semillas de 2000 a 3500 semillas/m².

En la Fig. 4.18 se presentan las diecisiete soluciones encontradas por la optimización del CASO OIII en 11,43 h de ejecución en el espacio de las tres funciones objetivo analizadas. Las mismas también se las puede observar en el gráfico de la Fig 4.19.

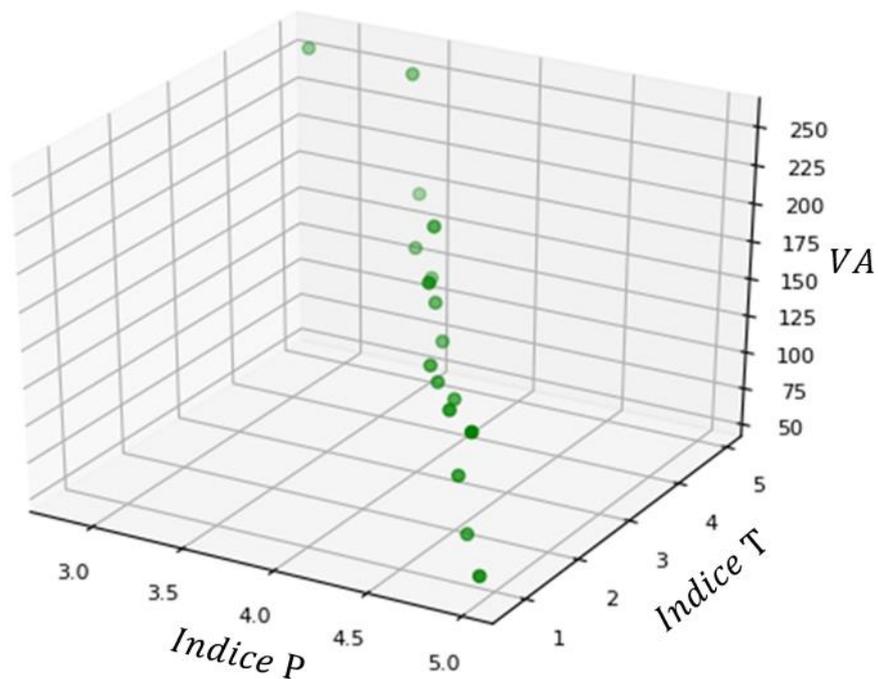


Fig. 4.18: Frente de Pareto CASO OIII

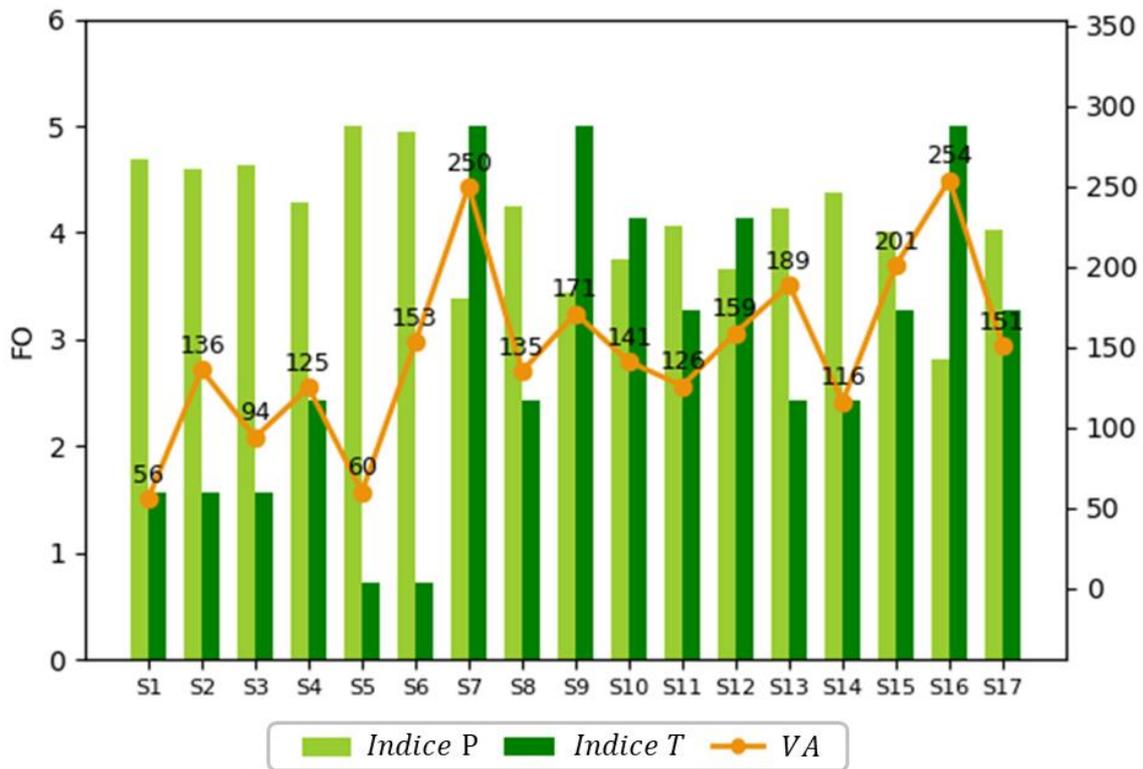


Fig. 4.19: Resultados optimización CASO OIII

La Fig. 4.19 exhibe los VA alcanzados por las distintas soluciones, cuyo promedio es de 148 USD/ha, similares a los del CASO OII (promedio 143 USD/ha) pero mucho menores a los del CASO OI (promedio 195 USD/ha), lo cual permite comprobar que una infestación inicial mayor repercute directamente en el rédito económico de la actividad, independientemente de las estrategias de control adoptadas. Esto sucede porque se incrementa la cantidad de soluciones que proponen la aplicación de herbicidas postemergentes (un 78% del total frente al 50% del CASO OI y al 62,5% del CASO OII), siendo que la mitad de las mismas plantean aplicaciones en dos o más años, lo que conlleva a un mayor gasto en control de malezas. A pesar de utilizar más herbicidas postemergentes, el índice P resulta mejor que en el caso anterior y un poco peor que en el CASO OI, con un promedio de 4,12. Esto se debe a que en este caso se alterna más entre glifosato y labranza a la hora de optar por un control presiembra. Por su parte, el promedio del índice T es de 2,88, apenas mejor que en el CASO OI, pero peor que en el CASO OII.

En la Tabla 4.3 se detalla el plan agronómico propuesto por las diferentes soluciones del frente de Pareto y en el Anexo IV, Tabla AIV.3, las correspondientes fechas de siembra y aplicación de los controles. Todas ellas plantean una mayor cantidad de siembras de cebada que de trigo, tal como sucedió en el CASO OI, debido nuevamente a que la cebada compite mejor con la maleza, razón por la cual es la opción más elegida cuando el banco de semillas es mayor. Cabe destacar que seis de las nueve soluciones que proponen que se siembre trigo, lo recomiendan dentro de los primeros tres años de simulación (S1, S3, S11, S12, S15 y S16) seleccionando el 50% de ellas trigo estándar y el otro 50% trigo altamente competitivo. Por otro lado, S4 y S12 presentan dos siembras de trigo entre 2015 y 2018, ambas sugieren que al menos una de ellas se trate de un cultivar altamente competitivo. Finalmente, sólo dos soluciones (S8 y S9) proponen la siembra de trigo estándar sobre el final del horizonte de planeamiento (2017 y 2018 respectivamente).

En cuanto al tipo de control presiembra, cinco soluciones proponen aplicación de glifosato la mayoría de los años (S7, S9, S10, S12 y S16), otras cinco plantean una mayor realización de labranzas en dicho período (S1, S2, S3, S5 y S6) y siete establecen un control presiembra alternando entre glifosato y labranza en una proporción similar (S4, S8, S11, S13, S14, S15 y S17). Dentro de todas las alternativas del frente de Pareto, las dos que arrojan menor valor de VA son S1 y S5, las cuales se diferencian del resto principalmente en que realizan una mayor cantidad de labranzas (en cuatro y cinco años respectivamente) y ninguna aplicación de herbicida postemergente. Nuevamente esto permite comprobar que, si se busca un mayor VA , no es la mejor opción elegir labranzas como método de control, aunque si se desea minimizar el impacto ambiental por herbicidas conviene, al menos, alternar entre ambos métodos.

Por otro lado, sólo seis de las diecisiete soluciones no realizan un control postemergente (S1, S5, S9, S10, S11 y S14). Las otras once propuestas, aplican al menos un herbicida en 2014, siendo que el 45% de ellas establece sólo una aplicación postemergente y el otro 55% entre dos y tres aplicaciones. Es importante destacar que las cuatro soluciones que mayor VA alcanzan (S13 con 189 USD/ha, S15 con 201 USD/ha, S7 con 250 USD/ha y S16 con 254 USD/ha) utilizan herbicidas postemergentes, comprobando que, aunque aumenten los gastos de control, es más redituable tener mejor controlada la maleza.

Tabla 4.3: Resultados del CASO OIII

Sol.	VA	Índice T	Índice P	2014				2015				2016				2017				2018			
				Cultivo	ρ_S	Control Pre. Post.		Cultivo	ρ_S	Control Pre. Post.		Cultivo	ρ_S	Control Pre. Post.		Cultivo	ρ_S	Control Pre. Post.		Cultivo	ρ_S	Control Pre. Post.	
S1	56	1,57	4,69	C	267	G	-	T-AC	354	L	-	C	264	L	-	C	272	L	-	C	267	L	-
S2	136	1,57	4,59	C	267	L	P	C	269	L	-	C	259	G	-	C	260	L	-	C	260	L	P
S3	94	1,57	4,64	C	272	L	P	C	276	L	-	T-E	340	G	-	C	260	L	-	C	273	L	-
S4	125	2,43	4,28	C	262	G	P	C	257	L	-	C	270	L	P	T-AC	320	L	-	T-AC	283	G	-
S5	60	0,71	5,00	C	269	L	-	C	263	L	-	C	258	L	-	C	274	L	-	C	274	L	-
S6	153	0,71	4,95	C	273	L	P	C	267	L	-	C	256	L	-	C	274	L	-	C	256	L	-
S7	250	5,00	3,39	C	274	G	P	C	274	G	-	C	253	G	-	C	267	G	-	C	260	G	-
S8	135	2,43	4,24	C	267	G	P	C	268	L	P	C	252	G	P	T-E	373	L	-	C	273	L	-
S9	171	5,00	3,43	C	275	G	-	C	272	G	-	C	271	G	-	C	271	G	-	T-E	331	G	-
S10	141	4,14	3,75	C	257	G	-	C	269	G	-	C	274	G	-	C	259	G	-	C	268	L	-
S11	126	3,28	4,06	C	274	L	-	T-AC	348	G	-	C	262	G	-	C	271	G	-	C	258	L	-
S12	159	4,14	3,66	C	270	G	P	T-E	378	G	-	C	271	G	P	C	261	G	-	T-AC	276	L	-
S13	189	2,43	4,23	C	264	L	P	C	272	G	-	C	256	G	-	C	268	L	P	C	259	L	P
S14	116	2,43	4,37	C	265	L	-	C	268	L	-	C	269	L	-	C	272	G	-	C	258	G	-
S15	201	3,28	4,01	C	279	L	P	T-E	366	G	-	C	267	G	-	C	263	L	-	C	254	G	-
S16	254	5,00	2,81	T-AC	298	G	D	C	276	G	-	C	269	G	-	C	262	G	-	C	257	G	P
S17	151	3,28	4,02	C	276	G	P	C	255	L	-	C	272	L	-	C	265	G	-	C	253	G	-

En este caso también se presentará la dinámica poblacional y el factor de competencia del cultivo de las estrategias que presentan el mayor VA (S16), índice T (S9) e índice P (S5).

El mejor VA de 254 USD/ha es alcanzado por S16, cuya dinámica poblacional (Fig. 4.20) permite observar que, en el período de competencia maleza-cultivo (bajo la curva naranja de FC), se alcanzan picos máximos de AVEFA de 40 ind/m². Para lograr este resultado, esta solución propone una siembra de trigo el primer año y cuatro siembras de cebada en los últimos cuatro (2015-2018). En 2014 selecciona trigo altamente competitivo con una alta densidad de siembra (298 semillas/m²) para competir mejor con la maleza. Como control presiembra determina que todos los años se aplique glifosato, lo que provoca que el índice T sea el máximo posible dado que no se emplean labranzas. A su vez, en 2014 y 2018 se realiza un control postemergente, lo que permite que los rendimientos de los cultivos sean los mayores en esos años (datos no mostrados). En cuanto al índice P , es el peor de todo el frente de Pareto, ya que siempre se utilizó control químico. De esta manera, esta estrategia consigue un VA que resulta ser el 79% de la mejor solución encontrada en el CASO OI (S12 con 321 USD/ha) con un índice P que disminuyó al 82,9% de S12-CASO OI (porque se requirió un control postemergente adicional), mientras que el índice T es el mismo (igual a 5,00). Esto demuestra que un aumento en el tamaño del banco de semillas del 75%, afecta la economía, aunque ésta puede controlarse medianamente a costa de provocar un mayor impacto ambiental.

Por otro lado, S9 logra el mejor índice T , al igual que S16, con un mejor índice P (22% mayor que el de S16) y un peor VA (un 67% del de S16). La solución S9 propone una siembra de trigo y cuatro de cebada, pero a diferencia de S16, los primeros cuatro años de simulación selecciona cebada y en el último trigo estándar (2018). A su vez, también utiliza glifosato como control presiembra, pero difiere con S16 en que no realiza ningún tipo de control postemergente, por esa razón su índice P es más alto. En la Fig. 4.21 se aprecia cómo el control en este caso es más deficiente que en S16, ya que la población de AVEFA llega a presentar picos de hasta 260 ind/m² cuando compete con el cereal (2015), lo cual es mucho mayor que para S16 (Fig. 4.20), conduciendo a un VA inferior.

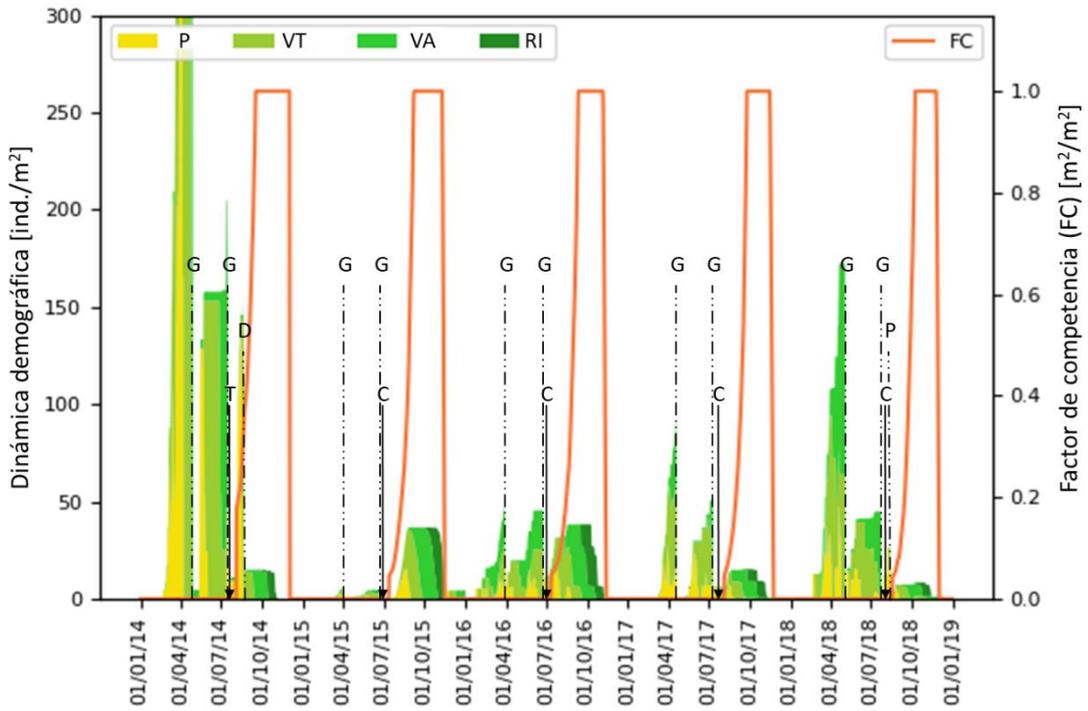


Fig. 4.20: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) de S16 – CASO OIII

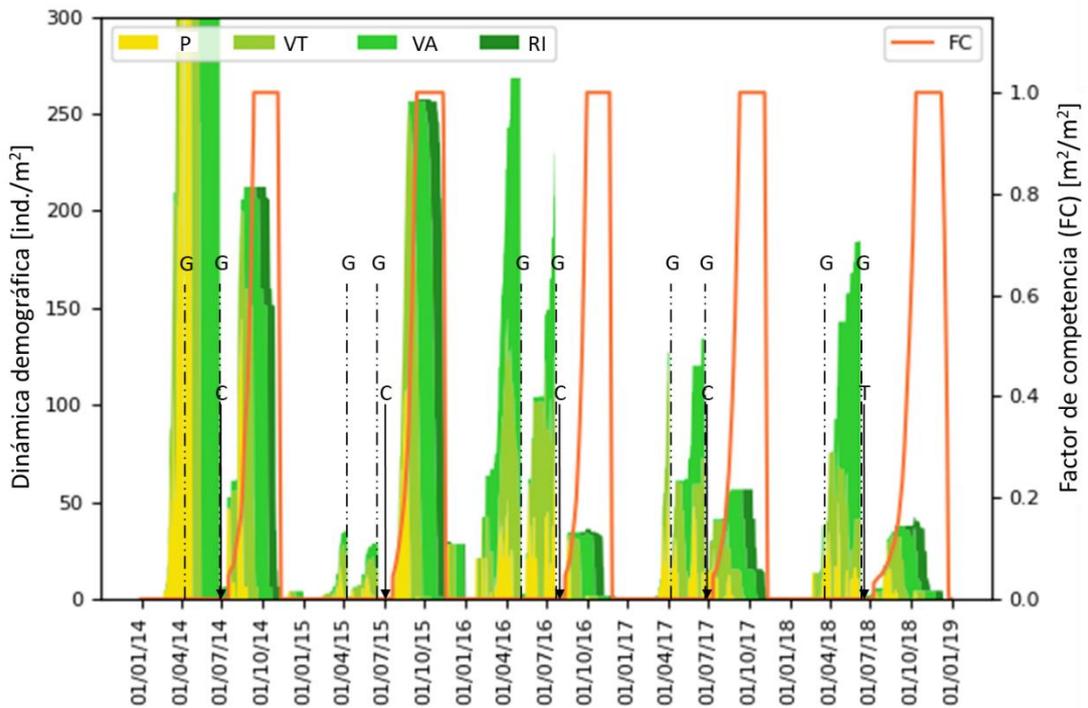


Fig. 4.21: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) de S9 – CASO OIII

Finalmente, S5 es la solución que posee el mejor valor del índice P que podría obtenerse. Esta estrategia implementa labranzas todos los años como control presiembra, lo que ocasiona que el índice T por erosión del suelo sea de 0,71, el más bajo (peor) de todo el frente de Pareto. Como tampoco se recomiendan aplicaciones postemergentes, el índice P se mantiene en 5,00, ya que no se usó control químico en ningún momento. Esto origina que AVEFA (Fig. 4.22) presente picos de hasta 230 ind./m² en la competencia cultivo-maleza, lo que denota un control deficiente. Por esta razón y teniendo en cuenta el hecho de que el control mecánico tiene un costo más elevado que el químico, se logra el en este caso el segundo VA más bajo del frente de Pareto.

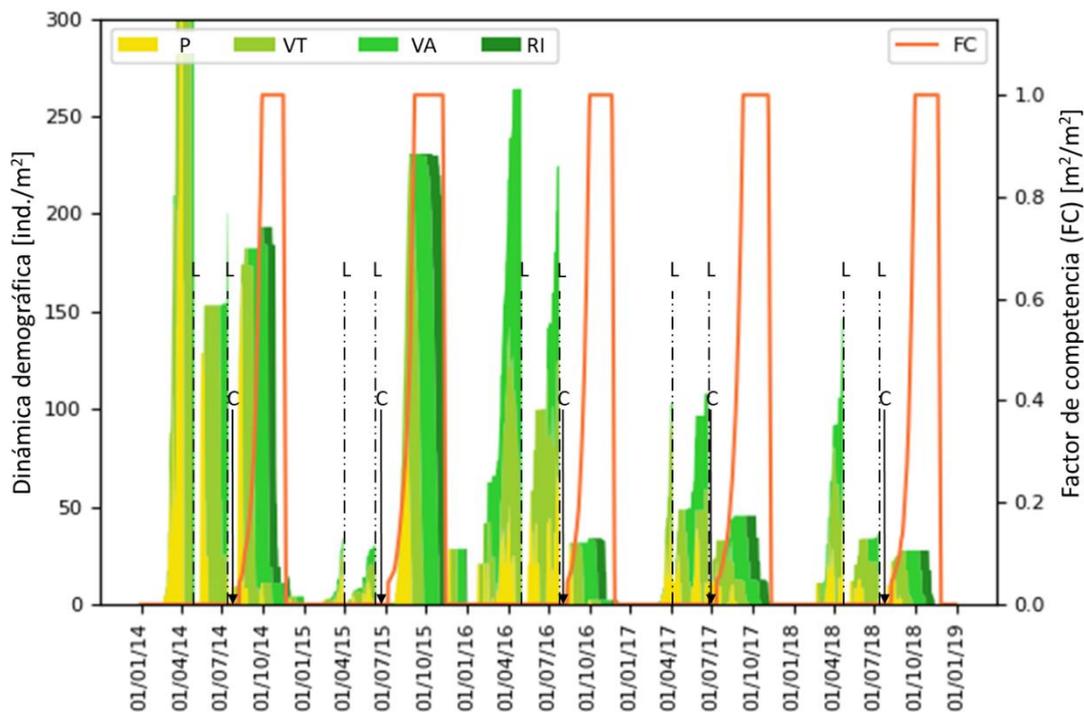


Fig. 4.22: Dinámica poblacional de AVEFA (P : Plántula, VT : Vegetativo Temprano, VA : Vegetativo Avanzado, RI : Reproductivo Inicial) y factor de competencia (FC) de S5 – CASO OIII

4.2.4. CASO OIV

Este experimento persigue representar una posible táctica agronómica que refleje prácticas y objetivos más aproximados a los habituales. Como la labranza es una técnica

relativamente poco utilizada en los últimos tiempos, se decidió incorporar una restricción de igualdad (h_1) para obligar al sistema a elegir solo la aplicación de glifosato como método de control presiembra en los cinco años analizados.

Dado que la labranza no es tenida en cuenta en esta oportunidad, se decidió que en vez de maximizar los índices P y T , se minimice el índice EIQ . De esta manera, el problema de optimización planteado queda definido según la Ec. 4.3.

$$\begin{array}{l} \text{Min } F \left\{ \begin{array}{l} f_1 = -VA \\ f_2 = EIQ \end{array} \right. \\ \text{Sujeto a:} \\ h_1 = \text{Cantidad}_{\text{LabranzaTOTAL}} = 0 \end{array} \quad \left. \vphantom{\begin{array}{l} \text{Min } F \\ \text{Sujeto a:} \\ h_1 = \text{Cantidad}_{\text{LabranzaTOTAL}} = 0 \end{array}} \right| \quad (4.3)$$

El frente de Pareto se presenta en la Fig. 4.23 luego de 11,78 h de cómputo. A diferencia de los casos anteriores, en esta ocasión la frontera de Pareto se compone sólo de cuatro soluciones, dado que no se encuentran otras estrategias que provoquen alguna mejoría en al menos uno de los objetivos. Esto sucede ya que en este caso no se debe decidir qué tipo de control presiembra se llevará a cabo y, además, sólo existen dos funciones objetivo (en vez de tres) para guiar la búsqueda.

En el Anexo IV, Tabla AIV.4, se especifican las fechas de siembra y aplicación de los controles. La Tabla 4.4, que detalla cada una de las soluciones del frente de Pareto alcanzado luego de optimizar el CASO OIV, muestra que, nuevamente, todas las soluciones proponen la siembra de cebada en una mayor cantidad de años que de trigo. Además, se vuelve a comprobar que, si se determina sembrar trigo en los primeros años, se selecciona un cultivar altamente competitivo para combatir mejor la maleza (S3), mientras que, si se lo elige para los últimos años, se opta por un cultivar estándar con mayor rendimiento potencial y menor capacidad de competencia (S1 y S4).

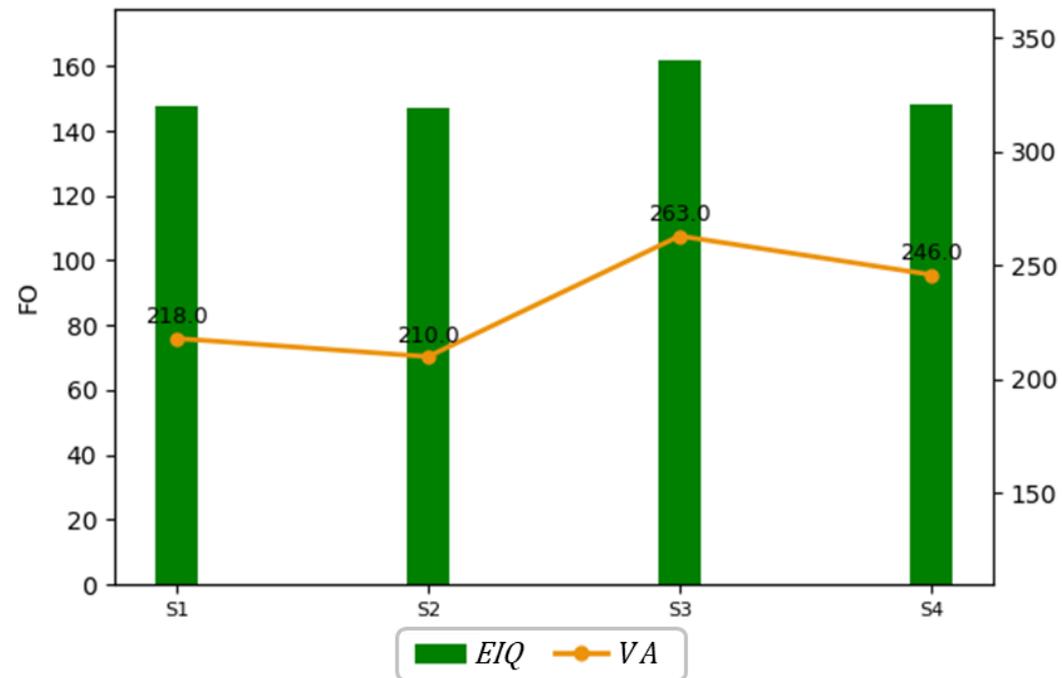


Fig. 4.23: Resultados optimización CASO OIV

Tabla 4.4: Resultados del CASO OIV

Sol.	VA	EIQ	2014				2015				2016				2017				2018			
			Cultivo	ρ_S	Control		Cultivo	ρ_S	Control		Cultivo	ρ_S	Control		Cultivo	ρ_S	Control		Cultivo	ρ_S	Control	
					Pre.	Post.																
S1	218	147,61	C	257	G	P	C	258	G	-	C	260	G	-	T-E	310	G	-	T-E	242	G	-
S2	210	146,88	C	268	G	-	C	266	G	-	C	254	G	-	C	264	G	-	C	266	G	-
S3	263	161,65	T-AC	385	G	D	T-AC	301	G	-	C	254	G	-	C	262	G	-	C	272	G	-
S4	246	148,35	C	266	G	P	C	266	G	P	C	253	G	-	C	261	G	-	T-E	386	G	-

Asimismo, S4 permite visualizar cómo una mayor cantidad de aplicaciones de herbicidas no conduce directamente a obtener el mejor *VA* (alcanza el 69% del más alto), pero sí repercute en un mayor impacto ambiental (aunque no el máximo, dado que una aplicación de diclofop incide más en el *EIQ* que dos de pinoxaden, como se verifica en el *EIQ* de S3).

De las cuatro estrategias que brinda el CASO OIV se presentan, a continuación, la dinámica poblacional de AVEFA y el factor de competencia de los cultivos de las soluciones S3 y S2 que son las que logran el mejor *VA* y menor *EIQ* respectivamente.

La solución S3 (Fig. 4.24) propone la siembra de trigo altamente competitivo los primeros dos años, mientras que en los últimos tres opta por cebada. Como control postemergente solo realiza una aplicación el primer año, el de mayor infestación. Esta estrategia controla eficazmente a la maleza, ya que en el período de competencia con el cultivo los picos de densidad se mantienen por debajo de 30 ind/m² (a excepción del 2014, donde el pico de 95 ind/m² es intervenido con el diclofop-metil), lo que permite alcanzar los mejores rendimientos del cultivo a costa de ser la propuesta con mayor *EIQ*.

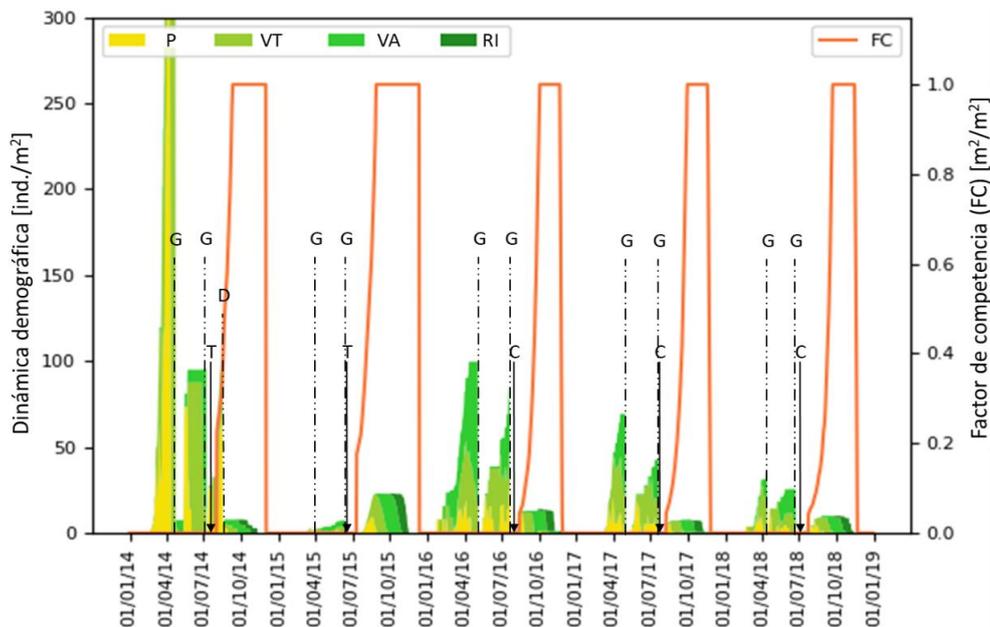


Fig. 4.24: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) de

En cambio, S2 implementa la siembra de cebada en todo el horizonte de planeamiento y no realiza ningún tipo de control postemergente (Fig. 4.25). La combinación de estas medidas provoca un mayor crecimiento de la maleza, presentando un pico máximo de 255 ind/m² en 2015 y logrando, en general, un control más deficiente de AVEFA que en el caso anterior. Esto repercute en el rendimiento del cultivo y el margen bruto de la actividad, conduciendo al menor *VA* del frente de Pareto, aunque presentando el menor impacto ambiental de todas las soluciones halladas.

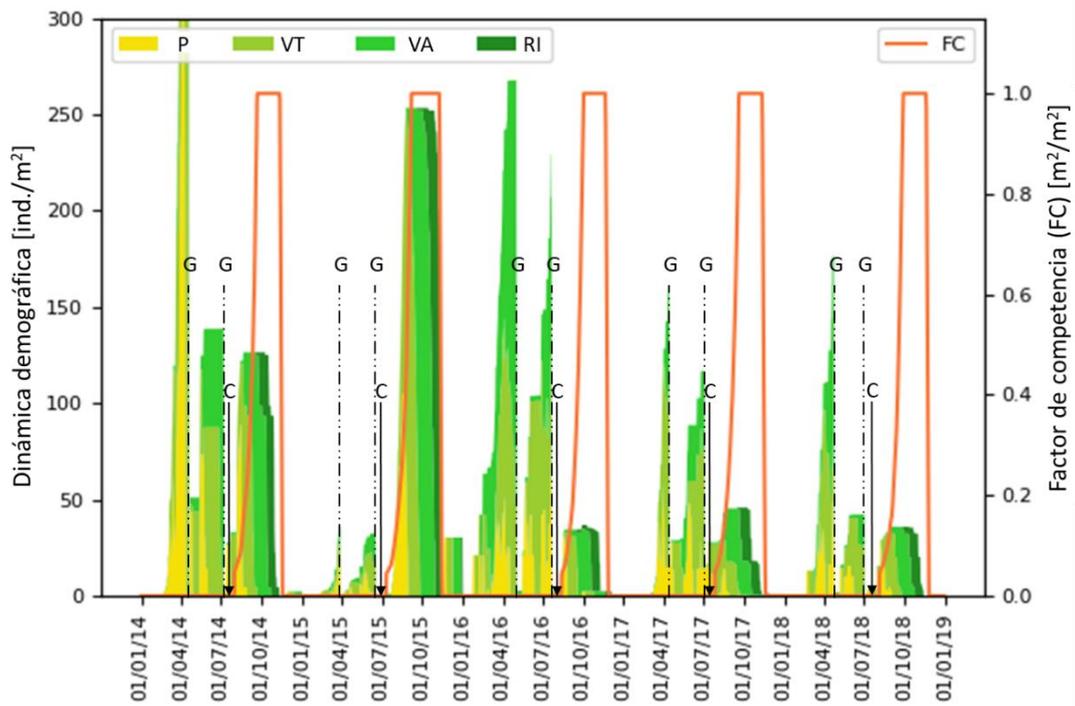


Fig. 4.25: Dinámica poblacional de AVEFA (*P*: Plántula, *VT*: Vegetativo Temprano, *VA*: Vegetativo Avanzado, *RI*: Reproductivo Inicial) y factor de competencia (*FC*) de S2 – CASO OIV

CAPÍTULO 5

CONCLUSIONES Y TRABAJO FUTURO

5.1. Contribución de la tesis y conclusiones generales

Una de las contribuciones principales de esta tesis fue la adaptación y extensión del modelo de simulación agronómico, propuesto por Molinari y col. (2020). El mismo permite estimar los efectos de diferentes estrategias de control sobre la dinámica poblacional de una maleza anual (*Avena fatua* L.) en competencia con cereales de invierno (trigo y cebada) en un plan de rotación multianual. Por ello, en este trabajo se lo integró en una herramienta de asistencia a la toma de decisiones relacionadas al Manejo Integrado de Malezas (MIM).

Este modelo, programado originalmente en una planilla de cálculo, se implementó en el lenguaje de programación de código abierto Python. Este cambio de plataforma permitió lograr aceleraciones del orden de 10x en una ejecución típica, resultando un paso imprescindible para avanzar en la integración del simulador con algoritmos de optimización y realizar exploraciones exhaustivas del espacio de soluciones en tiempos de cómputo razonables.

Otra contribución importante, tendiente a facilitar la integración del simulador con optimizadores, fue programar una relación automática para determinar las distintas fechas del ciclo del cultivo requeridas como datos de entrada del modelo de simulación del cereal.

Estas fechas, que antes se tomaban del software CRONOS, ahora se especifican a través de ecuaciones basadas principalmente en el tiempo térmico acumulado (*TTA*).

A su vez, se extendieron los módulos de evaluación económica y de impacto medioambiental con más términos e indicadores adicionales a los propuestos originalmente.

Específicamente, para estimar el rendimiento económico se adoptaron dos indicadores: el margen bruto (*MB*) y el valor actual (*VA*). El primero considera el beneficio directo anual de la actividad y se determina como los ingresos debido a la venta de los cereales, menos los gastos relacionados con la siembra, cosecha, comercialización y limpieza de las semillas del cultivo, así como con el uso de los distintos métodos de control de malezas. Sin embargo, dado que la herramienta de simulación propuesta permite analizar un horizonte de varios años, se consideró necesario cuantificar de qué manera los márgenes brutos futuros se reflejaban en la actualidad, por ello se introdujo el *VA*. Este índice permite establecer rápidamente, según su signo y magnitud, si resulta conveniente o no la adopción de estrategias de manejo específicas, constituyendo una herramienta de análisis fundamental para la toma de decisiones.

Con respecto al impacto ambiental, si bien existen numerosas formas de medirlo, en esta tesis se consideraron dos criterios de evaluación: el Coeficiente de Impacto Ambiental (*EIQ*) y los índices de riesgo de herbicidas (*P*) y de labranzas (*T*) (Ferraro y col., 2003). El *EIQ* está diseñado únicamente para cuantificar el impacto de los agroquímicos, siendo la metodología más popular empleada en los estudios agronómicos. Sin embargo, como su aplicabilidad es limitada debido a que no refleja los daños asociados a otras acciones de control de malezas (como por ejemplo labranzas), se incorporaron los índices de labranza y de herbicidas mencionados para complementar este análisis.

Con este modelo de simulación junto con sus módulos de evaluación económica y ambiental, se diseñaron cinco casos de estudio representativos de distintos escenarios de manejo de *Avena fatua* L. en competencia con trigo y cebada por un horizonte de planificación de cinco años. Las estrategias de MIM analizadas incluyen un uso bajo y alto de herbicidas en combinación con medidas culturales y control mecánico en presiembra (labranza).

El análisis de estas cinco estrategias permitió concluir que, en el período analizado, el control postemergente con herbicidas resultó indispensable para lograr resultados económicos razonables, aunque no necesariamente debieron aplicarse todos los años del horizonte estudiado. Por otro lado, se comprobó que la realización sostenida de labranzas

como control presiembra provoca riesgos medioambientales inaceptables y, a su vez, reduce el margen económico neto. Los mejores resultados económicos y de control de malezas, con impacto ambiental moderado, se obtuvieron combinando medidas de acción químicas y culturales.

Sin embargo, existen muchas más combinaciones de los distintos métodos de control que las de las cinco estrategias propuestas, aun para el sistema bajo estudio. A pesar de que éste podría considerarse acotado, tanto en número de cultivos posibles, medidas de manejo y extensión del horizonte de estudio, se podría llegar a conducir a mejores resultados que los casos analizados.

Dada entonces la necesidad de explorar de manera sistemática un enorme espacio de posibles estrategias, se desarrolló una implementación computacional propia de un algoritmo de optimización, con el objetivo de identificar automáticamente aquellas estrategias más prometedoras teniendo en cuenta un menor impacto ambiental y/o un mayor beneficio económico. Este algoritmo de optimización constituye la segunda contribución principal de este proyecto.

La herramienta de optimización se basó en un algoritmo estocástico no-lineal, el optimizador por enjambre de partículas (PSO). Este método se eligió debido a que se han reportado buenos resultados sobre diversas aplicaciones, es relativamente sencillo de programar y posee una gran flexibilidad para ser hibridado con otros métodos y extender sus prestaciones.

Sin embargo, para poder aplicar este optimizador al modelo agronómico desarrollado, fue necesario añadir al PSO original, un tratamiento de restricciones, de variables binarias y de múltiples objetivos. Primero, se incorporó la metodología basada en “violaciones absolutas totales” que permite el manejo de restricciones tanto de igualdad como de desigualdad.

Luego, se añadió una metodología *ad hoc* para manipular variables binarias (*Angle Modulation*) que sólo agrega cuatro coeficientes al espacio continuo original del problema. Las variables binarias se emplean para establecer qué cultivo se sembrará, el tipo de cultivar y qué método de control se seleccionará a lo largo del horizonte de planeamiento.

Por último, como se buscaba encontrar las mejores soluciones que cumplieran con dos o más criterios, se programó la técnica del frente de Pareto. Ésta presenta como resultado un conjunto de soluciones, donde cada una es mejor que las restantes en al menos uno de los objetivos analizados. De esta manera, en el caso de MIM, es posible determinar la frontera de Pareto correspondiente a los objetivos de minimizar el impacto ambiental y maximizar el beneficio económico. En el contexto de MIM, contar con una lista de alternativas se considera preferible a presentar una única solución “óptima” en algún sentido abstracto.

Si bien todas las metodologías incorporadas al PSO se implementaron para poder resolver el modelo agronómico de MIM, es necesario destacar que la herramienta de optimización se creó como de propósito general. Es decir, la misma también es útil para optimizar cualquier otro modelo mixto-entero no lineal con múltiples objetivos, dado que se adoptó una filosofía de programación que buscó mantener de manera separada el motor de búsqueda y el modelo de simulación.

Para testear la metodología propuesta se optimizaron cuatro escenarios, que difieren entre sí tanto por las funciones objetivo a optimizar como por las restricciones impuestas. En la mayoría de los casos de estudio, la búsqueda prioriza la elección de cebada por sobre la de trigo en gran parte de los años. Esto se debe a que éste cereal compite mejor con la maleza, principalmente porque las fechas de siembra de dicho cultivo resultan más favorables para el perfil de emergencia de AVEFA en los años analizados.

En cuanto al control presiembra, muchas soluciones alternan entre la selección de glifosato y labranza, aunque las que mejor VA logran son las que realizan mayormente barbecho químico, dado que la labranza reduce el margen de ganancia. A su vez, en líneas generales, se puede concluir que para obtener un mayor VA se recomienda aplicar, al menos una vez, algún control postemergente. Sin embargo, las soluciones reportadas suelen ser muy variadas entre sí, brindando la posibilidad al usuario de optar por aquella que considere más conveniente en su momento, ya sea priorizando la rentabilidad de la actividad, un menor impacto ambiental o una solución de compromiso entre ambos criterios.

En conclusión, el optimizador desarrollado aplicado sobre el modelo agroeconómico constituye la base de una herramienta para guiar el complejo proceso de toma de decisiones de la actividad agrícola. Este sistema permite establecer el mejor esquema de rotación de cultivos y de tratamientos para combatir la maleza en función de la rentabilidad económica y el impacto medioambiental. Asimismo, se proporcionan las fechas de siembra y de aplicación dado que se emplea un modelo de emergencia de la maleza a campo como función de las variables climáticas esenciales (temperatura ambiente y precipitaciones). Si bien estas variables poseen una gran incertidumbre, especialmente en estudios que involucran meses o años, la discretización diaria de la línea del tiempo permite, en teoría, realizar estudios sumamente detallados posibilitando hacer uso de la abundante cantidad de datos históricos meteorológicos disponibles.

Finalmente, la implementación de la herramienta en un lenguaje de software libre implica una gran ventaja a la hora de realizar actividades de transferencia, frente a alternativas que requieran el pago de una licencia comercial. Respecto a este punto, actualmente existe una versión del modelo disponible en un sitio de internet público¹ que cuenta con dos módulos. Uno de ellos permite establecer el pronóstico de la maleza, el cual predice la emergencia de las principales malezas del sudoeste bonaerense (*Avena fatua* L., *Lolium multiflorum* y *Vicia villosa*). En cambio, el otro predice la interacción entre trigo y *Avena fatua* L., estimando el impacto de una estrategia de control químico en barbecho establecida para un horizonte de planeamiento de un año, permitiendo observar en un gráfico la evolución de los distintos estados fenológicos de la maleza, así como también el área foliar del cultivo (TPLA).

5.2. Trabajo Futuro

A medida que se realizaba esta tesis se identificaron varios aspectos interesantes para desarrollar y profundizar que podrían extender las prestaciones de la herramienta creada.

¹ <http://pronostico-malezas.frbb.utn.edu.ar/>

Desde el punto de vista del simulador se prevé la incorporación de:

- *Nuevos cultivos*

El desarrollo del modelo se planteó de la manera más general posible para poder añadir también cultivos de verano como maíz, soja y girasol, ya que de esa manera se realizaría un uso más intensivo del suelo durante todo el ciclo agronómico tal como sucede en zonas menos áridas que en el sector de Bordenave, como por ejemplo en el centro de la Pcia. de Buenos Aires (Tres Arroyos, Olavarría-Azul).

- *Nuevas malezas*

En cuanto a las malezas, también sería significativo poder simular otras muy perjudiciales, como lo es por ejemplo el raigrás (*Lolium multiflorum*) que, además, está presentando resistencia a herbicidas.

- *Nuevos métodos de control de malezas*

Dado que como método de control no químicos solo se consideró labranzas en barbecho, si se tuvieran en cuenta otras formas de disminuir la población de malezas existirían más posibilidades de seleccionar otras estrategias que reduzcan la potencial aparición de resistencia a herbicidas. Ejemplos de estas alternativas serían el empleo de cultivos de cobertura, y el pastoreo de animales.

- *Una forma de simular la resistencia de las malezas a los controles químicos*

La resistencia de las malezas a los agroquímicos afecta considerablemente a las estrategias de manejo de malezas y a la rentabilidad de la actividad, es importante poder representarla en el modelo, ya que es un tema que cada vez está cobrando más importancia debido a los efectos negativos que ocasiona. Una posibilidad es modelar dos poblaciones coexistentes de la misma especie, una susceptible y una resistente a los herbicidas. Simulaciones por periodos de varios años permitirían investigar la evolución de cada una de las poblaciones y cuantificar la dinámica de instalación de la variante resistente.

- *Una representación del estado del suelo*

El suelo se ve afectado por la presencia de las malezas y los cultivos, ya que utilizan sus recursos (tales como agua y nutrientes) para poder desarrollarse. Además, el uso de ciertos métodos de control, como la labranza, provocan perturbaciones en las propiedades del suelo. Todos estos factores afectan finalmente al rendimiento del cultivo y a una adecuada selección del método de control. Por estos motivos, en trabajos futuros es importante considerar el modelado de la interacción del suelo con las estrategias de MIM que se podrían realizar.

- *Incorporación de incertidumbre*

La mayoría de los parámetros del modelo poseen una significativa incertidumbre, en especial si se considera que se están simulando periodos de varios años. Tal es el caso, por ejemplo, de los parámetros climáticos y los relacionados con el módulo económico (precios y costos). En primer lugar, debería identificarse mediante un análisis de sensibilidad global del modelo agronómico los más influyentes en las variables de salida. A continuación, debería plantearse un problema de optimización bajo incertidumbre paramétrica para investigar el espacio de MIM.

Por otro lado, desde la perspectiva del optimizador, se identificó como una opción interesante:

Acelerar el algoritmo de optimización

Considerando el elevado tiempo de ejecución reportado en los casos de optimización analizados (mayor a 11 horas), se considera la posibilidad de acelerar los tiempos de cómputo de este algoritmo. Para ello, existen diversas herramientas o metodologías que podrían utilizarse. Una opción podría ser la librería JAX. Esta aplicación permite acelerar las funciones de Python y NumPy mediante la compilación “just in time” y la paralelización automática. De esta manera se puede obtener un mejor rendimiento del algoritmo sin tener que salir de Python, lo que la vuelve una opción muy atractiva para aplicar.

Por último, en cuanto a la transferencia de la herramienta al medio productivo, se considera la posibilidad de:

Extender las prestaciones del simulador en línea

El módulo de interacción maleza-cultivo actualmente en línea¹ presenta sólo una estrategia de MIM fija a lo largo de una única temporada, con actualización diaria del pronóstico meteorológico y presentando solo las variables agronómicas. En el futuro se prevé ampliar su alcance permitiendo que el usuario pueda simular la estrategia de su interés. Asimismo, se procurará incorporar los módulos económico y medioambiental y mostrar los resultados de una manera amigable e intuitiva.

Anexo I: Nomenclatura y parametrización del modelo cultivo-maleza

Tabla AI.1: Parámetros del cultivo

<i>Parámetro</i>	<i>Unidades</i>	<i>Descripción</i>
$Precio_{venta_{cultivo}}$	<i>USD/ton</i>	Precio de venta del cultivo.
$Gastos_S$	<i>USD/ha</i>	Gastos de siembra del cultivo: representa el costo de compra de la semilla, de su siembra y del fertilizante aplicado. Se considera un gasto fijo que sólo varía de acuerdo al cultivo seleccionado y a la densidad de siembra.
$Porcentaje_{Gastos_{sc}}$	%	Porcentaje correspondiente a gastos de cosecha y comercialización del cultivo. Varía de acuerdo al tipo de cultivo cosechado.
$TTMF_{cultivo}$	$^{\circ}C$	Tiempo térmico de madurez fisiológica: grados térmicos acumulados necesarios para que el cultivo alcance la madurez fisiológica.
$DSE_{cultivo}$	<i>plantas/m²</i>	Densidad de siembra estándar: es la densidad de siembra comúnmente utilizada en la región de estudio.
$A_{cultivo}$ y $K_{cultivo}$	-	Parámetros de pérdida de rendimiento del cultivo con la maleza: Componen la ecuación para estimar el rendimiento del cultivo en competencia con la maleza.
$SC_E_PCC_{cultivo}$	-	Susceptibilidad del cultivo a la maleza entre la fecha de emergencia y de inicio del periodo crítico del cultivo (PCC): representa el grado en que el cultivo es afectado por la maleza en ese período.

Tabla AI.1 (continuación): Parámetros del cultivo

Parámetro	Unidades	Descripción
$SC_{PCC_{cultivo}}$	-	Susceptibilidad del cultivo a la maleza a partir del comienzo y hasta el final del periodo crítico del cultivo (PCC): representa el grado en que el cultivo es afectado por la maleza en ese período.
$SC_{PCC_{MF_{cultivo}}}$	-	Susceptibilidad del cultivo a la maleza desde el fin del periodo crítico del cultivo (PCC) y hasta la fecha de madurez fisiológica del cultivo: representa el grado en que el cultivo es afectado por la maleza en ese período.

Tabla AI.2: Parámetros de la maleza

Parámetro	Unidades	Descripción
TTA_{EF}	$^{\circ}C$	Tiempo térmico acumulado para alcanzar cada estado fenológico: representa los grados día acumulados que requiere la planta para alcanzar cada estado fenológico.
$CA_{máx}$	$ind./m^2$	Capacidad de porte del agroecosistema: es la máxima cantidad de individuos de la misma especie que pueden coexistir antes que la competencia intraespecífica controle el crecimiento de la maleza.
FP_{EF}	-	Factor de competencia ponderada para cada estado fenológico de la maleza: determina la magnitud de la competencia que ejerce la maleza de un dado estado fenológico en relación con el resto de ellos.
lb	-	Representa las pérdidas de semillas por predación en el período comprendido entre la cosecha de un cultivo y la siembra del siguiente cultivo (barbecho).

Tabla AI.2 (continuación): Parámetros de la maleza

Parámetro	Unidades	Descripción
ld	-	Representa las pérdidas de semillas por dispersión.
sm	-	Representa las pérdidas de semillas por mortalidad natural.
$q[t]$	%	Representa el porcentaje del banco de semillas del año t de las semillas que son quiescentes.
Fec_{coh1}	<i>Sem./ind.</i>	Fecundidad de la cohorte 1.
Fec_{coh2}	<i>Sem./ind.</i>	Fecundidad de la cohorte 2.
$Prod. Sem_{máx}$	<i>Sem./ind.</i>	Producción máxima de semillas de maleza.

Tabla AI.3: Parámetros de los métodos de control

Parámetro	Unidades	Descripción
$Nombre_{control}$	-	Nombre del método de control.
$Precio_{control}$	<i>USD/L o kg</i>	Precio del método de control.
$Costo_{aplic}$	<i>USD/ha</i>	Costo de aplicación del método de control.
$Control_{EF}$	%	Eficiencia en el control de cada estado fenológico de la maleza.
$Residualidad$	<i>Días</i>	Duración del efecto residual sobre plántulas.

Tabla A1.3 (continuación): Parámetros de los métodos de control

Parámetro	Unidades	Descripción
<i>ia</i>	%	Concentración del ingrediente activo del herbicida. Suelen estar especificados en el marbete o etiqueta de cada herbicida.
<i>Aplic_{MC}</i>	<i>L o kg/ha</i>	Aplicaciones de un método de control por hectárea. Suelen estar especificados en el marbete o etiqueta de cada herbicida.
<i>EIQ_{ia}</i>	-	Coefficiente de impacto ambiental de cada ingrediente activo presente en el herbicida (establecidos en ¹).
<i>STU</i>	-	Cantidad de rastrojo restante luego de la labranza.
<i>STA</i>	-	Estabilidad de los agregados del suelo.
<i>LCC</i>	-	Clase de capacidad del suelo.
<i>LD_{50r}</i>	<i>mg ia/1000g rata</i>	Dosis letal oral aguda para 50 ratas.
<i>LD_{50a}</i>	<i>mg ia/abeja</i>	Dosis letal oral aguda para 50 abejas.

¹ <https://nysipm.cornell.edu/eiq/list-pesticide-active-ingredient-eiq-values/>

Tabla AI.4: Datos de Trigo y Cebada

	Trigo	Cebada
$Precio_{venta_{cultivo}}$ [USD/ton]	185	150
$Porcentaje_{Gastos_{cc}}$ [%]	30	25
$TTMF_{cultivo}$ [°C]	2260	1727
$DSE_{cultivo}$ [plantas/m ²]	200	250
$A_{cultivo}$	100	1
$K_{cultivo}$	5	2
$SC_{E_{PCC_{cultivo}}}$	1	1
$SC_{PCC_{cultivo}}$	5	5
$SC_{PCC_{MF_{cultivo}}}$	1	1

Tabla AI.5: Datos de *Avena Fatua* L.

	<i>Avena Fatua</i> L.
$TTA_{Plántula}$ [°C]	70
$TTA_{Veg. Temprano}$ [°C]	280
$TTA_{Veg. Avanzado}$ [°C]	400
$TTA_{Rep. Inicial}$ [°C]	300
$CA_{máx}$ [ind/m ²]	250
$FP_{Plántula}$	0.15
$FP_{Veg. Temprano}$	0.30
$FP_{Veg. Avanzado}$	0.60
$FP_{Rep. Inicial}$	1.00
lb	0.2075

Tabla AI.5 (continuación): Datos de *Avena Fatua* L.

<i>Avena Fatua</i> L.	
ld	0.6700
sm	0.0732
$q[t - 1]$	0.70
$q[t - 2]$	0.20
$q[t - 3]$	0.10
Fec_{coh_1} [Sem/ind]	187.16
Fec_{coh_2} [Sem/ind]	19.28
$Prod.Sem_{m\acute{a}x}$ [Sem/ind]	14500

Tabla AI.6: Datos de los métodos de control de malezas

Método	Labranza	Glifosato	Pinoxaden	Diclofop
$Control_{Pl\acute{a}ntula}$ [%]	100	99	100	100
$Control_{Veg. Temprano}$ [%]	100	99	90	90
$Control_{Veg. Avanzado}$ [%]	100	99	70	70
$Control_{Rep. Inicial}$ [%]	100	50	20	20
Precio [USD/L o kg]	0.90	4	42	26.05
$Costo_{aplic}$ [USD/ha]			10	
EIQ_{ia}	0	15.30	15.30	26
ia [%]	0	48	6	28
$Dosis$ [L o kg/ha]	44.50	2	0.80	2

Tabla A1.6 (continuación): Datos de los métodos de control de malezas

Método	Labranza	Glifosato	Pinoxaden	Diclofop
<i>STU</i>	0.1	-	-	-
<i>STA</i>	0.2	-	-	-
<i>LCC</i>	IV	-	-	-
<i>LD</i> _{50r} [mg ia /1000 g rata]	-	2000	3000	512
<i>LD</i> _{50a} [mg ia/abeja]	-	200	100	131

Tabla A1.7: Parámetros propios del caso a simular

Parámetro	Unidades	Descripción
$Fecha_{inicial}$	día/mes/año	Fecha inicial de simulación.
$Tiempo_{simulación}$	años	Tiempo de simulación.
$Rotación_{cultivos}$	-	Esquema de rotación de los cultivos: se debe especificar el cultivo que se siembra cada año.
$Fecha_{siembra_{cultivo}}$	día/mes/año	Fecha siembra cultivo: es determinada por el usuario, según el caso que desea simular.
$DAC_{cultivo}$	plantas/m ²	Densidad actual de siembra: es la densidad con la que se siembra el cultivo.
$MPRM_{cultivo}$	-	Máxima pérdida de rendimiento del cultivo por malezas: representa el porcentaje de cosecha del cultivo que puede perderse debido a una alta competencia de malezas.
$RP_{cultivo}$	ton/ha	Rendimiento potencial del cultivo: es el rendimiento máximo que podría alcanzar el cultivo bajo condiciones óptimas de todos los factores de la producción. Este dato es específico de cada cultivo y varía de acuerdo a su competitividad.
$BS_{inicial}$	Sem/ha	Banco inicial de semillas de malezas: representa la infestación inicial de semillas de malezas por hectárea en donde se realizará la simulación del crecimiento de un cultivo en competencia con una maleza.
$TPLA_{máx_{cultivo}}$	m ² /m ²	Área foliar máxima del cultivo: total de área de hoja presente por unidad de área de cultivo. TPLA caracteriza una canopia (conjunto verde de la planta) en un agroecosistema, siendo clave en el análisis del crecimiento de los cultivos, su productividad, el uso del agua, el manejo de las malezas y de las enfermedades.

Tabla A1.7 (continuación): Parámetros propios del caso a simular

Parámetro	Unidades	Descripción
$Control_{maleza}$	-	<i>Controles de maleza aplicados</i> : nombres de los controles de maleza que se aplicaron en la simulación.
$Fecha_{control}$	día/mes/año	<i>Fecha de aplicación de los controles de maleza</i> .
$\%Sem_{Cocec}$	%	<i>Porcentaje de semillas de maleza levantadas en la cosecha</i> : cantidad de semillas de maleza que son cosechadas junto con el cultivo con respecto al total de semillas producidas.
$\%Sem_{zar}$	%	<i>Porcentaje de Semillas de maleza con el cultivo cosechado</i> : cantidad de semillas que continúan con el cultivo con respecto a las que ingresaron a la cosechadora, luego del zarandeo que realiza la propia cosechadora.
$Costo_{zar}$	USD/zar	<i>Costo de zarandeo</i> : costo por zarandear la muestra de semillas y grano luego de la cosecha. Según la Acondicionadora de Cereales Bahía ²) es de 5 USD/zarandeo.
$Costo_{Limpieza}$	USD/ton	<i>Costo fijo de limpieza del grano</i> : según INTA ³ , para trigo y cebada es de 1708.69 \$/ton.
$T_{mín}, T_{máx}, T_{media}$ y <i>Precipitaciones</i>	°C, mm	<i>Pronóstico (o registro histórico) del estado del tiempo</i> : se debe proveer el registro meteorológico o el pronóstico diario de las temperaturas mínimas ($T_{mín}$), máximas ($T_{máx}$) y medias (T_{media}), así como las precipitaciones. Con esta información se estima la emergencia diaria y se calculan los Grados Día acumulados necesarios para monitorear el pasaje entre estados fenológicos de la maleza.

² http://www.acbsa.com.ar/documentos/Tarifario_ACBSa.pdf

³ <https://inta.gob.ar/servicios/limpieza-de-semillas>

Anexo II: Modelos de simulación de los cultivos y la maleza

All.1 Modelo de simulación del cultivo

El modelo de simulación de cultivos posee una discretización diaria del horizonte de planeamiento, es decir, se realiza un seguimiento día a día de la evolución de las principales variables que lo representan. En primer lugar, se calcula el tiempo térmico acumulado (TTA) (Ec. All.1a) a partir de los grados térmicos diarios (GD). Se utiliza la definición habitual GD que se corresponde con la temperatura media de cada día (Ec. All.1b). Las temperaturas diarias las debe proveer el usuario a lo largo de todo el período de simulación que desee analizar, ya sea a través de registros históricos o predicciones meteorológicas.

$$TTA[día] = \sum_{d=1}^{día} GD_d \quad (All.1a)$$

donde $TTA[día]$ es el tiempo térmico acumulado en [°C] hasta ese día; GD_d representa los grados térmicos diarios en [°C] del día d y $día$ se refiere al día actual de la fecha de simulación.

$$GD_d = \frac{T_{max_d} - T_{min_d}}{2} \quad (All.1b)$$

donde T_{max_d} es la temperatura máxima en [°C] del día d y T_{min_d} la temperatura mínima en [°C] del día d .

El tiempo térmico acumulado permite establecer el área foliar total de la planta (*TPLA*). Esta variable representa la cantidad de superficie de las hojas (m²) que se encuentra en una determinada superficie de terreno (m²) (Aguirre-Salado y col., 2011). El *TPLA* es un buen indicador del desarrollo y la salud de los cultivos (Labbafi y col. 2019), y puede empleárselo para cuantificar la competencia del cultivo sobre la maleza.

Para el cálculo de *TPLA* se emplean las correlaciones propuestas en Molinari y col. (2020) para trigo y cebada (Ecs. AII.2a y AII.2b). Ambas ecuaciones plantean que, si la fecha actual se encuentra entre la fecha de emergencia y la de madurez fisiológica del cultivo, el área foliar total de la planta será función del tiempo térmico acumulado hasta esa fecha, pero si esta fuera de ese período, *TPLA* será igual a cero.

Para todo d en (1, tiempo_{simulación}):

Si $Fecha[d] \geq Fecha_{Emergencia_{TRIGO}}$ y $Fecha[d] < Fecha_{MF_{TRIGO}}$:

Si $TTA[d] < 1116$:

$$TPLA_{TRIGO}[d] = 0.1138e^{0.003714 * TTA[d]}$$

Si $1116 \leq TTA[d] < 2260$:

$$TPLA_{TRIGO}[d] = 0.0812 * TTA[d] + 5.02 * 10^{-5} * TTA[d]^2 - 1.07 * 10^{-8} * TTA[d]^3$$

Sino:

$$TPLA_{TRIGO}[d] = 0$$

(AII.2a)

Para todo d en (1, tiempo_{simulación}):

Si $Fecha[d] \geq Fecha_{Emergencia_{CEBADA}}$ y $Fecha[d] < Fecha_{MF_{CEBADA}}$:

Si $TTA[d] < 870$:

(AII.2b)

$$TPLA_{CEBADA}[d] = 0.02e^{0.0054*TTA[d]}$$

Si $870 \leq TTA[d] < 1480$:

$$TPLA_{CEBADA}[d] = 0.336 - 7.51 * 10^{-4} * TTA[d] \\ + 1.15 * 10^{-6} * TTA[d]^2$$

Sino:

$$TPLA_{CEBADA}[d] = 0$$

donde $Fecha_{Emergencia_{CULTIVO}}$ es la fecha de emergencia del cultivo [día/mes/año]; $Fecha_{MF_{CULTIVO}}$ es la fecha de madurez fisiológica del cultivo [día/mes/año]; y $TPLA[d]$ es el área foliar total de la planta hasta el día d expresado en [m^2/m^2].

Luego, con el dato de $TPLA$, es posible precisar el factor de competencia diaria del cultivo sobre la maleza (FC) según la Ec. AII.3. Este factor indica el grado en que el cultivo permite el avance o crecimiento de la maleza en su presencia, influyendo en la competencia interespecífica generada entre estas dos especies (la cual se explicará con más detalle en el modelo de simulación de maleza de la siguiente sección). Su valor puede variar entre 0 y 1, cuando FC es igual a cero no existe competencia, en cambio, cuando FC es igual a uno, la competencia ejercida es la máxima.

Para todo d en $(1, tiempo_{simulación})$:

$$FC[d] = \frac{(TPLA[d]/TPLA_{m\acute{a}x}) * DAC}{DSE}$$

(AII.3)

donde $FC[d]$ el factor de competencia diaria del cultivo sobre la maleza; $TPLA_{m\acute{a}x}$ es el área foliar máxima del cultivo [m^2/m^2]; DAC es densidad actual de siembra del cultivo [$plantas/m^2$] y DSE es la densidad de siembra estándar [$plantas/m^2$].

Adicionalmente, se calcula la susceptibilidad del cultivo a la competencia (SC) de acuerdo a su estado de desarrollo en cada momento (Ec. All.4). La susceptibilidad del cultivo a la competencia interespecífica (con otra especie) se evalúa desde su emergencia y hasta el inicio de su madurez fisiológica, siendo más importante el efecto durante el período crítico de competencia de la maleza con el cultivo (PCC).

Para todo d en $(1, tiempo_{simulación})$:

Si $Fecha[d] \geq Fecha_{Emergencia_{CULTIVO}}$ y $Fecha[d] < Fecha_{InicioPCC_{CULTIVO}}$:

$$SC[d] = SC_{E_PCC_{CULTIVO}} * FC[d]$$

Si $Fecha[d] \geq Fecha_{InicioPCC_{CULTIVO}}$ y $Fecha[d] < Fecha_{FinPCC_{CULTIVO}}$:

$$SC[d] = SC_{PCC_{CULTIVO}}$$

Si $Fecha[d] \geq Fecha_{FinPCC_{CULTIVO}}$ y $Fecha[d] < Fecha_{MF_{CULTIVO}}$:

$$SC[d] = SC_{PCC_MF_{CULTIVO}}$$

Sino:

$$SC[d] = 0$$

(All.4)

donde $Fecha_{Emergencia_{CULTIVO}}$ es la fecha de emergencia del cultivo [día/mes/año]; $Fecha_{InicioPCC_{CULTIVO}}$ y $Fecha_{FinPCC_{CULTIVO}}$ es la fecha de inicio y fin de PCC respectivamente [día/mes/año]; $Fecha_{MF_{CULTIVO}}$ es la fecha de madurez fisiológica del cultivo [día/mes/año]; $SC[d]$ es la susceptibilidad del cultivo a la competencia interespecífica con otra especie en el día d ; $FC[d]$ el factor de competencia del cultivo sobre la maleza en el día d ; $SC_{E_PCC_{CULTIVO}}$, $SC_{PCC_{CULTIVO}}$ y $SC_{PCC_MF_{CULTIVO}}$ son los factores de peso asociados al período entre la emergencia y el inicio del PCC , durante el PCC y entre el fin del PCC y el inicio de la madurez del cultivo respectivamente.

Por último, al finalizar la campaña anual, se estima el rendimiento esperado del cultivo (RC) a través de la Ec. AII.5 propuesta por Panell y col. (2004) y adoptada por Molinari y col. (2020).

$$RC[\text{año}] = \left[\frac{DSE+A}{DSE} + \frac{DAC}{A+DAC+K*DM[\text{año}]} * MPRM + (1 - MPRM) \right] * RP_{cultivo} \quad (\text{AII.5})$$

donde $RC[\text{año}]$ es el rendimiento del cultivo calculado anualmente [t/ha]; DAC es la densidad actual de siembra [$plantas/m^2$]; DSE es la densidad de siembra estándar [$plantas/m^2$]; $MPRM$ máxima pérdida de rendimiento por malezas [%]; DM es la densidad de malezas [$ind./m^2$]; A y K constantes de la pérdida del rendimiento del cultivo y $RP_{cultivo}$ representa el rendimiento potencial del cultivo [t/ha].

AII.2 Modelo de simulación de la maleza

A continuación, se explica cada una de las etapas principales en el ciclo de vida de la maleza:

1) **Banco de Semillas (BS):** representa el conjunto de semillas en el banco del suelo, conformando y manteniendo la población de malezas. Se determina anualmente (Ec. AII.6) en base al ingreso por la producción de semillas de los individuos que alcanzaron el estado reproductivo avanzado en los tres años anteriores. El banco de semillas considera sólo la proporción de semillas que podrían germinar bajo las condiciones ambientales óptimas (semillas quiescentes o sin dormición). Las mismas varían según el tiempo transcurrido desde la dispersión primaria: si se produce una cierta cantidad de semillas en un año, al siguiente año germinará un porcentaje relativamente elevado, al año siguiente lo hará una proporción menor y en el tercero solo una pequeña fracción. También se tienen en cuenta los egresos por factores bióticos y debido a la longevidad de las semillas, esto es: las pérdidas de semillas por predación al barbecho, por dispersión y por mortalidad natural.

El cálculo del BS permite estimar el riesgo de infestación en los siguientes años. Además, la porción del banco de semillas que se encuentre quiescente en el año simulado, determina la emergencia diaria de los individuos para dicho año.

$$BS[\text{año}] = \sum_{t=-3}^{-1} (Prod_{sem}[\text{año}] * (1 - lb) * (1 - ld) * q[t] * (1 + sm * t)) \quad (AII.6)$$

donde $BS[\text{año}]$ es el banco de semillas de cada año [$semillas/m^2$]; $Prod_{sem}[\text{año}]$ es la producción de semillas al final del ciclo [$semillas/m^2$]; lb son las pérdidas de semillas por predación en el período comprendido entre la cosecha de un cultivo y la siembra del siguiente cultivo (barbecho); ld son las pérdidas de semillas por dispersión; sm son las pérdida de semillas por mortalidad natural; $q[t]$ representa las semillas quiescentes en el año t () y t es el año que varía entre los tres años previos hasta el año actual del cálculo.

2) Dinámica poblacional de la maleza: Se simula a partir de cohortes (o generaciones) diarias. El tiempo térmico acumulado (TTA) define el estado fenológico en que se encuentra la maleza. En el modelo se consideran cinco estados fenológicos:

- i. **Plántula (P):** La cantidad de individuos en esta fase depende de la emergencia diaria que se establece a partir de la multiplicación de la tasa de emergencia (estimada para cada día a partir de un modelo adecuado) por el banco de semillas quiescentes del año simulado (Ec. AII.). En este estudio se emplea el modelo de redes neuronales desarrollado en Chantre y col. (2012) para calcular la tasa de emergencia. En este estado fenológico influye la competencia interespecífica. La misma representa el efecto competitivo del cultivo sobre la maleza y se calcula teniendo en cuenta la cantidad de individuos que ingresan a esta etapa por el factor de competencia determinado por la simulación del cultivo (cálculo detallado más adelante).

$$Emergencia[día][año] = tasa_{emergencia}[día][año] * BS[año] \quad \left| \quad (AII.7)\right.$$

donde $Emergencia[día]$ es la emergencia diaria de la semilla en ese año [$individuos/m^2$]; $tasa_{emergencia}$ es la tasa de emergencia diaria del año de simulación en ese año [$individuos/semillas$] y $BS[año]$ es el banco de semillas de malezas quiescentes en ese año [$semillas/m^2$].

- ii. *Vegetativo Temprano (VT)*: Esta fase se alcanza cuando se logra una acumulación de grados día igual a 70°Cd a partir del estado anterior.
- iii. *Vegetativo Avanzado (VA)*: Este estado incide en la competencia intra e interespecífica. Su aparición se debe a la superación de una acumulación de grados días igual a 280°Cd a partir del estado anterior.
- iv. *Reproductivo Inicial (RI)*: Posee una capacidad competitiva importante en la competencia intra e interespecífica. Esta fase se inicia cuando la acumulación de grados días es igual a 400°Cd a partir del estado anterior.
- v. *Reproductivo Avanzado (RA)*: Su capacidad competitiva es poco significativa en comparación con los dos estados previos porque los individuos comienzan a envejecer (proceso de senescencia). Este estado surge cuando la acumulación de grados días es igual a 300°C a partir del estado anterior.

El ingreso de individuos al próximo estado no sólo depende del tiempo térmico acumulado, sino que también se ve influenciado por la competencia intraespecífica ($Comp_{intraesp}$). Ésta es la presión que ejerce cada planta de maleza sobre los individuos de la misma especie y se calcula como la cantidad de individuos totales existentes en cada estado fenológico por un factor de ponderación correspondiente a cada estado fenológico específico (Ec. AII.9).

Si $EF = ([P], [VT], [VA], [RI])$:

$$Compet_{intraesp}[EF][día] = \left(\sum_{d=1}^{día} Acum_{individuos}[EF][d-1] * FP[EF] \right) \quad \left| \quad (AII.8)\right.$$

donde EF representa el estado fenológico de la maleza (P : plántula, VT : vegetativo temprano, VA : vegetativo avanzado, RI : reproductivo inicial); $Compet_{intraesp}[EF][día]$ es la competencia intraespecífica de cada estado fenológico cada día [$individuos/m^2$]; $Acum_{individuos[EF][d-1]}$ es la cantidad acumulada de individuos en cada estado fenológico EF en el día previo al día actual de simulación [$individuos/m^2$] y el $FP[EF]$ es el factor de ponderación de cada EF .

El ingreso de individuos a cada EF (Ec. AII.9) ocurre si la competencia intra-específica es menor que la capacidad ambiental máxima ($CA_{máx}$). Ésta representa el número de individuos máximo de cada EF que soporta el agroecosistema y, por ende, condiciona la cantidad de plantas que pasa al siguiente estado.

Finalmente, la cantidad de individuos en un determinado estado fenológico va a depender de la cantidad de individuos eliminados por las diferentes acciones de control de malezas que se vayan implementando a lo largo de la temporada (aplicación de herbicidas, labranzas, etc.). Cada una de estas acciones de control se cuantifican por medio de un valor de efectividad asociado a cada EF según el método de control específico ($Control[EF]$), eliminando las cohortes diarias que resultan susceptibles a la acción implementada.

El ingreso al estado de plántulas se calcula diferente al resto, debido a que se tiene en cuenta las semillas del banco que emergieron ($Emergencia$).

Si $Compet_{intraesp}[EF][día] \leq CA_{máx}$:

$$Ingreso_{individuos}[P][día] = Emergencia[día](1 - Control[P][día])$$

Si $EF = ([VT], [VA], [RI], [RA])$:

$$Ingreso_{individuos}[EF][día] = Pasaje[EF \rightarrow EF + 1][día] \\ - Control[EF]$$

Sino:

(AII.9)

$$Ingreso_{individuos}[EF][día] = 0$$

donde $Comp_{intraesp}[EF][día]$ es la competencia intraespecífica diaria de cada estado fenológico [$individuos/m^2$]; $CA_{máx}$ es la capacidad ambiental máxima [$individuos/m^2$]; $Ingreso_{individuos}[EF][día]$ es el ingreso de individuos a cada estado fenológico; $Emergencia[día]$ es la emergencia diaria de la semilla [$individuos/m^2$]; $Control[EF][día]$ es la efectividad del método de control sobre cada EF ; $Pasaje[EF \rightarrow EF + 1]$ pasaje de un estado fenológico de la maleza al siguiente [$individuos/m^2$].

A partir de un balance es posible entonces establecer la acumulación de individuos que se encuentran en cada estado fenológico ($Acum_{individuos}[EF][día]$). Esta cantidad se estima en base a los individuos que ya se encontraban en ese EF , más los nuevos individuos que ingresan a dicho estado y restando las cohortes afectadas por el control implementado (si hubiera) y los individuos que cumplieron las condiciones para continuar hacia el próximo EF (Ec. All.10). En particular, sólo en el caso del estado plántula, se debe tener en cuenta también una disminución en la cantidad de individuos debido a la competencia interespecífica mencionada anteriormente. Asimismo, para los individuos que se encuentran en el estado reproductivo avanzado solo se tiene en cuenta los que ya se encontraban en dicho estado sumados a los que acaban de ingresar.

$$\begin{aligned}
 Acum_{individuos}[P][día] &= Acum_{individuos}[P][día - 1] \\
 &+ Ingreso_{individuos}[P][día] \\
 &- Acum_{individuos}[P][día - 1] \times Control[P][día] \\
 &- Pasaje[P \rightarrow VT][día] \\
 &- FC[día] \times Ingreso_{individuos}[P][día] \\
 &\quad \text{Competencia interespecífica}
 \end{aligned}
 \tag{All.10}$$

Si $EF = ([VT], [VA], [RI])$:

$$\begin{aligned}
Acum_{individuos}[EF][día] &= Acum_{individuos}[EF][día - 1] \\
&+ Ingreso_{individuos}[EF][día] \\
&- Pasaje[EF \rightarrow EF + 1][día] \\
&- Acum_{individuos}[EF][día - 1] \\
&* Control[EF][día]
\end{aligned}$$

$$\begin{aligned}
Acum_{individuos}[RA][día] &= Acum_{individuos}[RA][día - 1] \\
&+ Ingreso_{individuos}[RA][día]
\end{aligned}$$

donde $Acum_{individuos}[EF][día]$ es la cantidad de individuos acumuladas en cada EF ; $Ingreso_{individuos}[EF][día]$ es el ingreso de individuos a cada estado fenológico; $FC[d]$ es el factor de competencia diaria del cultivo sobre la maleza; $Control[EF][día]$ es la efectividad del método de control sobre cada EF ; $Pasaje[EF \rightarrow EF + 1]$ es el pasaje de un estado fenológico de la maleza al siguiente [$individuos/m^2$].

Una vez establecida la cantidad de individuos en cada estado fenológico cada día del horizonte de simulación, se puede prever la cantidad presente en el fin del ciclo. Con esta distribución poblacional es posible calcular una “densidad ponderada” (DM) según la Ec. AII.11. Esta densidad, que resulta de la sumatoria de individuos en cada estado fenológico ponderada por el efecto competitivo interespecífico de cada estado y por la susceptibilidad del cultivo a la competencia, es la que se emplea para calcular la pérdida de rendimiento del cultivo (Ec. AII.5).

$$DM[año] = \frac{\sum_{día=1}^{días\ totales} (Acum_{individuos}[EF][día] * FP[EF] * SC[día])}{día_{MF} - día_{Emergencia}} \quad (AII.11)$$

$DM[año]$ es la densidad de malezas anual ponderada [*individuos/m²*]; $Acum_{individuos}[EF][día]$ es la cantidad de individuos acumulados en cada EF (P : plántula, VT : vegetativo temprano, VA : vegetativo avanzado, RI : reproductivo inicial); $FP[EF]$ es el factor competitivo ponderado de cada EF ; $PCC[día]$ factor de ponderación diario del período crítico de competencia de la maleza con el cultivo; $día_{MF}$ día juliano en que el cultivo alcanza la madurez fisiológica [día] y $día_{Emergencia}$ día juliano en que emerge el cultivo [día].

3) **Producción de Semillas** ($Prod_{sem}$): es un parámetro que permite estimar la cantidad de semillas de maleza que se producirán al final del ciclo. Se calcula anualmente como la suma de la cantidad de individuos en estado Reproductivo Avanzado antes del PCC ($cohorte_1$) y después del PCC ($cohorte_2$) multiplicados por la fecundidad correspondiente a cada cohorte según la Ec. All.12. Se representa como un porcentaje de la producción de semillas máxima del banco que se considera.

$$Prod_{sem}[año] = \frac{cohorte_1[año] * Fec_{coh1} + cohorte_2[año] * Fec_{coh2}}{Prod.Sem_{máx}} * 100 \quad (All.12)$$

donde $Prod_{sem}[año]$ es el porcentaje de la producción de semillas máximas de cada año [%]; $cohorte_1$ es la cantidad de individuos en estado Reproductivo Avanzado antes del PCC [*individuos/m²*]; $cohorte_2$ es la cantidad de individuos en estado Reproductivo Avanzado después del PCC [*individuos/m²*]; Fec_{coh1} es la fecundidad de la cohorte 1 [*semillas/individuos*]; Fec_{coh2} es la fecundidad de la cohorte 2 [*semillas/individuos*] y $Prod.Sem_{máx}$ es la producción máxima de semillas de maleza [*semillas/individuos*].

Cabe aclarar que todos los parámetros considerados en estos modelos se encuentran detallados en el Anexo I junto con los valores de aquellos son constantes.

Anexo III: Parámetros de los casos simulados

Tabla AIII.1: Datos propios del CASO SI

CASO I	2014	2015	2016	2017	2018
Cultivo	TRIGO	CEBADA	TRIGO	CEBADA	TRIGO
Siembra	01/07/14	26/07/15	01/07/16	26/07/17	01/07/18
Control Presiembra					
Glifosato	15/04/14	15/04/15	15/04/16	15/04/17	15/04/18
Glifosato	30/06/14	25/07/15	30/06/16	25/07/17	30/06/18

Tabla AIII.2: Datos propios del CASO SII

CASO II	2014	2015	2016	2017	2018
Cultivo	TRIGO	CEBADA	TRIGO	CEBADA	TRIGO
Siembra	01/07/14	26/07/15	01/07/16	26/07/17	01/07/18
Control Presiembra					
Glifosato	15/04/14	15/04/15	15/04/16	15/04/17	15/04/18
Glifosato	30/06/14	25/07/15	30/06/16	25/07/17	30/06/18
Control Postemergente					
Diclofop	12/08/14	-	20/08/16	-	-
Pinoxaden	-	30/08/15	-	-	-

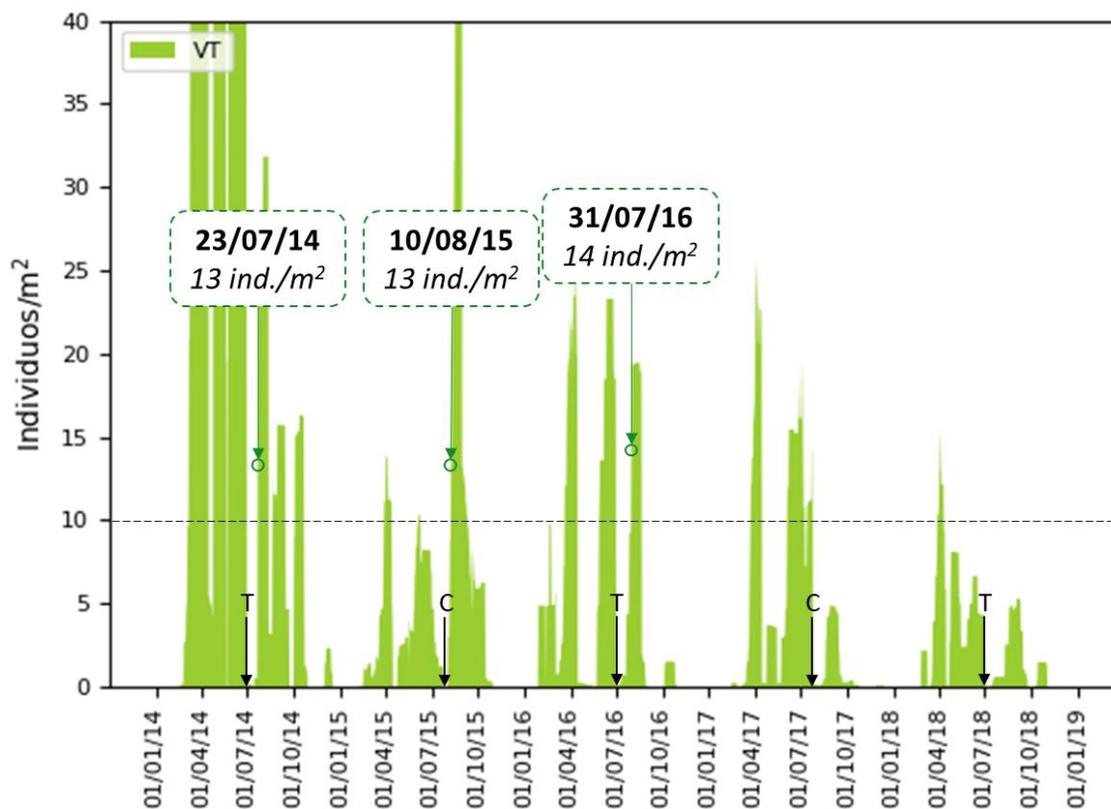


Fig. AIII.1: Determinación de las fechas de aplicación de herbicidas post-siembra para el CASO SII cuando el estado vegetativo temprano (VT) supera los 10 ind./m²

Tabla AIII.3: Datos propios del CASO SIII

CASO III	2014	2015	2016	2017	2018
Cultivo	TRIGO	CEBADA	TRIGO	CEBADA	TRIGO
Siembra	16/7/14	15/06/15	29/06/16	14/07/17	31/07/18
Control Presiembra					
Glifosato	15/04/14	15/04/15	15/04/16	15/04/17	15/04/18
Glifosato	15/07/14	14/06/15	28/06/16	13/07/17	30/07/18

Tabla AIII.4: Datos propios del CASO SIV

CASO IV	2014	2015	2016	2017	2018
Cultivo	TRIGO	CEBADA	TRIGO	CEBADA	TRIGO
Siembra	16/07/14	15/06/15	29/6/16	14/07/17	31/07/18
Control Presiembra					
Glifosato	15/04/14	15/04/15	15/04/16	15/04/17	15/04/18
Glifosato	15/07/14	14/06/15	28/06/16	13/07/17	30/07/18
Control Postemergente					
Diclofop	06/09/14	-	-	-	-
Pinoxaden	-	01/09/15	-	-	-

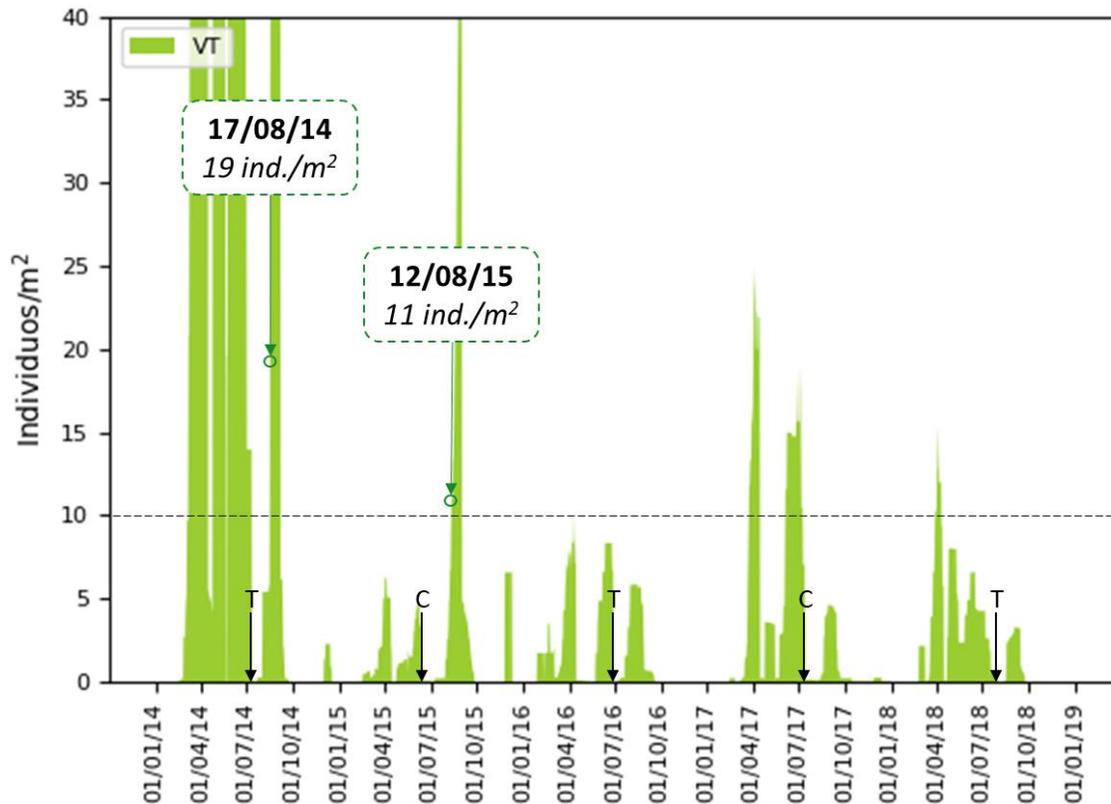


Fig. AIII.2: Determinación de las fechas de aplicación de herbicidas post-siembra para el CASO SIV cuando el estado vegetativo temprano (VT) supera los 10 ind/m²

Tabla AIII.5: Datos propios del CASO SV

CASO V	2014	2015	2016	2017	2018
Cultivo	TRIGO	CEBADA	TRIGO	CEBADA	TRIGO
Siembra	16/07/14	15/06/15	29/06/16	14/07/17	01/08/18
Control Presiembra					
Labranza	15/04/14	15/04/15	15/04/16	15/04/17	15/04/18
Labranza	15/07/14	14/06/15	28/06/16	13/07/17	31/07/18
Control Postemergente					
Diclofop	06/09/14	-	-	-	-
Pinoxaden	-	06/09/15	-	-	-

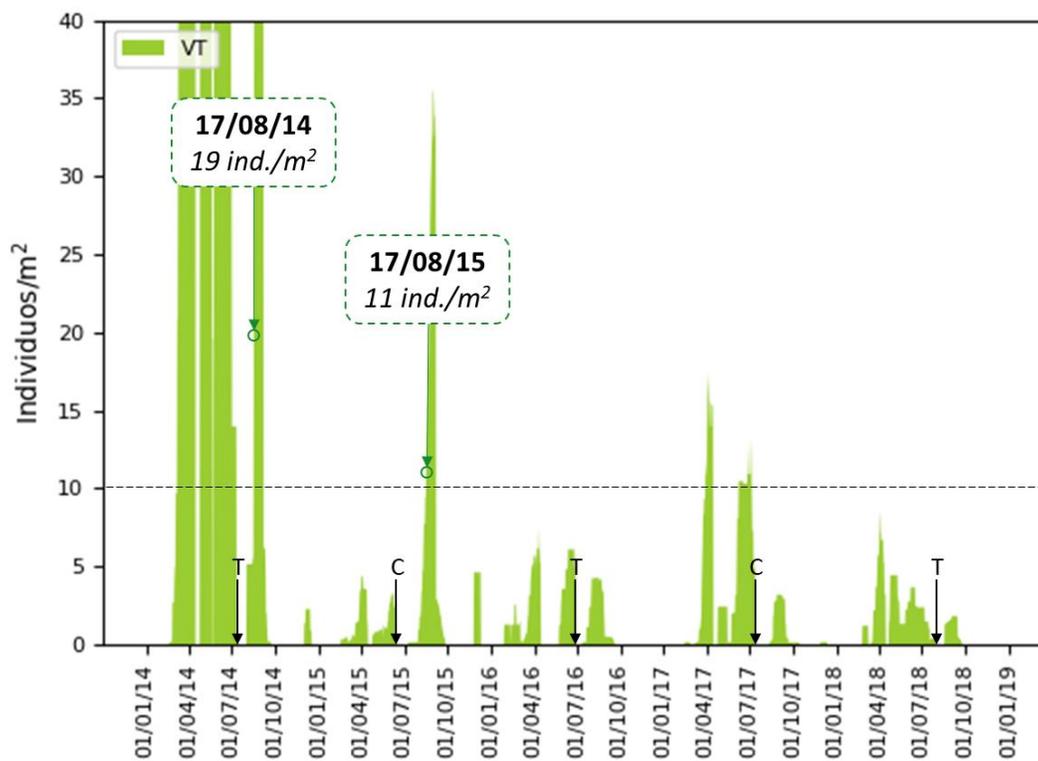


Fig. AIII.3: Determinación de las fechas de aplicación de herbicidas post-siembra para el CASO SV cuando el estado vegetativo temprano (VT) supera los 10 ind/m²

Anexo IV: Resultados de los casos optimizados

Tabla AIV.1: Resultados del CASO OI

Sol.	2014				2015				2016				2017				2018			
	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	1º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control
S1	29/07	03/05	28/07	11/08	19/07	22/04	13/07	-	19/07	28/04	15/07	-	04/07	09/04	29/06	-	17/07	22/04	07/07	-
S2	29/07	02/05	28/07	13/08	16/07	22/04	07/07	-	16/07	23/04	13/07	-	01/07	06/04	26/06	-	12/07	20/04	30/06	-
S3	20/06	28/03	19/06	-	29/06	07/04	23/06	-	27/07	02/05	21/07	-	19/07	25/04	15/07	-	12/06	23/03	10/06	-
S4	28/07	06/05	21/07	13/08	06/07	14/04	27/06	-	20/06	01/04	14/06	-	09/07	12/04	02/07	-	13/07	22/04	02/07	-
S5	28/07	05/05	15/07	15/08	29/06	09/04	22/06	-	10/07	16/04	04/07	-	06/07	10/04	01/07	-	11/07	16/04	08/07	-
S6	28/07	08/05	24/07	14/08	29/06	09/04	22/06	-	25/07	03/05	22/07	-	01/07	03/04	24/06	-	05/07	08/04	30/06	-
S7	20/07	22/04	18/07	-	22/06	28/03	16/06	-	27/07	06/05	22/07	-	28/07	06/05	22/07	-	30/07	05/05	21/07	-
S8	19/07	21/04	18/07	-	02/07	06/04	24/06	-	23/07	26/04	18/07	-	25/07	02/05	19/07	-	09/07	16/04	26/06	-
S9	18/06	25/03	12/06	-	06/07	11/04	30/06	-	17/07	23/04	13/07	-	26/07	01/05	23/07	-	13/07	21/04	30/06	-
S10	24/06	29/03	18/06	-	13/07	21/04	03/07	-	26/07	30/04	21/07	-	19/07	23/04	14/07	-	29/06	10/04	20/06	-
S11	05/07	07/04	29/06	-	24/07	29/04	17/07	-	28/07	02/05	21/07	-	22/07	02/05	13/07	-	24/06	04/04	15/06	-
S12	29/07	05/05	24/07	14/08	20/07	27/04	14/07	-	19/06	24/03	16/06	-	04/07	09/04	27/06	-	02/07	11/04	26/06	-

Tabla AIV.2: Resultados del CASO OII

Sol.	2014				2015				2016				2017				2018			
	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control
S1	09/07	16/04	28/06	-	15/07	18/04	04/07	-	27/07	05/05	22/07	-	23/07	03/05	16/07	-	25/07	01/05	24/07	-
S2	20/07	27/04	16/07	21/08	06/07	14/04	03/07	-	24/06	03/04	14/06	-	21/07	29/04	15/07	-	01/07	04/04	20/06	-
S3	29/07	06/05	27/07	16/08	03/07	08/04	24/06	-	21/07	27/04	12/07	-	01/07	07/04	24/06	-	09/07	14/04	29/06	-
S4	15/07	21/04	08/07	-	16/06	22/03	06/06	-	18/07	23/04	12/07	-	23/07	28/04	22/07	-	05/06	09/03	30/05	-
S5	17/07	23/04	05/07	20/08	15/07	17/04	11/07	-	20/07	26/04	11/07	-	17/07	25/04	12/07	-	15/07	18/04	03/07	27/07
S6	21/07	28/04	11/07	-	15/07	18/04	09/07	-	26/07	01/05	20/07	-	06/07	14/04	01/07	-	17/07	24/04	07/07	-
S7	29/07	08/05	21/07	15/08	24/06	28/03	12/06	-	13/07	17/04	10/07	-	15/07	17/04	13/07	-	07/07	14/04	26/06	-
S8	25/06	02/04	17/06	-	01/07	09/04	22/06	-	27/07	03/05	23/07	-	23/07	29/04	21/07	-	23/06	29/03	15/06	-
S9	24/07	02/05	19/07	24/08	18/07	26/04	10/07	-	27/07	03/05	21/07	-	17/07	21/04	13/07	-	21/06	24/03	20/06	-
S10	28/07	09/05	17/07	-	19/07	21/04	09/07	-	25/07	04/05	18/07	-	08/07	14/04	03/07	-	15/06	22/03	11/06	-
S11	27/07	03/05	18/07	15/08	19/07	22/04	13/07	-	30/07	07/05	23/07	-	16/07	27/04	14/07	-	17/07	22/04	04/07	-
S12	30/07	09/05	28/07	-	14/07	24/04	05/07	-	13/07	22/04	06/07	-	22/07	30/04	14/07	-	02/07	06/04	21/06	-
S13	24/07	02/05	18/07	12/08	17/07	22/04	11/07	-	22/07	29/04	16/07	-	10/07	17/04	04/07	-	22/07	27/04	12/07	-
S14	27/07	05/05	22/07	15/08	01/07	08/04	25/06	-	06/07	12/04	30/06	-	15/06	23/03	10/06	-	24/07	29/04	13/07	23/08
S15	24/07	01/05	17/07	12/08	22/07	03/05	17/07	-	17/06	25/03	12/06	03/07	16/07	24/04	10/07	-	12/07	19/04	05/07	-
S16	23/07	02/05	16/07	11/08	28/06	04/04	22/06	-	19/07	26/04	15/07	26/08	27/06	05/04	22/06	-	25/06	30/03	14/06	-

Tabla AIV.3: Resultados del CASO OIII

Sol.	2014				2015				2016				2017				2018			
	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control
S1	18/06	24/03	06/06	-	07/07	13/04	29/06	-	26/06	30/03	17/06	-	21/07	28/04	15/07	-	12/06	17/03	01/06	-
S2	26/07	03/05	16/07	13/08	12/06	20/03	07/06	-	13/06	23/03	31/05	-	10/07	19/04	01/07	-	08/07	18/04	26/06	21/07
S3	27/07	04/05	23/07	15/08	23/07	01/05	11/07	-	13/06	18/03	04/06	-	06/07	11/04	01/07	-	25/07	05/05	18/07	-
S4	27/07	02/05	26/07	15/08	27/06	31/03	15/06	-	24/06	05/04	13/06	10/07	26/06	04/04	23/06	-	05/07	11/04	27/06	-
S5	24/07	30/04	15/07	-	20/06	30/03	10/06	-	26/07	02/05	25/07	-	29/06	05/04	24/06	-	16/07	22/04	10/07	-
S6	30/07	02/05	24/07	16/08	26/06	06/04	18/06	-	09/07	12/04	28/06	-	01/07	09/04	24/06	-	10/07	17/04	01/07	-
S7	23/07	28/04	14/07	10/08	25/06	06/04	13/06	-	20/07	23/04	18/07	-	30/06	05/04	25/06	-	17/07	22/04	13/07	-
S8	27/07	04/05	21/07	15/08	21/07	30/04	20/07	05/08	15/07	17/04	03/07	03/08	23/06	28/03	21/06	-	13/06	18/03	10/06	-
S9	30/06	07/04	27/06	-	01/07	10/04	18/06	-	27/07	04/05	21/07	-	28/06	04/04	23/06	-	12/06	18/03	09/06	-
S10	21/07	27/04	16/07	-	17/06	25/03	09/06	-	21/06	27/03	11/06	-	21/07	01/05	16/07	-	14/07	16/04	01/07	-
S11	25/06	31/03	24/06	-	17/07	21/04	05/07	-	24/07	29/04	20/07	-	24/06	02/04	22/06	-	19/06	24/03	09/06	-
S12	27/07	03/05	23/07	12/08	12/07	14/04	06/07	-	10/07	18/04	07/07	23/07	30/07	09/05	23/07	-	28/06	02/04	18/06	-
S13	28/07	02/05	21/07	14/08	05/07	10/04	01/07	-	20/07	29/04	15/07	-	10/07	15/04	07/07	20/07	03/07	10/04	27/06	15/07
S14	26/07	30/04	23/07	-	01/07	05/04	23/06	-	23/07	01/05	21/07	-	26/07	04/05	23/07	-	19/07	24/04	11/07	-
S15	27/07	04/05	19/07	14/08	06/07	16/04	27/06	-	25/06	31/03	24/06	-	02/07	10/04	28/06	-	12/07	17/04	01/07	-
S16	17/07	28/04	16/07	21/08	25/06	01/04	22/06	-	27/06	30/03	24/06	-	17/07	19/04	10/07	-	29/07	03/05	23/07	13/08
S17	24/07	03/05	20/07	11/08	10/07	18/04	01/07	-	17/06	25/03	13/06	-	01/07	09/04	27/06	-	07/07	11/04	03/07	-

Tabla AIV.4: Resultados del CASO OIV

Sol.	2014				2015				2016				2017				2018			
	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control	Siembra Cultivo	1º Control	2º Control	3º Control
S1	26/07	30/04	18/07	10/08	07/07	13/04	03/07	-	17/07	25/04	05/07	-	30/07	03/05	28/07	-	06/06	12/03	03/06	-
S2	13/07	19/04	07/07	-	22/06	29/03	17/06	-	26/07	02/05	21/07	-	10/07	14/04	03/07	-	12/07	23/04	01/07	-
S3	15/07	23/04	08/07	17/08	15/06	22/03	13/06	-	28/07	04/05	21/07	-	23/07	01/05	21/07	-	03/07	13/04	22/06	-
S4	26/07	02/05	22/07	11/08	30/06	08/04	27/06	15/07	10/07	15/04	04/07	-	21/07	23/04	18/07	-	30/07	10/05	19/07	-

Referencias

- Adams, T. A., & Seider, W. D. (2008). Semicontinuous distillation for ethyl lactate production. *AIChE journal*, 54(10), 2539-2552.
- Aguilera-Rueda, V. J., Ameca-Alducin, M. Y., Mezura-Montes, E., & Cruz-Ramírez, N. (2016). Particle Swarm Optimization with feasibility rules in constrained numerical optimization. A brief review. In 2016 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC) (pp. 1-6). IEEE.
- Aguirre-Salado, C. A., Valdez-Lazalde, J. R., Ángeles-Pérez, G., de los Santos-Posadas, H. M., & Aguirre-Salado, A. I. (2011). Mapeo del índice de área foliar y cobertura arbórea mediante fotografía hemisférica y datos SPOT 5 HRG: regresión y k-nn. *Agrociencia*, 45(1), 105-119.
- Andrew, I. K., & Storkey, J. (2017). Using simulation models to investigate the cumulative effects of sowing rate, sowing date and cultivar choice on weed competition. *Crop Protection*, 95, 109-115.
- Ang, K. M., Lim, W. H., Isa, N. A. M., Tiang, S. S., & Wong, C. H. (2020). A constrained multi-swarm particle swarm optimization without velocity for constrained optimization problems. *Expert Systems with Applications*, 140, 112882.
- Bansal, J. C., Singh, P. K., Saraswat, M., Verma, A., Jadon, S. S., & Abraham, A. (2011). Inertia weight strategies in particle swarm optimization. In *Nature and Biologically Inspired Computing (NaBIC), 2011 Third World Congress on* (pp. 633-640). IEEE.
- Benjamin, L. R., Milne, A. E., Parsons, D. J., Cussans, J., & Lutman, P. J. W. (2009). Using stochastic dynamic programming to support weed management decisions over a rotation. *Weed Research*, 49(2), 207-216.
- Berti, A., & Zanin, G. (1997). GESTINF: a decision model for post-emergence weed management in soybean (*Glycine max* (L.) Merr.). *Crop protection*, 16(2), 109-116.

- Berti, A., Bravin, F., & Zanin, G. (2003). Application of decision-support software for postemergence weed control. *Weed Science*, 51(4), 618-627.
- Binh, T. T., & Korn, U. (1997). Multiobjective evolution strategy for constrained optimization problems. In *Proceedings of the 15th IMACS World Congress on Scientific Computation, Modelling and Applied Mathematics*, Berlin (Vol. 357, p. 362).
- Boussaïd, I., Lepagnot, J., & Siarry, P. (2013). A survey on optimization metaheuristics. *Information Sciences*, 237, 82-117.
- Chalak-Haghighi, M., Van Ierland, E. C., Bourdôt, G. W., & Leathwick, D. (2008). Management strategies for an invasive weed: a dynamic programming approach for Californian thistle in New Zealand. *New Zealand Journal of Agricultural Research*, 51(4), 409-424.
- Chankong, V., & Haimes, Y. Y. (2008). *Multiobjective decision making: theory and methodology*. Courier Dover Publications.
- Chantre, G., Lodovichi, M., Blanco, A., Bandoni, A., & Sabbatini, M. (2013). Toma de decisiones en sistemas agronómicos y su aplicación al manejo de malezas.
- Chantre, G. R., Vigna, M. R., Renzi, J. P., & Blanco, A. M. (2018). A flexible and practical approach for real-time weed emergence prediction based on Artificial Neural Networks. *Biosystems engineering*, 170, 51-60.
- Chantre, G. R., & González-Andújar, J. L. (2020). *Decision Support Systems for Weed Management*.
- Chen, Y. W., Wang, L. C., Wang, A., & Chen, T. L. (2017). A particle swarm approach for optimizing a multi-stage closed loop supply chain for the solar cell industry. *Robotics and Computer-Integrated Manufacturing*, 43, 111-123.
- Cleghorn, C. W., & Engelbrecht, A. P. (2018). Particle swarm stability: a theoretical extension using the non-stagnate distribution assumption. *Swarm Intelligence*, 12(1), 1-22.
- Coello, C. A. C., Lamont, G. B., & Veldhuizen, D. A. V. (2007). *MOEA Test Suites. Evolutionary Algorithms for Solving Multi-Objective Problems: Second Edition*, 175-232.

- Colbach, N., Chauvel, B., Gauvrit, C., & Munier-Jolain, N. M. (2007). Construction and evaluation of ALOMYSYS modelling the effects of cropping systems on the blackgrass life-cycle: from seedling to seed production. *Ecological Modelling*, 201(3-4), 283-300.
- Conejo, A. J., Castillo, E., Mínguez, R., & García-Bertrand, R. (2006). Decomposition in linear programming: complicating variables. *Decomposition Techniques in Mathematical Programming: Engineering and Science Applications*, 107-139.
- Cousens, R., Brain, P., O'Donovan, J. T., & O'Sullivan, P. A. (1987). The use of biologically realistic equations to describe the effects of weed density and relative time of emergence on crop yield. *Weed Science*, 720-725.
- Crawford, B., Soto, R., Astorga, G., García, J., Castro, C., & Paredes, F. (2017). Putting continuous metaheuristics to work in binary search spaces. *Complexity*, 2017.
- Damiani, L., Diaz, A. I., Iparraguirre, J., & Blanco, A. M. (2020). Accelerated particle swarm optimization with explicit consideration of model constraints. *Cluster Computing*, 23(1), 149-164.
- Diez de Ulzurrun, P., Vigna, M. R., Leaden, M. I., & Martino, C. (2015). Patrones de emergencia de Avena fatua [L.] y Lolium multiflorum [LAM] en el sudeste y sudoeste de la Provincia de Buenos Aires. In Congreso Latinoamericano de Malezas. Congreso Argentino de Malezas. Buenos Aires. AR.
- Ding, J., Wang, Q., Zhang, Q., Ye, Q., & Ma, Y. (2019). A hybrid particle swarm optimization-cuckoo search algorithm and its engineering applications. *Mathematical Problems in Engineering*, 2019.
- Doole, G. J., & Pannell, D. J. (2008). Optimisation of a large, constrained simulation model using compressed annealing. *Journal of Agricultural Economics*, 59(1), 188-206.
- Doyle, C. J., Cousens, R., & Moss, S. R. (1986). A model of the economics of controlling *Alopecurus myosuroides* Huds. in winter wheat. *Crop Protection*, 5(2), 143-150.

- Elbes, M., Alzubi, S., Kanan, T., Al-Fuqaha, A., & Hawashin, B. (2019). A survey on particle swarm optimization with emphasis on engineering and network applications. *Evolutionary Intelligence*, 1-17.
- Erbeyoğlu, G., & Bilge, Ü. (2016). PSO-based and SA-based metaheuristics for bilinear programming problems: an application to the pooling problem. *Journal of Heuristics*, 22(2), 147-179.
- Ferraro, D. O., Ghera, C. M., & Sznaider, G. A. (2003). Evaluation of environmental impact indicators using fuzzy logic to assess the mixed cropping systems of the Inland Pampa, Argentina. *Agriculture, Ecosystems & Environment*, 96(1-3), 1-18.
- Fisher, B. S., & Lee, R. R. (1981). A dynamic programming approach to the economic control of weed and disease infestations in wheat. *Review of Marketing and Agricultural Economics*, 49(430-2016-31591), 175-187.
- Gaspars-Wieloch, H. (2019). Project net present value estimation under uncertainty. *Central European Journal of Operations Research*, 27(1), 179-197.
- González-Andújar, J. L., & Fernández-Quintanilla, C. (1991). Modelling the population dynamics of *Avena sterilis* under dry-land cereal cropping systems. *Journal of Applied Ecology*, 16-27.
- González-Andújar, J. L., & Fernández-Quintanilla, C. (2004). Modelling the population dynamics of annual ryegrass (*Lolium rigidum*) under various weed management systems. *Crop protection*, 23(8), 723-729.
- Gorddard, R. J., Pannell, D. J., & Hertzler, G. (1995). An optimal control model for integrated weed management under herbicide resistance. *Australian Journal of Agricultural Economics*, 39(1), 71-87.
- Gou, J., Lei, Y. X., Guo, W. P., Wang, C., Cai, Y. Q., & Luo, W. (2017). A novel improved particle swarm optimization algorithm based on individual difference evolution. *Applied Soft Computing*, 57, 468-481.

- Halim, A. H., Ismail, I., & Das, S. (2020). Performance assessment of the metaheuristic optimization algorithms: an exhaustive review. *Artificial Intelligence Review*, 1-87.
- Harker, K. N., & O'Donovan, J. T. (2013). Recent weed control, weed management, and integrated weed management. *Weed Technology*, 27(1), 1-11.
- Harkouss, F., Fardoun, F., & Biwole, P. H. (2018). Multi-objective optimization methodology for net zero energy buildings. *Journal of Building Engineering*, 16, 57-71.
- Ho, Y. C., & Pepyne, D. L. (2002). Simple explanation of the no-free-lunch theorem and its implications. *Journal of optimization theory and applications*, 115(3), 549-570.
- Jain, B. J., Pohlheim, H., & Wegener, J. (2001). On termination criteria of evolutionary algorithms. In *Proceedings of the Genetic and Evolutionary Computation Conference, GECCO-2001, San Francisco, CA, Morgan Kaufmann Publishers*.
- Kaveh, A., & Mahdavi, V. R. (2019). Multi-objective colliding bodies optimization algorithm for design of trusses. *Journal of Computational Design and Engineering*, 6(1), 49-59.
- Kennedy, J., Eberhart, R. (1995). Particle swarm optimization (PSO). In *Proc. IEEE International Conference on Neural Networks, Perth, Australia (pp. 1942-1948)*.
- Kennedy, J. (1999). Small worlds and mega-minds: effects of neighborhood topology on particle swarm performance. In *Evolutionary Computation, 1999. CEC 99. Proceedings of the 1999 Congress on (Vol. 3, pp. 1931-1938)*. IEEE.
- Kniss, A. R., & Coburn, C. W. (2015). Quantitative evaluation of the environmental impact quotient (EIQ) for comparing herbicides. *PloS one*, 10(6).
- Kovach, J; Petzold, C; Degnil, J y Tette, J. (1992). A method to measure the environmental impact of pesticides. *New York's Food and Life Sciences Bulletin* 139: 1-8.
- Labbafi, M., Khalaj, H., Allahdadi, I., Nadjafi, F., & Akbari, G. A. (2019). Using models for estimation of leaf area index in Cucurbita pepo L. *Journal of the Saudi Society of Agricultural Sciences*, 18(1), 55-60.

- Labrada, R., & Parker, C. (1994). Weed control in the context of integrated pest management. FAO Plant Production and Protection Paper (FAO).
- Lanfranconi, L.E.; Bragachini M.A.; Peiretti J.; Sanchez F.R. (2012). El avance de las malezas resistentes a herbicidas en los sistemas agrícolas. ¿Podremos controlarlas? Documento de trabajo INTA.
- Lang, J., & Zhao, J. (2016). Modeling and optimization for oil well production scheduling. Chinese Journal of Chemical Engineering, 24(10), 1423-1430.
- Lodovichi, M. V., Blanco, A. M., Chantre, G. R., Bandoni, J. A., Sabbatini, M. R., Vigna, M., ... & Gigón, R. (2013). Operational planning of herbicide-based weed management. Agricultural Systems, 121, 117-129.
- Lodovichi, M. V. (2018). Modelado poblacional del raigrás perenne (*Lolium perenne* L.) en cultivos de trigo de la región semiárida. Tesis doctoral.
- Luo, F., Yuan, Y., Ding, W., & Lu, H. (2018). An improved particle swarm optimization algorithm based on adaptive weight for task scheduling in cloud computing. In Proceedings of the 2nd International Conference on Computer Science and Application Engineering (pp. 1-5).
- Marini, F., & Walczak, B. (2015). Particle swarm optimization (PSO). A tutorial. Chemometrics and Intelligent Laboratory Systems, 149, 153-165.
- Martínez, Y., Cirujeda, A., Gómez, M. I., Marí, A. I., & Pardo, G. (2018). Bioeconomic model for optimal control of the invasive weed *Zea mays* subsp.(teosinte) in Spain. Agricultural Systems, 165, 116-127.
- Menalled, F. D. (2010). Consideraciones ecológicas para el desarrollo de programas de manejo integrado de malezas. Agroecología, 5, 73-78
- Menegat, A., Jäck, O., & Gerhards, R. (2017). Modelling of low input herbicide strategies for the control of wild oat in intensive winter wheat cropping systems. Field Crops Research, 201, 1-9.

- Mézière, D., Lucas, P., Granger, S., & Colbach, N. (2013). Does Integrated Weed Management affect the risk of crop diseases? A simulation case study with blackgrass weed and take-all disease. *European journal of agronomy*, 47, 33-43.
- Miranda-Varela, M. E., & Mezura-Montes, E. (2018). Constraint-handling techniques in surrogate-assisted evolutionary optimization. An empirical study. *Applied Soft Computing*, 73, 215-229.
- Zhang, H., & Rangaiah, G. P. (2012). An efficient constraint handling method with integrated differential evolution for numerical and engineering optimization. *Computers & Chemical Engineering*, 37, 74-88.
- Molinari, F. A., Blanco, A. M., Vigna, M. R., & Chantre, G. R. (2020). Towards an integrated weed management decision support system: A simulation model for weed-crop competition and control. *Computers and Electronics in Agriculture*, 175, 105597.
- Montain, M. E., Blanco, A. M., & Bandoni, J. A. (2015). Optimal drug infusion profiles using a particle swarm optimization algorithm. *Computers & Chemical Engineering*, 82, 13-24.
- Mussi, L., Daolio, F. & Cagnoni, S. (2011). Evaluation of parallel particle swarm optimization algorithms within the CUDA™ architecture. *Information Sciences*, 181(20), 4642-4657.
- Neeser, C., Dille, J. A., Krishnan, G., Mortensen, D. A., Rawlinson, J. T., Martin, A. R., & Bills, L. B. (2004). WeedSOFT®: a weed management decision support system. *Weed Science*, 52(1), 115-122.
- Ngatchou, P., Zarei, A., & El-Sharkawi, A. (2005). Pareto multi objective optimization. In *Proceedings of the 13th International Conference on, Intelligent Systems Application to Power Systems* (pp. 84-91). IEEE.
- Palau, H., Senesi, S., Mogni, L., & Ordóñez, I. (2018). Impacto económico macro y micro de malezas resistentes en el agro argentino. S/D: FAUBA-ADAMA. Recuperado de http://publicwebsite.adama.com/documents/345258/345805/Libro-Digital-ADAMA-FAUBA-150422_tcm41-61105. Pdf

- Pampara, G., Franken, N., & Engelbrecht, A. P. (2005). Combining particle swarm optimisation with angle modulation to solve binary problems. In 2005 IEEE congress on evolutionary computation (Vol. 1, pp. 89-96). IEEE.
- Pandey, S., & Medd, R. W. (1991). A stochastic dynamic programming framework for weed control decision making: an application to *Avena fatua* L. *Agricultural Economics*, 6(2), 115-128.
- Pannell, D. J., Stewart, V., Bennett, A., Monjardino, M., Schmidt, C., & Powles, S. B. (2004). RIM: a bioeconomic model for integrated weed management of *Lolium rigidum* in Western Australia. *Agricultural systems*, 79(3), 305-325.
- Papa, J.C., & D. Tunesca (2014). El doble golpe como táctica para controlar malezas “difíciles”. Maíz, 2014-Malezas. Trabajo publicado en www.aapresid.org.ar
- Pfetsch, M. E., Fügenschuh, A., Geißler, B., Geißler, N., Gollmer, R., Hiller, B., ... & Morsi, A. (2015). Validation of nominations in gas network optimization: models, methods, and solutions. *Optimization Methods and Software*, 30(1), 15-53.
- Raquel, C. R., & Naval Jr, P. C. (2005). An effective use of crowding distance in multiobjective particle swarm optimization. In *Proceedings of the 7th annual conference on Genetic and evolutionary computation* (pp. 257-264).
- Schaffer, J. D. (1984). *Multiple Objective Optimization with Vector Evaluated Genetic Algorithms*. *Proceedings of the First Int. Conference on Genetic Algorithms*, Ed. G.J.E Grefenstette, J.J. Lawrence Erlbaum (PhD). Vanderbilt University.
- Scursoni, J. A., Vigna, M. R., Gigón, R., Martín, A. N., Chantre Balacca, G. R., & Blanco, A. M. (2018). *Avena fatua* L.
- Selçuklu, S. B., Coit, D. W., & Felder, F. A. (2020). Pareto Uncertainty Index for Evaluating and Comparing Solutions for Stochastic Multiple Objective Problems. *European Journal of Operational Research*.

- Sells, J. E. (1995). Optimising weed management using stochastic dynamic programming to take account of uncertain herbicide performance. *Agricultural Systems*, 48(3), 271-296.
- Shokrian, M., & High, K. A. (2014). Application of a multi objective multi-leader particle swarm optimization algorithm on NLP and MINLP problems. *Computers & Chemical Engineering*, 60, 57-75.
- Tawarmalani, M., & Sahinidis, N. V. (2002). *Convexification and global optimization in continuous and mixed-integer nonlinear programming: theory, algorithms, software, and applications* (Vol. 65). Springer Science & Business Media.
- Taylor, C. R., & Burt, O. R. (1984). Near-optimal management strategies for controlling wild oats in spring wheat. *American Journal of Agricultural Economics*, 66(1), 50-60.
- Torra, J., Cirujeda, A., Recasens, J., Taberner, A., & Powles, S. B. (2010). PIM (Poppy Integrated Management): a bio-economic decision support model for the management of *Papaver rhoeas* in rain-fed cropping systems. *Weed research*, 50(2), 127-139.
- Valverde, B.E & I.A. Heap (2010) Situación actual de la resistencia a herbicidas en el mundo. En: Domínguez Valenzuela, J.A. y Medina Pitalúa, J.L. Eds *Resistencia de Plantas a Herbicidas*. Universidad Autónoma de Chapingo, Dpto Parasitología, Mexico 25-47.
- Vasileiadis, V. P., Otto, S., Van Dijk, W., Urek, G., Leskovšek, R., Verschwele, A., ... & Sattin, M. (2015). On-farm evaluation of integrated weed management tools for maize production in three different agro-environments in Europe: agronomic efficacy, herbicide use reduction, and economic sustainability. *European Journal of Agronomy*, 63, 71-78.
- Wiles, L. J., King, R. P., Schweizer, E. E., Lybecker, D. W., & Swinton, S. M. (1996). GWM: general weed management model. *Agricultural Systems*, 50(4), 355-376.
- Wolpert, D. H., & Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE transactions on evolutionary computation*, 1(1), 67-82.

- Woon, S. F., & Rehbock, V. (2010). A critical review of discrete filled function methods in solving nonlinear discrete optimization problems. *Applied mathematics and computation*, 217(1), 25-41.
- Wu, J. (2000). Optimal weed control under static and dynamic decision rules. *Agricultural Economics*, 25(1), 119-130.
- Yuen, M. C., Ng, S. C., & Leung, M. F. (2020). A Competitive Mechanism Multi-Objective Particle Swarm Optimization Algorithm and Its Application to Signalized Traffic Problem. *Cybernetics and Systems*, 1-32.
- Zemmal, N., Azizi, N., Sellami, M., Cheriguene, S., Ziani, A., AlDwairi, M., & Dendani, N. (2020). Particle Swarm Optimization Based Swarm Intelligence for Active Learning Improvement: Application on Medical Data Classification. *Cognitive Computation*, 12(5), 991-1010.
- Zhang, H., & Rangaiah, G. P. (2012). An efficient constraint handling method with integrated differential evolution for numerical and engineering optimization. *Computers & Chemical Engineering*, 37, 74-88.
- Zhang, M., Wang, H., Cui, Z., & Chen, J. (2018). Hybrid multi-objective cuckoo search with dynamical local search. *Memetic Computing*, 10(2), 199-208.
- Zhou, W., Lv, T., & Guo, Y. (2020). An Improved Particle Swarm Optimization Algorithm Based on DFC&HRS. In *International Conference on Machine Learning and Big Data Analytics for IoT Security and Privacy* (pp. 31-38). Springer, Cham.