

Desempeño biofísico y económico de sistemas de cultivos extensivos: una aproximación basada en modelos de simulación y algoritmos genéticos

Felipe Ghera¹, Lucas A. Figarola², Rodrigo Castro², Diego O. Ferraro¹

¹ Universidad de Buenos Aires (UBA), Facultad de Agronomía, Cátedra de Cerealicultura. UBA-CONICET, Instituto de Investigaciones Fisiológicas y Ecológicas Vinculadas a la Agricultura (IFEVA).

`felipeghersa@agro.uba.ar / ferraro@agro.uba.ar`

² Universidad de Buenos Aires (UBA), Facultad de Ciencias Exactas y Naturales, Departamento de Computación. CONICET, Instituto de Ciencias de la Computación (ICC).

`lfigarola@dc.uba.ar / rcastro@dc.uba.ar`

Resumen. En este trabajo se presenta un *framework* basado en modelos de simulación de cultivos y algoritmos genéticos para encontrar las combinaciones de variables de manejo (i.e. fertilización, secuencias y estructura de cultivos, y aplicación de fitosanitarios) que optimicen el desempeño biofísico y económico de sistemas de agrícolas extensivos. Además, se proponen valores umbral hipotéticos para las variables biofísicas y económicas a partir del cual se podría generar el colapso del sistema. Se generó una herramienta de diagnóstico que permite medir la distancia entre el desempeño de prácticas reales modales para Pergamino y los óptimos obtenidos mediante la optimización del algoritmo genético. Finalmente, se discuten las limitaciones de este tipo de aproximación y las implicancias para el diseño de sistemas de cultivos extensivos sustentables.

Keywords: Cultivos extensivos, Simulación, Algoritmos genéticos.

1 Introducción

Los sistemas de cultivos extensivos son una clase de sistemas biofísicos y socioeconómicos acoplados (CHANS) [1, 2] que se diseñan para aumentar su productividad y rentabilidad económica mediante el uso de insumos externos y recursos naturales internos. Sin embargo, este objetivo está limitado por condiciones sitio-específicas como el clima, el suelo o el contexto institucional, el conocimiento y la tecnología disponible [3, 4]. Es central, entonces, el uso de indicadores para evaluar el desempeño del agroecosistema y encontrar valores óptimos de funcionamiento (i.e. un diseño de sistemas que permita maximizar el logro económico minimizando el impacto sobre los recursos naturales) [5-7]. En la misma línea, también es deseable encontrar valores que se asocien a riesgos altos de colapso del sistema (e.g. contenido de materia orgánica del suelo, niveles de contaminación) que de alcanzarse generen caídas en los rendimientos o rentabilidad negativa [4].

Para evaluar el desempeño ambiental o económico de un agroecosistema es necesario medir el efecto que tienen distintas tácticas de manejo como pueden ser la aplicación de fitosanitarios, de fertilizantes, los sistemas de labranza o el tipo de rotación de cultivos, junto a la variabilidad en el flujo de capital [8, 9]. En general, para esto se utilizan estudios observacionales o ensayos experimentales [10]. Sin embargo, ambos casos requieren de tiempos y recursos considerables (en particular, en el caso de experimentos a largo plazo) [11]. Además, los resultados no pueden ser fácilmente extrapolados a condiciones edáficas o climáticas diferentes a las observadas en el contexto experimental.

Avances recientes en el desarrollo de modelos de simulación de cultivos (MSC) y capacidad computacional han generado una alternativa robusta a los estudios empíricos y la teoría pura, haciendo posible evaluar el desempeño de un agroecosistema bajo diferentes escenarios (temporales, ambientales y de manejo) en segundos o minutos mediante la experimentación *in silico* [12, 13]. Desde 1970, comenzando con el desarrollo del modelo CERES para simular el rendimiento de trigo y maíz, diferentes modelos han sido publicados, entre los cuales los más utilizados y validados actualmente son: DSSAT, EPIC, APSIM, STICS, WOFOST, ORYZA, y CROPSYST [13]. A partir de distintos abordajes de modelado y lenguajes de programación, estos modelos utilizan datos climáticos, edáfico y variables de manejo para simular el rendimiento y la biomasa de cultivos (anuales y perennes), así como el balance de agua y materia a escalas de lote, establecimiento o región. Sin embargo, una de las limitaciones de estos modelos es que requieren un trabajo extenso de parametrización manual, y no tienen incorporados módulos para automatizar la generación de estructuras de datos requeridas para ejecutar las simulaciones [14]. De este modo, en Figarola et al. [15] se desarrolló una herramienta de software que permite automatizar la generación de datos de entrada para ejecutar simulaciones en DSSAT para diferentes combinaciones de variables de manejo y escenarios climáticos y edáficos.

A partir de la selección del MSC y el conjunto representativo de indicadores para evaluar el desempeño biofísico y económico de un agroecosistema, es necesario analizar la existencia de compromisos y sinergias entre los indicadores [9, 16, 17]. Con frecuencia aumentos en la productividad o el desempeño económico generan impactos negativos en los componentes biofísicos o naturales de los agroecosistemas [18]. Entonces, se vuelve necesario evaluar el efecto de diferentes combinaciones de variables de decisión o manejo agronómico (e.g. especies y secuencias de cultivos, dosis de fertilizantes y fitosanitarios, fechas de siembra y genotipos) y jerarquizarlas en función de los indicadores seleccionados (i.e. funciones objetivo). A partir de esto, se podrán identificar las estrategias de manejo que optimicen las funciones objetivo, así como compromisos entre las ellas (mejoras en una función generan pérdidas en alguna otra función evaluada), o sinergias (mejoras simultáneas en dos o más funciones objetivo).

Uno de los desarrollos más recientes para evaluar el desempeño de sistemas productivos es la optimización evolutiva mediante el uso de algoritmos genéticos (AG) [19]. Los AG son una heurística de búsqueda que utiliza la lógica de evolución por selección natural para encontrar los "individuos" con mayor fitness dentro de una población desconocida. Estos individuos están caracterizados por genes que confieren rasgos fenotípicos (i.e. características del sistema o procesos). Un conjunto de genes se concatena

en un cromosoma y representa un individuo [20]. Esta metodología permite explorar, de manera iterativa, un espacio multidimensional de alternativas de manejo desconocidas y jerarquizarlas usando funciones de fitness (u objetivo) mediante un esquema de Pareto.

En este trabajo se presenta un *framework* basado en MSC y AG para encontrar las combinaciones de variables de manejo (i.e. nivel de fertilización, rotación y estructura de cultivos, y nivel de aplicación de fitosanitarios) que optimicen el desempeño biofísico y económico de sistemas de cultivos extensivos. Además, se proponen valores umbral hipotéticos a partir del cual se podría generar el colapso del sistema. A partir de esto, se generó una herramienta de diagnóstico que permite medir la distancia entre el desempeño de prácticas reales modales para Pergamino y los óptimos obtenidos mediante la optimización del algoritmo genético.

2 Métodos

2.1 Estructura del modelo

El *framework* se construyó a partir del acople de un AG, DSSAT (un MSC), ecuaciones de síntesis emergética y un modelo de riesgo por aplicación de fitosanitarios (RIPEST) (Fig. 1). Brevemente, el flujo de información y control del modelo es el siguiente: a partir de una lista de especies de cultivos que pueden ser potencialmente producidos en una región y tres niveles tecnológicos (dosis y tipo de fertilizante y nivel de aplicación de productos fitosanitarios) para cada cultivo, se generan todas las combinaciones de 3 o 5 años (rotaciones) posibles. Estas combinaciones están restringidas por un conjunto de reglas de factibilidad agronómica indicadas en el generador de secuencias de la Fig. 1. Están permitidas las secuencias con cultivos de primera de invierno y verano, cultivos de segunda de verano, cultivos de cobertura entre cultivos de verano e invierno y barbechos.

Para acoplar la simulación de cultivos y el AG se generó un codificador de genes y cromosomas. Esto se hizo a través de la codificación de genes como rotaciones factibles de 3 o 5 años, y cromosomas (individuos o secuencias) concatenando genes (Fig. 2). La longitud del cromosoma indica la longitud de la secuencia de cultivos (i.e. el plazo temporal de simulación). Por ejemplo, en caso de utilizar rotaciones de 3 años, un cromosoma de 10 *loci* codifica simulaciones de 30 años. En la Figura 2 se puede observar un cromosoma (i.e. individuo o secuencia de cultivos) conformado por 10 genes diferentes. A partir de esto, se utiliza un decodificador que transforma los datos contenidos en cromosomas y genes a archivos de entrada para ejecutar la simulación de la secuencia de cultivos a partir de la metodología propuesta en Figarola et al. [15]. Luego, se calculan las variables de salida que son utilizadas como métricas de desempeño ambiental y económico para evaluar el *fitness* de cada individuo.

Para ejecutar el AG es necesario determinar los hiperparámetros iniciales: (1) tamaño de población inicial, (2) número de generaciones, (3) la probabilidad de mutación y (4) la probabilidad de cruzamiento [21]. A partir de una población inicial de n individuos el algoritmo toma la probabilidad de cruzamiento y selecciona el conjunto de individuos para generar descendientes. Esto sucede a partir de la unión de una parte del

cromosoma de un individuo con la de otro individuo (siempre se generan cromosomas de la misma longitud). Luego, a partir de la probabilidad de mutación se determina un número de individuos, que componen la población inicial y los descendientes, y se muta un gen aleatorio (i.e. se asigna un nuevo valor). Finalmente, se evalúa el desempeño biofísico y económico de cada individuo y se los jerarquiza pareteanamente según el número de funciones objetivo. Para la generación siguiente, se crea una nueva población del mismo tamaño que la población inicial, con los individuos de mejor desempeño de la generación anterior. Este proceso se repite por tantas veces como el número de generaciones definidas por el usuario. Al finalizar el proceso se obtiene una frontera de Pareto; es decir, el conjunto de individuos que optimizan simultáneamente el desempeño en todas las funciones objetivo.

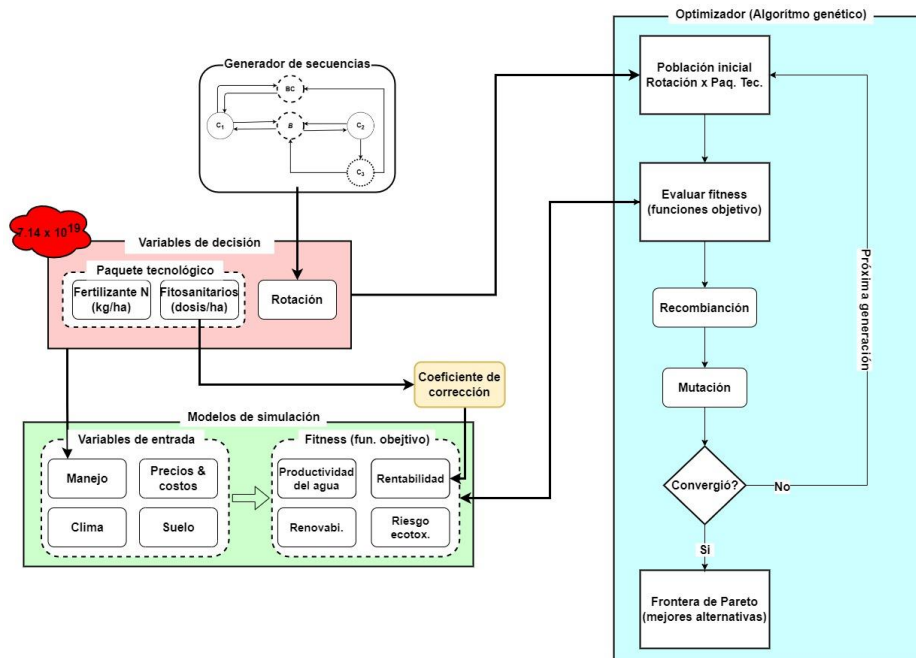


Fig. 1. Estructura del *framework* para optimización de sistemas de cultivos extensivos. A partir de un conjunto de secuencias (cuadro blanco) se generan combinaciones de variables de decisión (cuadro rosa). Los círculos de línea llena (C_1 de verano y C_2 de invierno) indican cultivos de primera. El círculo de línea punteada (C_3) indica un cultivo de segunda. Los círculos de línea de trazos gruesa (BC y B) indican barbechos con y sin cobertura vegetal, respectivamente. Luego se automatiza la generación de archivos para ejecutar las simulaciones de cultivos y se utiliza el optimizador (cuadro celeste) para generar nuevas combinaciones, evaluarlas (cuadro verde) y jerarquizarlas.




Fig. 2. Codificación de secuencias de cultivos en genes y cromosomas para la implementación del algoritmo genético. Cada cuadrado contiene un número para un gen que codifica una rotación de tres años. El conjunto de genes en línea genera un cromosoma. La longitud del cromosoma representa la extensión temporal de simulación. Las letras en negrita en los cuadros de colores representan cultivos (S: soja, T: trigo, M: maíz, G: girasol, S2: soja de segunda, M2: maíz de segunda), los subíndices T y t representan la fecha de siembra temprana o tardía, respectivamente, y las letras b y cc representan la utilización de barbecho o cultivos de cobertura entre cultivos, respectivamente.

En la Tabla 1 se presentan indicadores y métricas para cuantificar el desempeño biofísico y económico [3, 4]. Cada indicador corresponde a una componente del desempeño, que en conjunto permiten cuantificar la capacidad de autoorganización a partir de características estructurales (biodiversidad) y funcionales (balance de energía, agua y materia) [3]. Sistemas con mayores niveles de complejidad estructural y diversidad biótica muestran mayores niveles de integridad permitiendo mayor eficiencia y eficacia en la captura de recursos [22].

Tabla 1. Indicadores propuestos de desempeño biofísico y económico

Desempeño	Componente	Indicador	Métrica
Biofísico	Balance de materia y energía	Síntesis emergética	Cociente de rendimiento emergético (EYR) <i>energía capturada/energía importada</i>
			Cociente de carga ambiental (ELR) <i>energía no-renovable/energía renovable</i>
	Toxicidad	DSSAT (Century)	Aportes de carbono (residuo de cultivo)
		RIPEST (Riesgo de Pesticidas)	Toxicidad para insectos (UT_{ins}) Toxicidad para mamíferos (UT_{mam})
Económico	Balance hídrico	DSSAT (módulo de flujo hídrico)	Productividad del agua (PA) <i>rendimiento/precipitación</i>
	Ganancia	Rentabilidad	Rentabilidad promedio anual
	Riesgo	Probabilidad de pérdida económica	Probabilidad de rentabilidad < 0
	Estabilidad	Variabilidad en el nivel de ingresos	Coefficiente de variación de la rentabilidad promedio

Mediante la síntesis energética [23] se calcula el flujo de energético y balance de materia utilizando una unidad común (joule solar). Para cuantificar la capacidad de captura de energía y materia de los sistemas se utilizará el cociente de rendimiento energético (EYR). Esta métrica permite comparar la cantidad de energía capturada por unidad de energía importada al sistema. Sistemas con alta integridad y complejidad interna requerirán menores valores de energía importada para capturar energía y materia libre en el ambiente (radiación solar y nutrientes). Además, se utilizará el cociente de carga ambiental (ELR) para identificar el grado de renovabilidad que tienen los flujos de materia y energía de un sistema.

Se utiliza DSSAT [24] para simular el rendimiento, generación de biomasa y los aportes de carbono de residuos de cultivo luego de la cosecha (Gijsman, Hoogenboom et al. 2002). DSSAT simula la producción diaria total de biomasa del cultivo, así como la fracción cosechable de la biomasa total. De este modo, se utilizará la diferencia entre el valor de rendimiento (kg de biomasa cosechable) y el valor de biomasa total producida durante el período de crecimiento del cultivo (kg de biomasa aérea y radical) para estimar el aporte de carbono al sistema por los residuos del cultivo. Dado que DSSAT simula el rendimiento alcanzable limitado por agua, por lo que no están considerados los efectos de adversidades biológicas sobre los cultivos [24], se realizó una evaluación a partir de datos empíricos para obtener los coeficientes de daño (i.e. variación de rendimientos por adversidades) bajo distintos esquemas de protección de cultivos (i.e. tipo y dosis de fitosanitario) [25-27] (ver coeficiente de corrección Fig. 1).

A partir de los resultados de las simulaciones en DSSAT, se utiliza el cociente entre el rendimiento simulado y las precipitaciones como medida de productividad anual del agua de lluvias para generar grano (PA), y su partición en la relación Transpiración/Lluvias y Rendimiento/transpiración. La PA es el cociente entre el rendimiento (kg materia seca por hectárea) y las lluvias durante el período de cultivo (mm). La PA se puede descomponer en la proporción de las lluvias que se transpira, la eficiencia del uso de agua transpirada para generar materia seca (EUA) y la partición de materia seca destinada a la formación del grano. Estos factores están afectados por el balance hídrico de los agroecosistemas y pueden ser modificados mediante prácticas de manejo (e.g. especies, rotación de cultivos y fecha de siembra, entre otras). El aumento de la PA, tanto por una reducción de las salidas de agua que no son transpiración, como su conversión en grano, es crítico para mejorar la productividad de los sistemas de producción en secano.

Para estimar el riesgo ecotoxicológico para insectos y mamíferos por el uso de productos fitosanitarios se utilizan dos métricas del modelo RIPEST [28] que permiten medir la toxicidad de un conjunto de productos aplicados a partir del cociente entre la dosis aplicada y la dosis letal del producto; unidades de toxicidad para insectos (UTins) y mamíferos (UTmam). De este modo, el modelo permite cuantificar el riesgo ecotoxicológico y definir umbrales de aceptabilidad para distintos paquetes tecnológicos (combinación de pesticidas) para un año y lote específico. El valor de UT para cada compuesto se basa en la dosis letal aguda (LD50 de 48hs) para mamíferos e insectos:

$$Ti_i = \frac{D_i}{LD50_{i\ bee}}$$

$$Tm_i = \frac{D_i}{LD50_{i\ rat}}$$

donde, Tm_i y Ti_i son las unidades tóxicas para mamíferos e insectos, D_i es la dosis aplicada (gramos de producto formulado/ha) del pesticida $_i$, $LD50_{i\ rat}$ es la dosis letal aguda oral 50 para ratas (mg/k) del pesticida $_i$, y $LD50_{i\ bee}$ es la dosis letal aguda de contacto para abejas (μg /abeja) del pesticida $_i$.

A partir del cálculo de las UT para cada pesticida los valores de toxicidad de los pesticidas a aplicados en un lote son integrados para calcular la toxicidad total:

$$UTins_{la} = \sum Ti_{i,\dots,j}$$

$$UTmam_{la} = \sum Tm_{i,\dots,j}$$

donde, $UTins_{la}$ y $UTmam_{la}$ son las unidades tóxicas aplicadas en el lote l durante el año a , $\sum Ti_{i,\dots,j}$ y $\sum Tm_{i,\dots,j}$ son las sumatorias de unidades tóxicas para insectos y mamíferos, respectivamente, de los pesticidas $_{i,\dots,j}$.

Se utilizará la rentabilidad (i.e. Ingresos netos/costos) promedio anual de secuencias de cultivos simuladas para medir la ganancia económica. A partir de esto, se utiliza el coeficiente de variación de la rentabilidad promedio anual para cada simulación de 30 años para evaluar la estabilidad de las trayectorias de ganancias. Por último, como medida de riesgo económico se evalúa la probabilidad de pérdida económica (i.e. rentabilidad < 0) en el plazo de 30 años simulados:

$$P(\text{riesgo económico}) = \frac{pe_r}{n_r}$$

donde, pe es el número de años con rentabilidad menor a 0 de la rotación r , y n es la longitud (años) de la rotación r .

2.2 Implementación

El *framework* se desarrolló en Microsoft Visual Studio Code utilizando el lenguaje Python 3. Para ejecutar DSSAT en línea de comando se utilizaron los módulos *so* y *subprocess*. Para leer la matriz de restricciones se utilizó el módulo *csv*. Se utilizó el módulo *os.path* para trabajar con rutas de forma general. El algoritmo genético se desarrolló utilizando la librería DEAP (accesible a través de: <https://deap.readthedocs.io/en/master/>). Los gráficos y el análisis descriptivo se realizaron con el software estadístico R a través de los paquetes Ggplot2 y Raster.

2.3 Prueba de concepto

Para demostrar el funcionamiento del modelo se realizó una prueba de concepto utilizando la rentabilidad operativa (margen bruto / costos) como indicador de desempeño económico y el cociente entre energía no-renovable y energía renovable (ELR) como indicador de desempeño biofísico de Pergamino, Buenos Aires, Argentina. Esta localidad está ubicada en la región de la Pampa Ondulada (33°53'00"S; 60°34'00"O), la subregión más productiva de la región pampeana. Los suelos predominantes son Argiudoles típicos y la precipitación promedio anual es de 950mm. Para generar las

rotaciones de cultivos se utilizaron tres cultivos de verano (maíz, soja y girasol), un cultivo de invierno (trigo) y dos cultivos de cobertura (centeno y vicia faba). Se parametrizaron los archivos de DSSAT a partir de datos modales obtenidos de bases de datos de la Bolsa de Cereales (RETAA) y Márgenes Agropecuarios (Tabla 2). Estas bases también se utilizaron para generar matrices de precios y costos para el cálculo de la rentabilidad. Los cultivares fueron previamente calibrados y validados para la región. Se construyeron secuencias de 30 años a partir de rotaciones de 3 años. Se utilizó una serie climática obtenida de la base de datos climáticos de SIGA desde 1972 hasta 2002 y una matriz de suelo previamente validada (serie Rojas).

Para evaluar el *fitness* de las secuencias de 30 años (individuos) se utilizó el algoritmo NSGA-II [20] y se parametrizó utilizando una población inicial de 100 individuos, 300 generaciones, 0.9 de probabilidad de cruzamiento y 0.2 de probabilidad de mutación. Estos valores se determinaron a través de experimentación previa utilizando curvas de saturación para las funciones objetivo y una revisión bibliográfica. La optimización buscó minimizar el ELR y maximizar la rentabilidad simultáneamente. Es decir, se buscaron las alternativas que minimicen el uso de energía no-renovable y maximicen los ingresos del productor. Para valorizar los resultados se utilizaron umbrales que indicaran un mal desempeño del sistema. El criterio elegido fue el siguiente: valores por encima de 1 para ELR, es decir dependencia de energía no-renovable, y por debajo de 0 para rentabilidad, es decir que no se llegan a cubrir los costos con el margen bruto.

Tabla 2. Parámetros de manejo para simulación de cultivos

Cultivo	Genotipo	Fecha de siembra	Densidad (p/m ²)	Distancia entre hileras (cm)	Fertilizante N (kg/ha)
Maíz	DK 682 GS120	15 de septiembre	10	52	120
		1 de octubre	8	52	150
Trigo	Baguette 11	20 de junio	250	23	200
		5 de julio	220	23	200
Soja	DM 4800	5 de octubre	30	21	0
		20 de octubre	30	21	0
Girasol	Pioneer 64A93	15 de octubre	5	52	80
		1 de noviembre	5	52	80
Soja 2 ^{da}	DM 4800	10 de diciembre	37	21	0
Maíz 2 ^{da}	DK 682 GS120	18 de diciembre	7	52	200
Centeno	DSSAT Default Wheat	15 de abril	200	21	0
Vicia faba	DSSAT Default	15 de abril	200	21	0

Las funciones objetivo para la optimización fueron los promedios anuales de los tres indicadores para las secuencias de longitud temporal l en rotaciones de longitud temporal n :

$$M_r = \frac{\sum_{s=1}^n \frac{\sum_{c=1}^l M_{cs}}{l_s}}{n_r}$$

donde, M_r es el valor de la métrica promedio anual de la rotación r , M_{cs} es el valor de la métrica para el cultivo c en la secuencia s , l_s es la longitud temporal de la secuencia s , y n_r es la longitud temporal de la rotación r . Los cultivos doble y cultivos de verano seguidos por cultivos de cobertura serán considerados como un solo cultivo c para el cálculo de los valores de las métricas.

Finalmente, se simularon valores para las funciones objetivo correspondiente a una rotación de maíz seguido de soja y luego un cultivo doble de trigo y soja de segunda (MSWs) durante un período de 30 años. Se eligió esta rotación dado que es la rotación más frecuentemente utilizada en la región. Luego se diagnosticó el estado de este sistema en base a la evaluación de la distancia euclídea entre el desempeño de la rotación y el conjunto de secuencias óptimas obtenidas a través de los experimentos de optimización (fronteras de Pareto). Por último, mediante un análisis descriptivo se realizó una caracterización de las alternativas que se ubicaban entre la frontera de Pareto y el punto que indica el desempeño de la rotación MSWs en función de sus prácticas agronómicas (i.e. diversidad de cultivos, número de cultivos por año, proporción de cada cultivo en la rotación, y proporción de nivel tecnológico utilizado). Estos puntos representan secuencias con mayor eficiencia de Pareto que la rotación MSWs.

3 Resultados

A partir de la optimización de dos objetivos (rentabilidad y ELR) se encontró una frontera de Pareto de secuencias de cultivos alternativas que optimizan la rentabilidad operativa y el ELR. La frontera se compuso de 31 secuencias cuyo valor mínimo de ELR fue 1.05 y valor máximo de rentabilidad operativa fue de 177 (Fig. 3). Esto indica que todas las alternativas más eficientes encontradas estuvieron por encima del umbral fijado de ELR de 1, lo que implica un uso de energía no-renovable al menos 5% mayor que energía renovable. En cuanto a la rentabilidad de las alternativas pareteanas, tuvieron un rango de variación entre 133 y 177. Es decir, las ganancias de los sistemas pareteanos fueron en promedio entre 133% y 177% durante los 30 años simulados relativo a los costos de producción. La curvatura de la frontera de Pareto indica que en situaciones de máxima eficiencia existe un compromiso entre aumentos de la rentabilidad y la disminución del uso relativo de energía no-renovable.

La rotación de maíz, soja y un doble cultivo trigo, soja de segunda simulada tuvo una rentabilidad operativa de 107 y un ELR de 1.9. Es decir que, se obtuvo una ganancia económica promedio de 107% durante los 30 años simulados relativo a los costos y se utilizó casi el doble de energía no-renovable que renovable. En la Figura 3 se pueden observar los dos vectores generados para calcular la distancia euclídea entre el desempeño de la rotación MSWs y las secuencias alternativas con mayor eficiencia de Pareto. Del total de alternativas simuladas se encontraron 13166 con mayor eficiencia de Pareto que la rotación MSWs. Los puntos sobre el vector B representan alternativas que permiten mejorar el desempeño ambiental respecto de MSWs, en dirección hacia el sistema de aumentar rentabilidad de la frontera de Pareto. Los puntos sobre el vector A representan alternativas que permiten aumentar el desempeño económico en dirección

hacia el sistema de mayor ELR de la frontera de Pareto. La longitud de los vectores es $A=0.26$, $B=0.40$.

En la Figura 4 se presentó una caracterización de las secuencias que se encuentran sobre cada uno de los vectores, así como la frontera de Pareto. En el Fig. 4A se observa que las rotaciones que conforman ambos vectores permiten una disminución del valor de ELR respecto de la rotación MSWs. Lo mismo sucede en el Fig. 4B se observa que las rotaciones que conforman ambos vectores permiten aumentar el valor de rentabilidad respecto de la rotación MSWs. Las alternativas de mayor eficiencia de Pareto respecto de la rotación MSWs presentaron mayores niveles de diversidad de cultivos (Fig. 4D), una diversificación en los niveles tecnológicos utilizados (Fig. 4E), y una reducción en la proporción de soja (Fig. 4F). El número de cultivos tuvo una variación leve con una reducción para vectores A y B, y un aumento para el vector D.

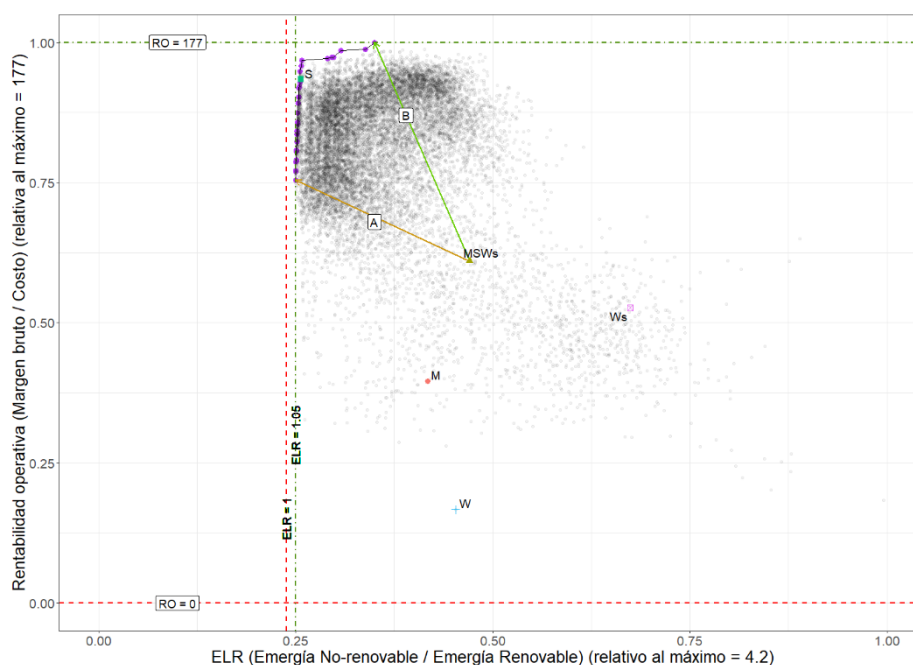


Fig. 3. Diagnóstico de desempeño biofísico (ELR) y económico (rentabilidad operativa) de una rotación de maíz, soja y un doble cultivo trigo, soja de segunda (MSWs). Los ejes están relativizados a los valores máximos observados en la optimización (ELR = 4.2, RO=177). Los puntos representan secuencias de simuladas de 30 años. Los puntos violetas representan el frente de Pareto obtenido en el experimento de optimización de dos objetivos utilizando NSGA-II. Los puntos grises es la población total del proceso de optimización. El punto verde representa la rotación MSWs. Los vectores marcan conjuntos de alternativas con mejor desempeño de Pareto que la rotación MSWs. Las líneas punteadas rojas muestran los umbrales deseables para los indicadores ELR = 1 (igual uso de energía no-renovable y renovable), RO = 0 (se cubren los costos con el margen bruto). Las líneas punteadas verdes muestran los valores máximos y mínimos de cada indicador para la frontera de Pareto obtenidos en la optimización.

Asimismo, los sistemas con mayor eficiencia de Pareto, tanto los que se ubicaron sobre la frontera, como aquellos que conforman los vectores A y B, tienen menor número de cultivos por año (Fig. 4C). Sin embargo, las rotaciones ubicadas sobre la frontera de Pareto también tienen menor diversidad de cultivos (Fig. 4D), principalmente explicadas por un aumento en la proporción del cultivo de soja y girasol por sobre los cultivos de trigo y maíz.

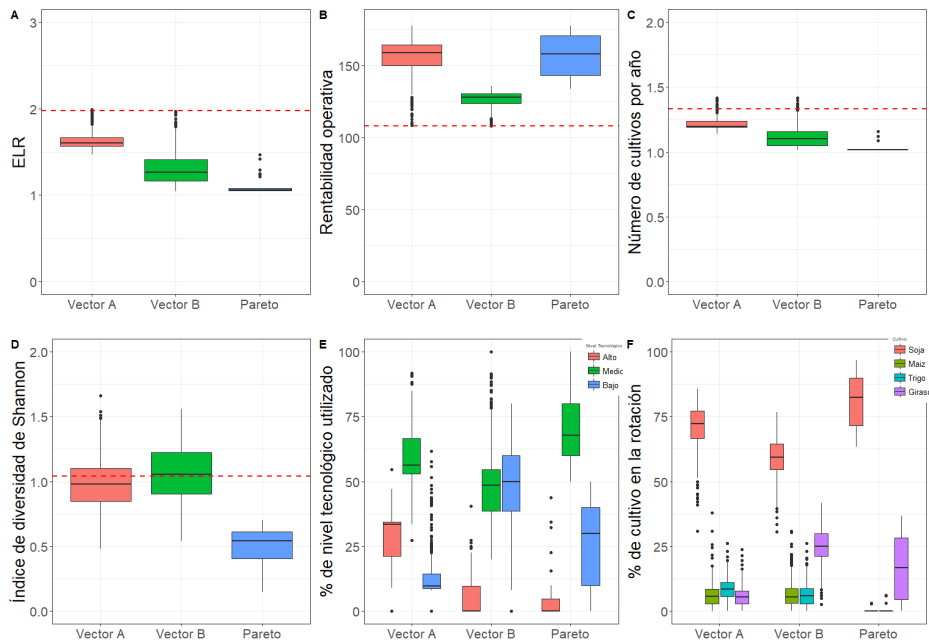


Fig. 4. Caracterización de secuencias alternativas con mayor eficiencia de Pareto respecto de la rotación MSWs. El vector A son alternativas que permiten aumentar el desempeño ambiental sin afectar la rentabilidad respecto de MSWs, el vector B representa alternativas que permiten mejorar el desempeño ambiental en dirección hacia el sistema de menor rentabilidad de la frontera de Pareto. La línea punteada roja en las figuras A, B, C y D son los valores de cada indicador para la rotación MSWs. El nivel tecnológico utilizado para MSWs fue 100% nivel medio, y la proporción de cultivos fue 60% soja, 20% trigo y 20% maíz.

4 Discusión y conclusiones

En este trabajo se presentó un *framework* que permite optimizar objetivos de desempeño biofísico y económico de sistemas de cultivos extensivos. Se realizó una prueba de concepto de optimización de dos objetivos para la localidad de Pergamino y se diagnosticó el desempeño de una práctica frecuente de la localidad en función de su distancia euclídea a las secuencias alternativas de mayor eficiencia de Pareto y sus características agronómicas.

Los resultados obtenidos en esta prueba de concepto presentan algunas limitaciones sobre las que es necesario profundizar. La primera es que no existe un marco general para establecer valores adecuados a los hiperparámetros de los algoritmos genéticos [29]. Estas metodologías de búsqueda heurística requieren un trabajo intensivo de parametrización a través de validación con expertos y experimentos factoriales. Aun así, es imposible tener certeza absoluta de que la frontera de Pareto encontrada implica el conjunto de óptimos globales [9]. No obstante, existen métricas que se pueden utilizar para evaluar la probabilidad de proximidad del conjunto óptimo obtenido con el conjunto óptimo global real [29, 30]. Una segunda limitación es que para calcular la rentabilidad solo se utilizaron datos de costos directos dentro de los establecimientos. No se consideraron los costos asociados con aranceles, impuestos y otras barreras para arancelarias relativas a cada cultivo. Estas variables podrían afectar fuertemente los resultados obtenidos ya que, no solo tienen valores temporalmente dinámicos, sino que pueden generar variaciones significativas en los precios relativos de cada cultivo.

No obstante, mediante una parametrización adecuada de los modelos de simulación y el algoritmo genético este *framework* permite explorar de manera exhaustiva el espacio de alternativas de manejo óptimas para diferentes condiciones ambientales y económicas. Utilizando metodologías convencionales de experimentación y ensayos a campo, esta aproximación sería imposible. Asimismo, es posible utilizar los resultados de la optimización para diagnosticar el estado actual de prácticas modales y encontrar alternativas factibles que permitan manejos de la tierra con mayores niveles de desempeño económico y menores niveles de impacto ambiental, así como las principales prácticas agronómicas que las caracterizan. Como consecuencia, este tipo de estudios es altamente relevante para el diseño de sistemas de cultivos extensivos sustentables, la generación de hipótesis acerca del funcionamiento de sistemas naturales y humanos acoplados y el desarrollo y mejora de modelos de simulación de cultivos.

Referencias

1. Liu, J., et al., *Complexity of coupled human and natural systems*. science, 2007. **317**(5844): p. 1513-1516.
2. Liu, J., et al., *Coupled human and natural systems*. AMBIO: a journal of the human environment, 2007. **36**(8): p. 639-649.
3. Müller, F. and M. Leupelt, *Eco targets, goal functions, and orientors*. 2012: Springer Science & Business Media.
4. Burkhard, B., B.D. Fath, and F. Müller, *Adapting the adaptive cycle: Hypotheses on the development of ecosystem properties and services*. Ecological Modelling, 2011. **222**(16): p. 2878-2890.
5. Ghersa, F., et al., *Theory and Practice for Environmental Risk Assessment: Understanding the Trade-Off Between the Benefits and Risks Behind Herbicide Use as Tool for Designing Sustainable Weed Management Systems*, in *Decision support systems for weed management*. 2020, Springer. p. 161-189.
6. Rositano, F. and D.O. Ferraro, *Ecosystem services provided by agroecosystems: A qualitative and quantitative assessment of this relationship in the Pampa region, Argentina*. Environmental management, 2014. **53**(3): p. 606-619.

7. Girardin, P., C. Bockstaller, and H.V.d. Werf, *Indicators: tools to evaluate the environmental impacts of farming systems*. Journal of sustainable agriculture, 1999. **13**(4): p. 5-21.
8. Ferraro, D.O. and M. Gagliostro, *Trade-off assessments between environmental and economic indicators in cropping systems of Pampa region (Argentina)*. Ecological indicators, 2017. **83**: p. 328-337.
9. DeVoil, P., W.A. Rossing, and G.L. Hammer, *Exploring profit-sustainability trade-offs in cropping systems using evolutionary algorithms*. Environmental Modelling & Software, 2006. **21**(9): p. 1368-1374.
10. Andrade, J.F., et al., *Productivity and resource use in intensified cropping systems in the Rolling Pampa, Argentina*. European Journal of Agronomy, 2015. **67**: p. 37-51.
11. Aref, S. and M.M. Wander, *Long-term trends of corn yield and soil organic matter in different crop sequences and soil fertility treatments on the Morrow Plots*. Advances in agronomy, 1997. **62**: p. 153-197.
12. Hoogenboom, G., et al., *Advances in crop modeling for a sustainable agriculture*. The DSSAT Crop Modeling Ecosystem, 2019: p. 173-216.
13. Jones, J.W., et al., *Brief history of agricultural systems modeling*. Agricultural systems, 2017. **155**: p. 240-254.
14. Silva, J.V. and K.E. Giller, *Grand challenges for the 21st century: what crop models can and can't (yet) do*. The Journal of Agricultural Science, 2020. **158**(10): p. 794-805.
15. Figarola, L., et al. *Automatización del modelo de simulación de cultivos DSSAT para evaluar el desempeño productivo bajo distintas estrategias de manejo y escenarios ambientales*. in *XII Congreso de AgroInformática (CAI 2020)-JAIIO 49 (Modalidad virtual)*. 2020.
16. Groot, J.C., G.J. Oomen, and W.A. Rossing, *Multi-objective optimization and design of farming systems*. Agricultural Systems, 2012. **110**: p. 63-77.
17. Kropp, I., et al., *A multi-objective approach to water and nutrient efficiency for sustainable agricultural intensification*. Agricultural Systems, 2019. **173**: p. 289-302.
18. Kanter, D.R., et al., *Evaluating agricultural trade-offs in the age of sustainable development*. Agricultural Systems, 2018. **163**: p. 73-88.
19. Groot, J.C. and W.A. Rossing, *Model-aided learning for adaptive management of natural resources: an evolutionary design perspective*. Methods in Ecology and Evolution, 2011. **2**(6): p. 643-650.
20. Deb, K., et al., *A fast and elitist multiobjective genetic algorithm: NSGA-II*. IEEE transactions on evolutionary computation, 2002. **6**(2): p. 182-197.
21. Chand, S. and M. Wagner, *Evolutionary many-objective optimization: A quick-start guide*. Surveys in Operations Research and Management Science, 2015. **20**(2): p. 35-42.
22. Holling, C.S., *Understanding the complexity of economic, ecological, and social systems*. Ecosystems, 2001. **4**(5): p. 390-405.
23. Odum, H.T., *Emergy accounting*, in *Unveiling wealth*. 2002, Springer. p. 135-146.
24. Jones, J.W., et al., *The DSSAT cropping system model*. European journal of agronomy, 2003. **18**(3-4): p. 235-265.
25. Mercau, J., et al., *On-farm assessment of regional and seasonal variation in sunflower yield in Argentina*. Agricultural Systems, 2001. **67**(2): p. 83-103.
26. Mercau, J., et al. *Evaluación a campo del comportamiento del modelo CERES en cultivos de maíz del norte de la provincia de Buenos Aires*. in *VII Congreso Nacional de Maíz. AIANBA. Pergamino, Buenos Aires, Argentina*. 2001.

27. Mercau, J.L., et al., *Predicting on-farm soybean yields in the pampas using CROPGRO-soybean*. Field Crops Research, 2007. **100**(2-3): p. 200-209.
28. Ferraro, D.O., et al., *Environmental risk indicators for weed management: a case study of ecotoxicity assessment using fuzzy logic*, in *Decision Support Systems for Weed Management*. 2020, Springer. p. 191-210.
29. Mills, K.L., J.J. Filliben, and A. Haines, *Determining relative importance and effective settings for genetic algorithm control parameters*. Evolutionary computation, 2015. **23**(2): p. 309-342.
30. Eiben, A.E. and S.K. Smit, *Parameter tuning for configuring and analyzing evolutionary algorithms*. Swarm and Evolutionary Computation, 2011. **1**(1): p. 19-31.