

Adaptive Goal Programming via Gaussian Processes for Forest Supply Chain Coordination

Dan E. Kröhling¹, María Laura Cúnico¹, Nicolás A. Vanzetti¹ and Gabriela Corsano¹

¹ Instituto de Desarrollo y Diseño INGAR (CONICET/UTN),
Avellaneda 3657 (S3002GJC), Santa Fe, Argentina.

Abstract. The forest supply chain involves multiple stakeholders whose operational decisions are interrelated, creating challenges in coordination and in the efficient distribution of benefits. This study analyzes how the systematic exploration of different coordination configurations among firms in the chain impacts both the overall economic performance of the system and the individual benefits of each firm. To this end, an iterative multi-objective optimization framework assisted by artificial intelligence is developed. The approach combines a mixed-integer linear programming (MILP) model based on goal programming, Gaussian Processes, and expected improvement criteria to guide the exploration of the weight search space. Unlike traditional approaches, the proposed methodology incorporates an adaptive objective selection mechanism that dynamically prioritizes those objectives with the greatest potential for improvement. At each iteration, Gaussian Process models are fitted to capture the relationship between weights and objective performance, enabling the construction of acquisition functions that balance exploration and exploitation in the search for new configurations. The results show that the proposed approach identifies a diverse set of efficient solutions, representing different trade-offs among economic objectives. Furthermore, the findings indicate that the integration of decisions can alter the distribution of benefits among stakeholders and generate operational configurations that are more favorable for the overall performance of the supply chain.

Keywords: Multi-objective optimization; Gaussian Processes; Bayesian optimization; Forest supply chain.

Programación Adaptativa por Metas mediante Procesos Gaussianos para la Coordinación de la Cadena de Suministro Forestal

Resumen. La cadena de suministro forestal involucra múltiples actores cuyas decisiones operativas se encuentran interrelacionadas, generando desafíos en la coordinación y distribución eficiente de beneficios. En este trabajo, se analiza cómo la exploración sistemática de distintas configuraciones de coordinación entre empresas de la cadena impacta en el desempeño económico global del sistema y en el beneficio individual de cada empresa. Con este objetivo, se

desarrolla un esquema iterativo de optimización multiobjetivo asistida por inteligencia artificial que combina un modelo de programación mixto entero lineal (MILP) basado en programación por objetivos, Procesos Gaussianos y criterios de mejora esperada para guiar la exploración del espacio de búsqueda de pesos. A diferencia de enfoques tradicionales, la metodología propuesta incorpora un mecanismo de selección adaptativa de objetivos que prioriza dinámicamente aquellos con mayor margen de mejora. En cada iteración, se ajustan modelos de Procesos Gaussianos que capturan la relación entre los pesos y el desempeño de los objetivos, permitiendo construir funciones de adquisición que balancean exploración y explotación en la búsqueda de nuevas configuraciones. Los resultados muestran que el enfoque propuesto permite identificar un conjunto diverso de soluciones eficientes, representando distintos *trade offs* entre los objetivos económicos. Asimismo, se evidencia que la integración de decisiones puede modificar la distribución de beneficios entre los actores y generar configuraciones operativas más favorables para el desempeño global de la cadena.

Palabras clave: Optimización multiobjetivo; Procesos Gaussianos; Optimización Bayesiana; Cadena de Suministro Forestal.

1 Introducción

La cadena de suministro (CS) forestal constituye un sistema complejo e integrado que articula múltiples actividades, desde la cosecha de recursos madereros hasta su transformación en productos industriales y energéticos. Este sistema involucra la extracción de trozas y residuos en áreas forestales, el transporte entre distintos actores y la conversión en bienes finales dentro de plantas de procesamiento. En este contexto, no solo la madera en sí misma, sino también los subproductos y residuos (como corteza, aserrín y astillas) adquieren creciente relevancia como insumos estratégicos para diversas aplicaciones.

La adecuada coordinación entre los distintos eslabones de la CS se vuelve un factor crítico para maximizar el uso de los recursos disponibles y mejorar el desempeño global del sistema. La necesidad de integrar actores con objetivos potencialmente divergentes, gestionar flujos de materiales heterogéneos y adaptarse a condiciones de demanda cambiantes, plantea desafíos operativos y estratégicos. A ello se suman exigencias crecientes en términos de sostenibilidad ambiental, eficiencia logística y resiliencia frente a incertidumbres, lo que demanda enfoques innovadores para la planificación y gestión de la cadena.

En el caso de Argentina, la CS forestal presenta un significativo potencial de expansión, particularmente en la región del Litoral, donde se concentra la mayor parte de las plantaciones forestales del país. No obstante, este potencial coexiste con limitaciones estructurales vinculadas a la eficiencia operativa, la articulación entre actores y la necesidad de diversificar la matriz productiva. En este escenario, resulta fundamental desarrollar herramientas que permitan abordar estos desafíos de manera integral, promoviendo una mayor coordinación y agregación de valor en el sector.

En este trabajo, se propone analizar la CS forestal desde una perspectiva integradora, poniendo énfasis en las oportunidades de mejora asociadas a la coordinación entre sus

participantes. De este modo, se busca contribuir al desarrollo de marcos analíticos que favorezcan una gestión más eficiente y equilibrada del sistema en su conjunto.

Diversas contribuciones académicas han explorado la toma de decisiones y el desempeño de la CS forestal bajo distintos enfoques metodológicos (Santos et al., 2019). En particular, se han desarrollado modelos para analizar estructuras descentralizadas, donde los distintos actores toman decisiones de manera autónoma, evidenciando la complejidad inherente a la coordinación en estos sistemas (Yue and You, 2017). También se han propuesto esquemas de optimización bajo distintos paradigmas de gestión (como producción contra pedido, inventarios administrados por el proveedor o planificación centralizada), así como modelos que incorporan simultáneamente objetivos económicos y ambientales (Alayet et al., 2018; Ahmadvand et al., 2021). Sin embargo, la mayoría de estos estudios adoptan una perspectiva centrada en el desempeño agregado de la cadena, privilegiando métricas globales que no permiten analizar en profundidad cómo se distribuyen los beneficios y costos entre los distintos participantes.

En este contexto, el presente trabajo tiene como objetivo desarrollar un enfoque integral para la evaluación y análisis de la CS forestal, abordando de manera simultánea el desempeño global y las implicancias a nivel de cada participante. Para ello, se propone una herramienta analítica basada en la combinación de programación mixta entera lineal (MILP) y técnicas de inteligencia artificial (IA). Específicamente, se desarrolla una metodología iterativa que ejecuta modelos subrogados, sustentados en procesos gaussianos (GPs), para explorar distintas configuraciones de los parámetros de peso empleados en un modelo de programación por objetivos, que se utiliza para representar la CS forestal con metas globales e individuales ponderadas. Esta integración permite recorrer de manera sistemática el espacio de soluciones, identificando configuraciones que equilibran los objetivos individuales y colectivos mediante el análisis de desviaciones respecto a óptimos globales e individuales.

La programación por objetivos propone la búsqueda de soluciones suficientemente buenas en contextos con múltiples objetivos y restricciones. Este enfoque resulta especialmente adecuado para problemas complejos de toma de decisiones, donde coexisten metas potencialmente conflictivas. Esta metodología ha sido ampliamente utilizada en diversos ámbitos (San Cristobal, 2012; Lee et al., 2017; Goli et al., 2019; Gütmen et al., 2023), incluso dentro de la industria forestal (Díaz-Balteiro et al., 2013; Broz et al., 2019). Su flexibilidad permite incorporar preferencias de los decisores y analizar distintos escenarios, lo que la convierte en una metodología particularmente valiosa para contextos donde es necesario armonizar intereses múltiples. Sin embargo, la definición de los parámetros de ponderación sigue siendo un aspecto crítico y no completamente resuelto dentro del marco de la optimización multicriterio. A pesar de la existencia de enfoques más rigurosos, como el Analytic Hierarchy Process (Kumar and Pant, 2023), la asignación de los pesos que reflejan la importancia relativa de cada objetivo suele basarse en juicios subjetivos o en criterios poco estandarizados. Por este motivo, se propone asistir al proceso de decisión mediante el uso de GPs, con el fin de explorar y asignar de manera sistemática distintas configuraciones de los pesos. Esta propuesta se apoya en algunos avances que se presentan en la literatura, en la que se han discutido algunas estrategias de integración entre el aprendizaje automático y la optimización MILP. En particular, Bengio et al. (2021) destacan la necesidad de un enfoque más integrado, proponiendo tratar los problemas de optimización como

instancias para entrenar un algoritmo de aprendizaje automático que aprenda a seleccionar la mejor estrategia de resolución. En la misma línea, Kotary et al. (2021) revisan métodos híbridos para problemas con restricciones, mientras que Gambella et al. (2021) analizan distintas técnicas de aprendizaje automático aplicadas a la optimización.

Finalmente, cabe destacar que este estudio examina el *trade off* entre la integración de la cadena y los intereses particulares de sus miembros desde una perspectiva táctica, proponiendo un enfoque que, si bien se desarrolla en el contexto forestal, resulta potencialmente extensible a otras CS con problemáticas similares. En consecuencia, el enfoque desarrollado facilita la evaluación de múltiples escenarios y provee a los tomadores de decisiones un marco robusto para identificar alternativas que promuevan una distribución más equitativa de beneficios y esfuerzos entre los actores de una CS. De este modo, la metodología se posiciona como una herramienta efectiva para fortalecer la coordinación y fomentar la colaboración en CS complejas, contribuyendo a una toma de decisiones más informada y alineada con los intereses de todos los participantes.

En síntesis, el trabajo propone un enfoque integrador para el análisis de la cadena de suministro forestal, junto con una metodología analítica que combina la evaluación global e individual mediante modelos multiobjetivo. A través de la exploración sistemática del espacio de soluciones mediante una estrategia guiada de pesos, se identifican configuraciones equilibradas y una representación diversa del frente de Pareto, evitando sesgos hacia objetivos particulares. Asimismo, se evidencia el impacto de la integración tanto en el desempeño global como en la distribución de beneficios, aportando un marco que permite analizar compromisos entre objetivos y mejorar la equidad y coordinación entre los actores.

El trabajo se estructura de la siguiente manera: en la sección 2, se declara el problema que será abordado, destacando los resultados preliminares que motivaron el desarrollo de la propuesta. En la sección 3, se introduce la metodología de articulación entre la programación por objetivos y GPs. En la sección 4, se presentan y analizan los resultados obtenidos a partir de la aplicación de la metodología propuesta, mientras que en la Sección 5 se exponen las conclusiones generales.

2 Descripción del Problema y Motivación

Se considera una cadena de suministro (CS) integrada por los sectores forestal e industrial. El sector forestal (FOR) es el encargado de proveer materia prima desde cuatro áreas de cosecha, mientras que el sector industrial se conforma por un conjunto de cuatro plantas, incluyendo una planta de generación de energía eléctrica (ENE), una planta de tableros de fibra (FB), un aserradero (SAW) y una planta de tableros contrachapados (PW). Los materiales provenientes del sector forestal, junto con los insumos adquiridos a mayor costo de proveedores externos, son procesados en estas instalaciones para obtener distintos productos finales destinados a la venta. A su vez, los procesos productivos generan subproductos que pueden reutilizarse internamente como insumos en otras plantas o como fuente de energía, configurando una red de interacciones e intercambios entre los distintos actores de la CS. La Fig. 1 presenta un

esquema de la estructura general de la CS analizada, en el que se observan las interacciones mencionadas entre los distintos agentes que conforman el sistema.

En el trabajo publicado por Vanzetti et al. (2022), los autores proponen un modelo de programación MILP para analizar el desempeño de esta cadena. Posteriormente, se utilizó un enfoque basado en programación por objetivos para considerar tanto el beneficio global del sistema, como el de cada uno de sus integrantes de manera individual. El objetivo fue evaluar los efectos de la integración y la coordinación entre los distintos eslabones de la CS.



Fig. 1. Cadena de suministro forestal.

En este contexto, se realizó una comparación de los beneficios obtenidos por cada planta bajo dos esquemas operativos: (1) de manera independiente: para cada sector productivo se resolvió el modelo MILP cuya función objetivo es la maximización del beneficio económico de dicho sector; (2) de forma integrada dentro de la cadena: se ejecutó el modelo MILP maximizando el beneficio global de la CS, y se evaluaron los beneficios individuales en el óptimo alcanzado. Los resultados de cada esquema se contrastaron para analizar el impacto de la integración de la CS sobre los rendimientos individuales de sus agentes. La Tabla 1 resume los beneficios individuales obtenidos por cada sector bajo el esquema de operación independiente, los cuales se reportan en la primera columna y representan el máximo rendimiento económico alcanzable para cada unidad productiva. En la segunda columna se consignan los beneficios individuales derivados de la operación integrada dentro de la CS. Finalmente, la tercera columna muestra la variación porcentual entre ambos esquemas operativos. Se evidencia, de este modo, un comportamiento contrapuesto entre los beneficios individuales y el beneficio global de la CS. En todos los casos, la operación integrada genera una disminución en los beneficios particulares de los actores que la componen, destacando una marcada disparidad en la magnitud de dichas variaciones. En particular, las pérdidas relativas oscilan entre valores inferiores al 5% y cercanos al 60%, lo que pone de manifiesto una distribución poco equitativa de los costos asociados a la coordinación sistémica. Esta situación desincentiva la cooperación entre los participantes y, en consecuencia, compromete la viabilidad del enfoque centralizado.

Con el objetivo de alinear los intereses individuales con el óptimo global de la CS, y promover los esquemas operativos integrados, se propone la implementación de un enfoque de programación por objetivos asistido por IA. Para evaluar el comportamiento

de la CS forestal, considerando simultáneamente los beneficios individuales y globales, es necesario definir algún criterio de ponderación. Sin embargo, la determinación de este criterio representa un desafío inherente al enfoque empleado. Por este motivo, proponemos generar una metodología iterativa que auxilie al proceso de selección de pesos mediante el uso de modelos subrogados.

Tabla 1. Comparación de beneficios individuales bajo esquemas de operación independiente e integrada en la cadena de suministro

Sectores Productivos	Beneficios (\$)		Variación (%)
	Operación Independiente	Operación Integrada	
Sector Forestal (FOR)	24096,2	22981,4	-4,6
Gen. Eléctrica (ENE)	1579,6	1480	-6,3
Tab. de fibra (FB)	6965,2	6388,4	-8,3
Aserradero (SAW)	9060,2	3767,8	-58,4
Contrachapados (PW)	5131,9	3274,7	-36,2
Beneficio global de CS	37892,3		

3 Metodología

La metodología propuesta se basa en un esquema iterativo de optimización multiobjetivo asistida por modelos subrogados, en el cual se combinan técnicas de programación por objetivos, Procesos Gaussianos (*Gaussian Processes* o GPs) (Rasmussen et al., 2005) y criterios de adquisición basados en mejora esperada (*Expected Improvement* o EI) (Qin et al., 2017). El procedimiento general se ilustra en la Fig. 2 y se describe a continuación.

3.1 Inicialización

El proceso comienza con la definición de un conjunto inicial de pesos WO para cada uno de los objetivos $i \in I$ analizados, donde $I = \{FOR, ENE, FB, SAW, PW\}$, representando distintas preferencias sobre los objetivos del problema. Se pretende explorar de manera iterativa distintos valores para estos pesos $WO = \langle WO_{FOR}, WO_{ENE}, WO_{FB}, WO_{SAW}, WO_{PW} \rangle$ con el fin de construir paulatinamente la frontera de Pareto del problema, esto es, el conjunto de soluciones óptimas en donde no es posible mejorar un objetivo sin empeorar otro.

A partir de cada uno de los pesos WO_i vinculados a cada objetivo i , se realiza una inicialización de parámetros, que incluye:

- El conjunto inicial de valores de los pesos $WO = \langle 20, 20, 20, 20, 20 \rangle$,
- Las correspondientes evaluaciones B_i de los beneficios individuales i .
- El beneficio global, $B_{GLO} = \sum_i B_i$.
- La configuración inicial de los modelos de Procesos Gaussianos.

3.2 Optimización por objetivos

En cada iteración, se ejecuta una etapa de optimización por objetivos, donde el problema multiobjetivo se resuelve utilizando los valores actuales de los pesos WO . Esto permite obtener soluciones candidatas que reflejan distintas compensaciones o *trade offs* entre objetivos.

Los resultados de esta optimización se incorporan al conjunto acumulado de resultados de optimización. De esta forma, cada iteración t en la que se corre el problema de optimización sirve para enriquecer la información que se tiene sobre la superficie objetivo.




Fig. 2. Diagrama de flujo de la propuesta metodológica.

3.3 Selección adaptativa del objetivo

A diferencia de los enfoques tradicionales de optimización multiobjetivo, que modelan todas las salidas de manera simultánea o mediante un escalado fijo, en este trabajo se propone un esquema de selección adaptativa de objetivos dentro de un proceso de optimización bayesiana secuencial.

Sea B el vector de beneficios individuales del problema multiobjetivo. En cada iteración t , se selecciona un único objetivo B_i de forma estocástica según una distribución de probabilidades. La probabilidad de selección de cada objetivo se actualiza en función del desempeño observado. En particular, se considera el mejor valor histórico $m_{i,t}$ por objetivo i para una iteración t , y se define una señal de déficit $\delta_{i,t} = m_{i,t} - B_{i,t}$, que mide el margen de mejora de cada objetivo. Esta señal se utiliza para asignar probabilidades, utilizando una medida dinámica de cuánto se encuentra el objetivo por debajo de su mejor desempeño observado.

Las probabilidades de selección se obtienen a partir de la señal de déficit $\delta_{i,t}$ mediante normalización. En particular, se calcula:

$$p_{i,t} = \frac{\delta_{i,t}}{\sum_j \delta_{j,t} + \varepsilon}$$

donde ε es una constante positiva pequeña utilizada para evitar divisiones por cero. De esta forma, los objetivos con mayor déficit respecto de su mejor desempeño histórico reciben una mayor probabilidad de selección, mientras que aquellos con menores déficits son seleccionados con menor frecuencia.

Este mecanismo introduce un criterio de justicia adaptativo, promoviendo una exploración más equilibrada del espacio de objetivos y evitando la concentración prematura en un subconjunto de ellos. Además, se logra un balance dinámico entre exploración y explotación en cada iteración.

3.4 Ajuste con Procesos Gaussianos

Para modelar la función objetivo se utiliza un conjunto de cinco GPs, uno por cada beneficio considerado. Cada GP aproxima la relación entre el vector de pesos WO y el valor de un objetivo específico. Aunque en cada iteración la función de adquisición se construye únicamente sobre el GP asociado al objetivo seleccionado, cada evaluación del modelo MILP genera simultáneamente observaciones para los cinco objetivos, permitiendo actualizar la base de datos utilizada por todos los modelos sustitutos.

Dado el objetivo seleccionado, se construye un GP unidimensional que modela la relación entre las variables de decisión, que corresponden a los pesos WO , y el valor de los beneficios individuales B_i . Es decir, se aproxima la función desconocida:

$$f_i(WO) \approx B_i$$

El GP queda completamente definido por una función de media y un *kernel* de covarianza, el cual captura la similitud entre distintas configuraciones de pesos. Este *kernel* induce propiedades estructurales en la función estimada (por ejemplo, suavidad), permitiendo interpolar de manera coherente entre observaciones cercanas en el espacio

de decisión. En este caso, la función de media corresponde a una media constante, mientras que la función de covarianza utiliza un *kernel RBF* (Radial Basis Function) con escalas de longitud independientes por cada dimensión de entrada (ARD). Los hiperparámetros del modelo se estiman automáticamente durante el proceso de entrenamiento.

A partir de este modelo, se obtiene una distribución posterior sobre $f_i(WO) \approx B_i$, que proporciona tanto una estimación del valor esperado como una medida de incertidumbre en cada punto del dominio. De esta forma, el problema multiobjetivo se aborda como una secuencia de problemas de regresión unidimensionales, donde en cada iteración se focaliza el aprendizaje en un objetivo particular, manteniendo un balance adaptativo entre ellos a través de la política de selección.

El uso de GPs resulta fundamental en este contexto, ya que permite aproximar funciones objetivo potencialmente costosas de evaluar, incorporando además una medida explícita de incertidumbre. Esto habilita la toma de decisiones informadas sobre dónde muestrear a continuación, maximizando la eficiencia del proceso de optimización.

3.5 Selección de pesos mediante mejora esperada

La distribución posterior obtenida a partir del GP se utiliza para definir una función de adquisición, la cual guía la selección del próximo vector de pesos a evaluar. En este trabajo se adopta el criterio de Mejora Esperada (*Expected Improvement*, EI), aplicado en el espacio de pesos.

La EI cuantifica, para cada posible configuración WO_i , la mejora esperada respecto del mejor valor observado hasta el momento para el objetivo considerado, combinando la media y la incertidumbre provistas por el GP. En particular, asigna mayor valor a aquellos puntos que presentan simultáneamente alto valor esperado y/o alta incertidumbre, favoreciendo así un balance natural entre explotación y exploración.

En este trabajo se emplea la función de adquisición EI en su formulación estándar, sin parámetros adicionales de exploración. El equilibrio entre exploración y explotación surge de manera inherente al criterio, ya que la mejora esperada depende tanto de la predicción media del modelo sustituto como de la incertidumbre asociada a dicha predicción. Como resultado, la búsqueda favorece simultáneamente regiones prometedoras y regiones insuficientemente exploradas del espacio de soluciones.

En términos prácticos, este enfoque permite, por un lado, evaluar el impacto esperado de distintas configuraciones de pesos sobre el desempeño del objetivo seleccionado y, por el otro, priorizar aquellas que maximizan la mejora potencial, contribuyendo indirectamente a una mejor aproximación del frente de Pareto. De esta forma, la selección de nuevos pesos no es aleatoria, sino que se encuentra informada por el modelo probabilístico, orientando la búsqueda hacia regiones del espacio de decisión con mayor potencial de ganancia.

3.6 Criterio de parada

El proceso iterativo continúa hasta alcanzar un criterio de parada predefinido, típicamente un número máximo de iteraciones t o, de manera equivalente, la cantidad de evaluaciones del modelo de optimización realizadas.

En cada iteración t , el conjunto de soluciones se actualiza incorporando nuevas configuraciones de pesos y sus correspondientes valores objetivo. Este conjunto acumulado constituye una aproximación progresiva del frente de Pareto, ya que contiene soluciones que reflejan distintos compromisos entre los objetivos en conflicto.

Las soluciones obtenidas resultan valiosas no solo por su calidad individual, sino también porque capturan la diversidad de *trade offs* presentes en el problema. En particular, permiten analizar cómo varían los objetivos frente a cambios en los pesos, identificar regiones del espacio de decisión asociadas a distintos perfiles de desempeño, y ofrecer un conjunto de alternativas entre las cuales un decisor puede seleccionar según sus preferencias.

El esquema propuesto, basado en selección adaptativa de objetivos y exploración guiada por modelos probabilísticos, favorece una cobertura más equilibrada del espacio de soluciones. Como resultado, se obtiene un conjunto de puntos que no solo tienden a ser eficientes, sino también informativos respecto de la estructura del problema multiobjetivo.

4 Resultados

La metodología propuesta se implementó para la CS forestal descrita en la sección 2, considerando un total de 100 iteraciones. La Fig. 3 presenta la evolución de los resultados alcanzados a través del método propuesto a lo largo de las iteraciones, junto con la dinámica de los pesos asociados a los objetivos. En el panel superior se muestra la composición promedio de los pesos cuando se utiliza la función de adquisición EI, mientras que en los paneles inferiores se ilustra la evolución del valor medio alcanzado para cada objetivo individual y para el objetivo agregado B_{GLO} , que corresponde a la suma de beneficios individuales.

En primer lugar, el gráfico de áreas apiladas evidencia que los pesos no permanecen constantes, sino que se ajustan dinámicamente a lo largo del proceso. Este comportamiento es consistente con el mecanismo de selección adaptativa de objetivos propuesto: los cambios en la distribución de pesos reflejan la reasignación de importancia hacia aquellos objetivos con mayor margen de mejora relativa. En particular, se observa que el algoritmo evita concentrarse de manera permanente en un único objetivo, promoviendo una exploración balanceada del espacio de soluciones.

En cuanto a los objetivos individuales, las curvas muestran que, si bien no todos los objetivos alcanzan simultáneamente sus máximos teóricos (debido a los *trade offs* inherentes), el método logra aproximarse a ellos de manera razonablemente equilibrada.

Finalmente, el objetivo agregado permite evaluar el desempeño global del sistema. La evolución de esta métrica refleja el efecto combinado de las decisiones tomadas en cada iteración, mostrando cómo la optimización secuencial guiada por modelos probabilísticos conduce a las distintas soluciones. En conjunto, los resultados evidencian que la metodología propuesta genera un conjunto de soluciones diverso e

informativo, capturando de manera efectiva los compromisos del problema multiobjetivo, que pueden ayudar en la toma de decisiones.




Fig. 3. Evolución de los resultados alcanzados a través del método propuesto.

La Tabla 2 presenta las correlaciones entre los pesos WO_i y los valores alcanzados en cada objetivo individual B_i . Estos resultados permiten analizar de manera cuantitativa cómo la asignación de pesos impacta en el desempeño de cada componente del problema multiobjetivo.

Tabla 2. Correlaciones entre pesos WO_i y valores alcanzados en cada beneficio individual B_i y el beneficio global B_{GLO} .

	B_{FOR}	B_{ENE}	B_{FB}	B_{SAW}	B_{PW}	B_{GLO}
WO_{FOR}	0.722	-0.091	-0.017	-0.449	-0.259	0.709
WO_{ENE}	0.003	0.711	-0.060	0.028	-0.124	-0.038
WO_{FB}	0.155	-0.077	0.757	-0.233	-0.104	0.183
WO_{SAW}	-0.546	0.248	-0.442	0.763	-0.409	-0.524
WO_{PW}	-0.107	-0.522	-0.203	-0.165	0.833	-0.033

En primer lugar, se observa una fuerte correlación positiva entre cada peso y su objetivo asociado, lo cual valida la coherencia del esquema de optimización. Incrementar el peso de un objetivo tiende a mejorar directamente su valor correspondiente. Este comportamiento confirma que el modelo responde de manera consistente a las preferencias inducidas por los pesos.

Más interesante aún es la presencia de correlaciones negativas cruzadas, que evidencian los *trade offs* inherentes al problema. Por ejemplo, el peso WO_{SAW} presenta correlaciones negativas significativas con varios objetivos (-0.546 con B_{FOR} , -0.442 con B_{FB} y -0.409 con B_{PW}), indicando que priorizar la maximización del beneficio del aserradero implica sacrificar desempeño en otros. De manera similar, una mayor ponderación del beneficio de los tableros (WO_{PW}) atenta contra el beneficio de la planta generadora de energía (B_{ENE}), con la cual muestra una correlación negativa marcada (-0.522), mientras que una mayor ponderación del beneficio del sector forestal (WO_{FOR}) afecta al beneficio del aserradero (B_{SAW}) de manera negativa (-0.449). Estos patrones sugieren que ciertos objetivos compiten fuertemente por los recursos o decisiones subyacentes, lo cual justifica la necesidad de un enfoque multiobjetivo que explore explícitamente estos compromisos en lugar de optimizar un único criterio agregado. Por otro lado, también se identifican correlaciones débiles o cercanas a cero entre algunos pares, lo que indica relativa independencia. Por ejemplo, WO_{ENE} tiene un impacto prácticamente nulo sobre B_{FOR} (0.003), lo que sugiere que estos objetivos pueden mejorarse de forma desacoplada.

El análisis de correlación entre los pesos y el beneficio global permite identificar qué objetivos tienen mayor incidencia en el desempeño agregado del sistema. En particular, se observa una fuerte correlación positiva del sector forestal WO_{FOR} (0.709), lo que indica que priorizar este objetivo contribuye significativamente a incrementar el beneficio global. En menor medida, el sector de tableros de fibra WO_{FB} (0.183) también presenta una relación positiva, sugiriendo un aporte favorable, aunque más moderado. En contraste, el aserradero, WO_{SAW} , exhibe una correlación negativa relevante (-0.524), es decir, asignar mayor peso a este objetivo tiende a deteriorar el desempeño global, evidenciando un *trade off* estructural dentro del sistema. Por su parte, el sector de energía WO_{ENE} y el de contrachapado WO_{PW} muestran correlaciones cercanas a cero (de -0.038 y -0.033 , respectivamente), lo que sugiere un impacto marginal sobre el beneficio global. Estos resultados demuestran que no todos los objetivos contribuyen de igual manera al desempeño agregado de la cadena.

En conjunto, esta estructura de correlaciones refuerza la pertinencia del enfoque propuesto: la existencia simultánea de relaciones positivas fuertes (en la que se alinean los objetivos individuales con su peso respectivo) y negativas cruzadas (en la que se muestran los conflictos entre objetivos) crea un escenario donde la selección adaptativa de objetivos y la exploración guiada por EI resultan especialmente adecuadas. En particular, el mecanismo de actualización de pesos permite responder dinámicamente a estos *trade offs*, priorizando aquellos objetivos que han quedado rezagados, sin perder de vista el impacto global sobre el sistema.

5 Conclusiones

En este trabajo se presentó un enfoque de optimización multiobjetivo asistido por inteligencia artificial para explorar configuraciones de coordinación en la cadena de suministro forestal. La combinación de un modelo MILP de programación por objetivos y un esquema iterativo basado en Procesos Gaussianos y mejora esperada permitió recorrer de manera eficiente el espacio de búsqueda de pesos, identificando soluciones que reflejan distintos compromisos entre los objetivos económicos.

Los resultados evidencian que la estructura del problema presenta *trade offs* significativos entre objetivos. En particular, el análisis de correlaciones mostró que el peso asociado al beneficio forestal (WO_{FOR}) tiene una influencia positiva relevante sobre el beneficio global (0.709), mientras que otros objetivos, como los relativos al aserradero (WO_{SAW}), presentan una incidencia negativa considerable (-0.524). Esto confirma que no todas las decisiones contribuyen de igual forma al desempeño agregado, y que la coordinación entre actores implica necesariamente equilibrar efectos contrapuestos.

Asimismo, el enfoque propuesto permitió construir un conjunto diverso de soluciones eficientes, donde ningún objetivo alcanza simultáneamente su valor máximo teórico, pero sí se logran configuraciones balanceadas con altos niveles de desempeño global. En este sentido, la exploración guiada del espacio de búsqueda de pesos resultó clave para evitar soluciones sesgadas hacia un único objetivo y favorecer una cobertura más representativa del frente de Pareto.

En conjunto, los resultados muestran que la integración de decisiones no solo impacta en el nivel de beneficio global, sino también en su distribución entre los participantes de la CS. La metodología propuesta permite, por lo tanto, no solo mejorar el desempeño del sistema, sino también generar información valiosa para la toma de decisiones, facilitando la identificación de configuraciones de coordinación más eficientes y consistentes con distintos criterios económicos.

Referencias

- Ahmadvand, S., Khadivi, M., Arora, R., Sowlati, T. (2021) Bi-objective optimization of forest-based biomass supply chains for minimization of costs and deviations from safety stock. *Energy Conversion and Management*: X, 11, 100101. <https://doi.org/10.1016/j.ecmx.2021.100101>

- Alayet, C., Lehoux, N., Lebel, L. (2018) Logistics approaches assessment to better coordinate a forest products supply chain. *Journal of Forest Economics*, 30, 13–24. <https://doi.org/10.1016/j.jfe.2017.11.001>
- Bengio, Y., Lodi, A., Prouvost, A. (2021). Machine learning for combinatorial optimization: A methodological tour d’horizon. *European Journal of Operational Research*, 290(2), 405–421. <https://doi.org/10.1016/j.ejor.2020.07.063>
- Broz, D. Vanzetti, N. Corsano, G. Montagna, J. (2019) Goal programming application for the decision support in the daily production planning of sawmills. *Forest Policy and Economics*, 102, 29–40. <https://doi.org/10.1016/j.forpol.2019.02.004>
- Díaz-Balteiro, L.; Pachón, J.; Romero, C. Goal programming in forest management: customizing models for the decision-makers preferences. *Scandinavian Journal of Forest Research* (2013) 28(2): 166-173. <https://doi.org/10.1080/02827581.2012.712154>
- Gambella, C., Ghaddar, B., Naoum-Sawaya, J. (2021). Optimization problems for machine learning: A survey. *European Journal of Operational Research*, 290(3), 807–828. <https://doi.org/10.1016/j.ejor.2020.08.045>
- Goli, A., Tirkolaee, E. B., Malmir, B., Bian, G.-B., & Sangaiah, A. K. (2019). A multi-objective invasive weed optimization algorithm for robust aggregate production planning under uncertain seasonal demand. *Computing*, 101(6), 499–529. <https://doi.org/10.1007/s00607-018-00692-2>
- Gütmen, S.; Roy, S. K.; Weber, G-W. (2023). An overview of weighted goal programming: a multi-objective transportation problem with some fresh viewpoints. *Central European Journal of Operations Research*, 32 (3), 1-12. [10.1007/s10100-023-00861-5](https://doi.org/10.1007/s10100-023-00861-5).
- Kotary, J., Fioretto, F., Hentenryck, P. van, Wilder, B. (2021). End-to-End Constrained Optimization Learning: A Survey. *Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence*, 4475–4482. <https://doi.org/10.24963/ijcai.2021/610>
- Kumar, A.; Pant, S. (2023). Analytical hierarchy process for sustainable agriculture: An overview. *MethodsX*, 10, 101954. <https://doi.org/10.1016/j.mex.2022.101954>.
- Lee, A.H.I.; Chen, H. H.; Kang, H.Y. (2017) A conceptual model for prioritizing dam sites for tidal energy sources, *Ocean Eng.*, 137, 38-47. <https://doi.org/10.1016/j.oceaneng.2017.03.039>.
- Najafizadeh, A., Salajegheh, A., Rahmani, A.M.; Sahafi, A. (2022) Multi-objective Task Scheduling in cloud-fog computing using goal programming approach. *Cluster Computing*, 25, 141–165. <https://doi.org/10.1007/s10586-021-03371-8>
- Qin, C., Klabjan, D., Russo, D. (2017). Improving the expected improvement algorithm. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS’17)*. Curran Associates Inc., Red Hook, NY, USA, 5387–5397.
- Rasmussen, C. E., & Williams, C. K. I. (2005). *Gaussian Processes for Machine Learning*. The MIT Press. <https://doi.org/10.7551/mitpress/3206.001.0001>
- San Cristobal, J.R. (2012) A goal programming model for the optimal mix and location of renewable energy plants in the north of Spain, *Renew. Sustain. Energy Rev.*, 16 (7), 4461-4464. <https://doi.org/10.1016/j.rser.2012.04.039>.
- Santos, A.; Carvalho, A.; Barbosa-Póvoa, A.; Marques, A.; Amorim, P. (2019) Assessment and optimization of sustainable forest wood supply chains – A systematic literature review. *Forest Policy and Economics*, 105, 112-135. <https://doi.org/10.1016/j.forpol.2019.05.026>
- Vanzetti, N.; Corsano, G.; Montagna, J. M. (2022) Economical Assessment of the Benefits of the Supply Chain Management: A Forestry Industry Example. *Ind. Eng. Chem. Res.*, 61 (35), 13205-13220. <https://doi.org/10.1021/acs.iecr.2c01655>.
- Yue, D., You, F. (2017) Stackelberg-game-based modeling and optimization for supply chain design and operations: A mixed integer bilevel programming framework. *Computers and Chemical Engineering*, 102, 81–95. <https://doi.org/10.1016/j.compchemeng.2016.07.026>