

UNIVERSIDAD DE CONCEPCIÓN - CHILE
FACULTAD DE INGENIERIA
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

***Optimización De Los Esquemas De Corte
En Aserraderos Forestales Mediante
Algoritmos Metaheurísticos***

por
Juan Eduardo Garcés Seguel

Profesor Guía:
Dra. Lorena Pradenas Rojas

Profesor Co- Guía:
Dr. Víctor Parada Daza

Concepción, diciembre de 2007

Tesis presentada a la

**ESCUELA DE GRADUADOS
DE LA UNIVERSIDAD DE CONCEPCION**



Para optar al grado de

MAGISTER EN INGENIERÍA INDUSTRIAL

Apoyado parcialmente por Proyecto ALFAII-0457-FA-FCD-FI-FC y Proyecto Fundación
Andes-Chile C- 13955/18

RESUMEN

Optimización De Los Esquemas De Corte En Aserraderos Forestales Mediante Algoritmos Metaheurísticos

Juan Eduardo Garcés Seguel
Mayo de 2007

PROFESOR GUIA: **Dra. Lorena Pradenas Rojas**
PROGRAMA: **Magíster en Ingeniería Industrial**

Existen numerosos procesos productivos que requieren del corte de materias primas con el fin de obtener productos finales o intermedios. En este estudio se han propuesto e implementado algoritmos metaheurísticos, basados en Simulated Annealing y Algoritmos Genéticos, para la optimización de los esquemas de corte en aserraderos.

Al aplicar el algoritmo basado en Simulated Annealing, se obtienen soluciones con rendimientos de 77,02% en promedio para todos los problemas de prueba. Por su parte, el Algoritmo Genético implementado es capaz de alcanzar y superar la mejor solución conocida para la mayoría de los problemas de prueba considerados, obteniendo soluciones con un rendimiento promedio de casi 82% para todos los problemas. Al comparar ambos algoritmos, para un mismo tiempo de ejecución, la implementación de Algoritmos Genéticos es capaz de encontrar mejores soluciones que Simulated Annealing.

Palabras Claves: Problema de corte, optimización aserraderos, metaheurísticas

ABSTRACT

Optimization of Sawing Patterns at Sawmills Using Metaheuristic Algorithms

Juan Eduardo Garcés Seguel
May 2007

THESIS SUPERVISOR: Dr. Lorena Pradenas Rojas
PROGRAM: Master in Industrial Engineering

Numerous productive processes exist that require of the cut of raw material in order to obtaining final or intermediate products. In this study are proposed and implemented metaheuristic algorithms, based on Simulated Annealing and Genetic Algorithms, for the optimization of the sawing patterns at sawmills.

When applying the Simulated Annealing algorithm, solutions with 77,02% of efficiency were obtained in average for all of the test problems. The Genetic Algorithm could reach the best known solution for most of the test problems, obtaining solutions with almost 82% of average efficiency for all the test problems. When comparing both algorithms for the same execution time, was obtained that the implementation of Genetic Algorithms can find better solutions than Simulated Annealing.

Keywords: Cutting problem, sawmills optimization, metaheuristics.

ÍNDICE

CAPÍTULO 1. INTRODUCCIÓN	3
1.1 Antecedentes generales.....	3
1.2 Objetivos	4
1.3 Metodología	5
CAPÍTULO 2. DESCRIPCIÓN DEL PROBLEMA	7
2.1 Antecedentes generales.....	7
2.2 El proceso de corte de rollizos	9
2.2.1 Calidad de la madera obtenida a partir de una troza	9
2.2.2 Rendimiento de materia prima.....	10
2.2.3 Beneficio Económico.....	15
CAPÍTULO 3. MARCO TEÓRICO	16
3.1 El Problema de corte de piezas a partir de materias primas.....	16
3.2 Aplicaciones	17
3.3 Problema de corte de piezas regulares.....	18
3.4 Problema de corte de piezas irregulares.....	19
3.5 Formulaciones y modelamiento.....	20
3.6 Métodos de resolución para el problema de corte de piezas	21
3.6.1 Métodos exactos	22
3.6.2 Heurísticas Particulares	23
3.6.3 Metaheurísticas	25
3.6.4 Métodos Híbridos.....	26
3.7 Optimización del corte de rollizos	27
3.7.1 Desarrollo de modelos de optimización	27
3.7.2 Aplicación de herramientas de simulación.....	30
3.7.3 Consideraciones respecto al caso particular	31
CAPÍTULO 4. PROPUESTA DE SOLUCIÓN	33
4.1 Definición del problema	33
4.2 Caracterización del problema.....	36
4.3 Solución propuesta.....	38
4.4 Generación de soluciones	39
4.5 Implementación de Simulated Annealing.....	46
4.5.2 Decisiones genéricas.....	48
4.5.3 Decisiones específicas.....	49

4.5.4 Interacción entre función constructora y Simulated Annealing	53
4.6 Implementación del Algoritmo Genético	54
4.6.2 Representación y codificación de una solución	56
4.6.3 Definición de operadores.....	57
4.6.4 Función de Evaluación	58
4.6.5 Inicialización del algoritmo.....	59
4.6.6 Criterios de término.....	59
4.6.7 Parámetros del algoritmo.....	59
4.6.8 Interacción entre función constructora y Algoritmo Genético.....	60
4.7 Implementación Computacional	61
CAPÍTULO 5. RESULTADOS	62
5.1 Generación de problemas de prueba	62
5.2 Establecimiento de parámetros	65
5.2.2 Establecimiento de parámetros para Simulated Annealing	68
5.2.3 Establecimiento de parámetros para el Algoritmo Genético.....	96
5.3 Resultados promedio para Simulated Annealing	114
5.4 Resultados promedio para Algoritmo Genético.....	115
5.5 Comparación entre ambos algoritmos.....	116
CAPÍTULO 6. CONCLUSIONES	120
REFERENCIAS.....	124
ANEXOS.....	127

CAPÍTULO 1. INTRODUCCIÓN

1.1 Antecedentes generales

Existen numerosos procesos productivos que necesariamente requieren el corte de materias primas con el fin de obtener productos finales o intermedios, tal es el caso de las industrias de: muebles, textil, cuero, calzado, vidrio, aserrío, entre otras. Maximizar el uso del material es un importante objetivo, debido a que el costo de éste usualmente corresponde a un alto porcentaje del costo del producto terminado. En muchas empresas manufactureras, el proceso de seleccionar las piezas a cortar y la ubicación de las diferentes piezas en la lámina se realiza en forma manual y de acuerdo con la experiencia del operario encargado de efectuar esta tarea.

El problema de ubicar y cortar diferentes piezas a partir de una lámina o placa con el fin de minimizar las pérdidas de material, o maximizar el valor que proporcionan las piezas cortadas es conocido en la literatura como "cutting stock problem". El problema de corte de piezas es del tipo NP-Completo, es decir, para todos los algoritmos actualmente conocidos capaces de encontrar soluciones óptimas para estos problemas, el número de pasos computacionales crece exponencialmente de acuerdo al tamaño de la instancia. Es por esta razón que entre los métodos de solución para estos problemas predominan las técnicas heurísticas, ya sea particulares o de propósito general, con el fin de encontrar buenas soluciones en tiempo computacional razonable.

En el caso de la industria del aserrío, uno de los puntos más importantes dentro de la programación de la producción, consiste en definir cómo se cortarán los rollizos disponibles, es decir, determinar un programa de corte con el fin de satisfacer el conjunto de pedidos del aserradero para un cierto horizonte de tiempo, minimizando la pérdida de materia prima, lo que se traduce en importantes ahorros en costo de ésta. Para este proceso se utilizan los denominados esquemas de corte, los cuales son diagramas en que se detalla el tipo y ubicación de las piezas que se desea obtener a partir de rollizos de un diámetro

determinado. El proceso de definir los esquemas de corte a utilizar se efectúa manualmente, y en el caso de aserraderos grandes, es a veces apoyado por programas computacionales que permiten simular los resultados de aplicar un determinado esquema, mediante un procedimiento de “prueba y error”. Actualmente, en nuestro país no se dispone de herramientas de optimización para esta tarea, sino que la asignación de esquemas de corte se efectúa de acuerdo a la experiencia del programador y en base a información histórica relativa a los esquemas de corte utilizados y sus rendimientos. A partir de esa información histórica, se seleccionan directamente o se adaptan los esquemas que se cree pueden optimizar el rendimiento de la materia prima.

El propósito de este estudio es desarrollar e implementar algoritmos metaheurísticos para la optimización del corte de rollizos en aserraderos. Los algoritmos planteados constan de dos fases: una función constructora capaz de generar soluciones factibles (en este caso, un conjunto de esquemas de corte) dependiendo de la información que se le proporcione como entrada, y una metaheurística, ya sea Simulated Annealing o Algoritmos Genéticos, las cuales se encargan de efectuar la búsqueda a través del espacio de solución. A diferencia del procedimiento utilizado actualmente para definir el programa de corte, que requiere de un conjunto de esquemas de corte previamente generado, los algoritmos propuestos generan un conjunto de esquemas de cortes factibles con el objetivo de maximizar el rendimiento de la materia prima, sin necesidad de recurrir a patrones de corte predefinidos.

1.2 Objetivos

Objetivo General

Proponer un modelo y un algoritmo de solución usando metaheurísticas para el problema de optimización del corte irregular de piezas, aplicado al corte de rollizos en aserraderos.

Objetivos específicos

- Modelar con metaheurísticas (Simulated Annealing y Algoritmos Genéticos) el problema de corte irregular de piezas aplicado al problema de optimización de los esquemas de corte de rollizos en aserraderos.

- Implementar los algoritmos propuestos.
- Determinar valores para los parámetros de los algoritmos que permitan encontrar buenas soluciones para los problemas de prueba considerados.
- Comparar los resultados obtenidos con ambas metaheurísticas.

1.3 Metodología

La metodología utilizada durante el desarrollo de este estudio fue la siguiente:

- Revisión de la literatura referente al problema de corte de piezas. Se efectuó una revisión de trabajos recientes en el tema, tanto para corte de piezas regulares como irregulares.
- Estudio del problema específico. Esta etapa incluyó visitas a aserraderos de la región, consulta a expertos y revisión de la literatura especializada en la industria del aserrío (Haygreen et al., 1996, y Willinston, 1988). Esto permitió conocer las características más relevantes con relación al problema de corte de rollizos. Además, se efectuó una revisión de trabajos relacionados con la optimización de la producción de madera aserrada.
- Modelamiento del problema. Consistió en una caracterización del problema, incluyendo la definición de variables y parámetros relevantes, así como el establecimiento de algunos supuestos para el modelamiento.
- Propuesta, implementación y prueba de los algoritmos de solución. En esta etapa se desarrollaron los algoritmos para el problema en estudio, los cuales se implementaron computacionalmente. Para determinar los valores apropiados para los parámetros de las metaheurísticas, se diseñó una serie de experimentos multifactoriales. Se generó aleatoriamente un conjunto de problemas de prueba, con el fin de evaluar el desempeño de los algoritmos propuestos.

El contenido de este informe se estructura de la siguiente forma: En el capítulo dos se realiza una descripción del problema, que incluye caracterización del proceso productivo en general y distintos aspectos respecto al procedimiento de corte de rollizos. En el capítulo

tres se presentan conceptos teóricos referentes al problema de corte de piezas, sus variantes, aplicaciones, así como las principales técnicas y métodos de solución; además se presenta una revisión de la literatura específica al problema de optimización de la producción de madera aserrada. En el capítulo cuatro se describe la propuesta de solución al problema en estudio, incluyendo los supuestos considerados, parámetros y variables del problema y la descripción de los algoritmos propuestos. En el capítulo cinco se presentan los resultados obtenidos para los problemas de prueba considerados, así como una comparación entre los algoritmos propuestos. Finalmente, en el capítulo seis se exponen las principales conclusiones y recomendaciones referentes a este estudio.

CAPÍTULO 2. DESCRIPCIÓN DEL PROBLEMA

2.1 Antecedentes generales

El sector forestal comprende todas las actividades económicas relacionadas con la explotación e industrialización de productos forestales. Como parte del sector forestal, la industria del aserrío pertenece, según la clasificación de actividades forestales (CAEF) usada por el Instituto Forestal chileno (INFOR), a la industria forestal de primera transformación, que reúne el conjunto de actividades relacionadas con la conversión química, mecánica o mixta de los productos extraídos del bosque, principalmente madera en trozas. Los productos resultantes, en general, mantienen la condición de bien intermedio, sirviendo como insumo a otro proceso productivo (industria forestal de segunda transformación). En este sentido, el aserrío es una actividad más de manufactura entre las del sector forestal, la cual consiste básicamente en la obtención de piezas de madera de determinadas dimensiones, denominadas escuadrías, a partir de trozas o rollizos. Las piezas obtenidas presentan diversas características que permiten satisfacer distintos mercados.

Las diferencias principales entre los distintos aserraderos que existen en nuestro país se refieren a: proceso productivo que emplean, tecnologías, especialización, calificación del personal, entre otros. En general, el proceso de aserrío puede comprender las siguientes operaciones (Haygreen et al., 1996):

- Trozado: La materia prima (trozos), es cortada en trozos de menor longitud.
- Descortezado: Consiste en quitar la corteza al trozo. Esta operación permite remover impurezas, como arena o gravilla, proporcionando mayor duración a las sierras. La corteza removida puede ser usada como combustible para generación de energía. Además, el “chipeado” de madera sin corteza puede ser usado para elaborar pulpa.
- Corte primario: En esta etapa se puede usar uno de los dos métodos siguientes:

1. Colocar la troza en un carro “huincha”. Se corta una pieza de la troza con cada paso de ésta a través de la sierra. Este método actualmente se usa de preferencia para el corte de trozas más grandes, de sobre 16 pulgadas de diámetro, o en aserraderos que requieren de flexibilidad en cuanto al tamaño de trozas a procesar y madera a obtener.
 2. Headrig de paso simple. Las trozas pasan a través de la máquina sólo una vez, en un flujo más o menos continuo. Sierras secundarias efectúan cortes adicionales. El creciente uso de trozas más pequeñas ha estimulado el desarrollo de este tipo de equipamiento.
- Cortes secundarios: Después de la primera etapa de corte, la madera obtenida en la operación anterior puede requerir cortes adicionales, tanto en ancho como en largo, con el fin de eliminar defectos, o dimensionar la madera de acuerdo a los distintos requerimientos. En esta etapa es necesario disponer de operarios capacitados en calidad de la madera, ya que además de maximizar el volumen de madera a obtener, muchas veces se prioriza maximizar el valor de ésta.
 - Clasificado: En esta etapa la madera es clasificada de acuerdo a distintos criterios, tales como: calidad, usos, dimensiones, etc. Además, se puede clasificar de acuerdo con el tratamiento posterior (secado, tratamientos químicos, etc.).
 - Tratamientos: Luego de ser clasificada, la madera debe ser secada en hornos, cuyas condiciones internas, tales como humedad y temperatura son constantemente controladas. El secado mejora la calidad de la madera y la protege de decoloración, putrefacción, encogimiento y otras deformaciones. Además, las tablas deben pasar por tratamientos químicos proporcionándoles otras propiedades, dependiendo del producto.
 - Clasificado y Empaque: En esta etapa, la madera es nuevamente clasificada, empacada y almacenada en espera de ser enviada a su destino final.

2.2 El proceso de corte de rollizos

El objetivo principal de la etapa de corte de rollizos en el proceso de aserrío, es cortar las trozas de forma de obtener madera de distintas dimensiones y grados de calidad, con el fin de satisfacer las órdenes de los clientes.

Existen diversas formas de cortar la materia prima para obtener las escuadrías requeridas, sin embargo, es fundamental optimizar el corte con el objetivo de maximizar el rendimiento de la materia prima y el beneficio económico para el aserradero. En este sentido, Faaland y Briggs (1984) plantean que los encargados de programar la producción y los operadores deben tomar complejas decisiones con el fin de determinar la programación de los cortes. El programador no sólo debe considerar los precios de los productos y las características de la materia prima, sino que también las muchas combinaciones potenciales de piezas a producir, al momento de obtener una solución al problema de programación. Los encargados de estas tareas deben además tomar las decisiones rápidamente, en especial cuando las instalaciones están configuradas para una alta producción.

El corte se programa de acuerdo a ciertos esquemas, conocidos como esquemas de corte, establecidos según consideraciones de rendimiento y valor, características de la materia prima, limitaciones de equipos y el proceso. Entonces, es fundamental en la programación de la producción de un aserradero, conocer los esquemas de corte a usar, dada la materia prima disponible, y con el fin de satisfacer un determinado pedido.

2.2.1 Calidad de la madera obtenida a partir de una troza

Dependiendo de la zona del rollizo de la cual se obtienen las escuadrías se pueden distinguir:

- Madera lateral: Estas piezas son obtenidas de la periferia del trozo y se caracterizan por ser maderas prácticamente libres de nudos y otros defectos. Por lo tanto, tiene un alto

valor económico y está orientada a la industria de remanufactura. Puede ser obtenida en el corte primario y secundario.

- Madera semi lateral: También orientada a la industria de remanufactura, presenta mayor cantidad de nudos y defectos que deben ser eliminados, por lo que su rendimiento en remanufactura es menor.
- Madera Central: Obtenida de la parte central del trozo. Se caracteriza por presentar gran cantidad de nudos y principalmente por la presencia de médula. Frecuentemente es usada en la industria de la construcción.

2.2.2 Rendimiento de materia prima

Según Oja et al. (2003), la operación exitosa de un aserradero depende de la capacidad de lograr la mayor recuperación de valor posible a partir de la materia prima. Esto se puede lograr, por ejemplo, optimizando la utilización de ésta.

En muchos casos, el costo de materia prima corresponde a 50% - 75% del costo del producto aserrado. Por lo tanto, el rendimiento de la materia prima es un factor importante en la rentabilidad de un aserradero. Una medida para medir el rendimiento de la materia prima es el volumen de madera producida (cortada), dividido por el volumen total de troncos utilizados. Lewis (1985) plantea que se puede lograr un incremento en el rendimiento de la materia prima principalmente a través de dos formas: Aplicando tecnología a los procesos (por ejemplo, tener máquinas con mayor precisión), y mediante el desarrollo de sistemas que ayuden a los operadores a tomar mejores decisiones.

El rendimiento de materia prima puede ser influenciado por distintos factores, los que se pueden clasificar en tres tipos:

- Factores que dependen de los trozos (materia prima).
- Factores que dependen de los productos a obtener.

- Factores que dependen del proceso de corte.

2.2.2.1 Factores que dependen de la materia prima

Además de clasificarse de acuerdo a sus dimensiones, la materia prima puede ser ordenada con respecto a su calidad. Oja et al. (2003) plantean que el conocimiento de las características de los trozos es de gran ayuda para un mejor aprovechamiento de la materia prima. Algunos factores dependientes de la materia prima que influyen en el rendimiento de la misma son:

- **Diámetro.** El rendimiento de la materia prima aumenta a mayor diámetro del trozo.
- **Largo.** En general, el rendimiento de materia prima decrece a medida que la longitud del tronco aumenta. Esto se explica debido a la conicidad del trozo, es decir, los diámetros de los extremos de rollizo no son iguales, por lo que no permite obtener productos laterales y conseguir un rendimiento idéntico que en largos más cortos.
- **Conicidad.** Se refiere a que los diámetros de los extremos del rollizo no son iguales. En general, a medida que la conicidad aumenta, el rendimiento disminuye.
- **Curvatura.** La rectitud el rollizo es una característica deseable. A pesar de que se han logrado avances en la genética de los árboles, éstos inevitablemente presentarán cierta curvatura, debido a factores ambientales, genéticos o patógenos. Por estas razones es que el trozo puede presentar curvatura en sus extremos, respecto al eje longitudinal. Este defecto no es común, pero se presenta con mayor frecuencia en rollizos de diámetros mayores. Tiene un efecto directo en el rendimiento, ya que no es posible aprovechar la madera en las curvas para obtener productos. Además del menor rendimiento, una mayor proporción de la madera obtenida es de baja calidad. Cown et al. (1984) estudiaron el efecto de la curvatura de los rollizos en el rendimiento de la materia prima.
- **Deformaciones.** Obligan a sacrificar el volumen producido. Entre las deformaciones más comunes se pueden mencionar las protuberancias, que corresponden a irregularidades en la superficie del trozo y surgen como consecuencia de podas tardías o

mal realizadas. Estas protuberancias pueden ser sólo superficiales, o puede tratarse de nudos ocultos.

Los defectos de forma pueden afectar el buen posicionamiento del tronco en ciertas máquinas, y traer como consecuencia piezas con canto muerto.

Se ha mencionado la importancia que tiene el conocer las características de la materia prima con que se cuenta. Diversos estudios se han realizado con el fin de intentar predecir las características de los rollizos. Entre éstos, se pueden mencionar a Oja et al. (2003), quienes intentan determinar la precisión de un sistema de clasificación automático de rollizos, el cual utiliza un scanner de rayos X. Lundgren (2000) desarrolla un modelo que intenta predecir las características de la materia prima a partir de información proporcionada por un scanner 3D, el cual puede ser utilizado como apoyo para la optimización de madera aserrada. Sería una ventaja adicional el conocer también las características internas de la materia prima, ya que los defectos internos son usualmente visibles después de los cortes primarios (Todoroki y Rönnqvist, 2002). Es así como Rinnhofer et al. (2003) utilizan un scanner CT para detectar defectos internos en los trozos, con el fin de desarrollar un sistema que ayude a los operadores a tomar mejores decisiones respecto a la utilización de la materia prima, variando parámetros como posicionamiento de las sierras, y distintos programas de corte.

2.2.2.2 Factores que dependen de los productos.

- *Largo.* Dada la forma del tronco (conicidad, curvatura, y otros defectos), es difícil generar un patrón de corte para productos de largo mayor.
- *Sobre dimensionamiento de las piezas.* La madera, al momento de ser cortada, tiene un cierto grado de humedad. Al ser secada, este grado de humedad disminuye, lo que trae como consecuencia la disminución de su volumen. El sobredimensionamiento permite compensar los errores de corte debidos a la falta de precisión y por otra parte a la contracción de secado que sufre el producto. Sin embargo, incide negativamente en el aprovechamiento de materia prima, costo que es asumido por el aserradero y no por el cliente, el cual paga por las dimensiones originales de la pieza. Maness y Lin (1995)

plantean que una forma de lograr un mayor aprovechamiento de la materia prima sería disminuir el sobredimensionamiento requerido para las piezas a cortar.

- *Calidad.* Las escuadrías son asociadas a una cierta calidad, es decir, a ciertas características que debe poseer la madera. Entonces, ciertas escuadrías deben ser obtenidas desde zona específicas del rollizo, lo que no ayuda al aprovechamiento de la materia prima. Puede ocurrir también que la materia prima no sea la adecuada para satisfacer determinadas órdenes (por ejemplo, puede ocurrir que la materia prima sea de alta calidad, y se requiera obtener productos de calidad baja, o viceversa). Esta situación no ayuda ni al aprovechamiento de la materia prima, ni a la maximización de las utilidades (Todoroki y Rönnqvist, 2002).

2.2.2.3 Factores relacionados con el proceso de corte

Este punto se refiere a las condiciones generales de la maquinaria y equipamiento disponible. Se debe conocer el flujo de la línea de producción, el grado de automatización y el nivel de mantenimiento de las máquinas, además de sus características y capacidades, ya que éstas limitan la altura y anchos máximos de corte, así como diámetros de troza máximos factibles de procesar y el número de cortes por pasada. Según Todoroki y Rönnqvist (1997), el valor potencial que se puede obtener a partir de la materia prima depende no sólo de ésta, sino también de las características de las máquinas con que cuenta la instalación. En este sentido influyen factores como:

- *Tipo de aserradero.* La incorporación de nueva tecnología a los procesos ha contribuido en gran medida a mejorar el rendimiento de materia prima.
Otro punto a considerar es la relación entre el tipo de aserradero y la materia prima utilizada.
- *Optimización del patrón de corte.* Se refiere a la forma en que se asignan los esquemas de corte y los criterios de optimización que se utilizan. Ésta puede ser realizada manualmente, apelando a la experiencia del operador, o bien con la ayuda de algún programa computacional.

No sólo es importante la optimización durante la etapa de corte principal, también es fundamental en etapas posteriores (cortes secundarios). Teniendo esto en mente, Todoroki y Rönnqvist (2002) desarrollan una solución orientada a optimizar en volumen la etapa de corte primario, y los cortes secundarios son optimizados con el objetivo de maximizar el valor de las piezas obtenidas.

- *Ingreso del rollizo a las sierras.* El caso ideal es que las trozas ingresen en forma perpendicular, sin embargo, en general éstos ingresan con cierto ángulo de desviación a las máquinas. También es importante cuál extremo del rollizo ingresa primero, siendo recomendable que éstos ingresen por el extremo de diámetro menor.
- *Espesor de corte.* A medida que aumenta el espesor de la sierra, se produce mayor aserrín, lo que se traduce en un menor aprovechamiento de la materia prima. Por lo tanto, el reducir el espesor de corte puede ayudar a aumentar la eficiencia en la utilización de la materia prima (Maness y Lin, 1995). Sin embargo, si se disminuye el espesor de corte, también disminuye la precisión de éste, y por tanto es necesario aumentar el espesor del producto a cortar, es decir, existe un compromiso en el cual, a menor espesor de corte, se requiere de un mayor sobredimensionamiento. Entonces, el aumento del rendimiento de materia prima mediante disminución de los espesores de corte puede ser perjudicial.

Según Maness y Lin (1995), existen esencialmente cinco cambios en las estrategias de aserrío que pueden influenciar tanto un aumento en el valor y en el rendimiento como resultado de una reducción en el espesor de corte (además de reducción en el sobredimensionamiento).

1. Aumento del número de piezas: En ciertos casos, es posible agregar piezas adicionales a un determinado patrón de corte, como consecuencia de una reducción en el espesor de corte.
2. Aumento del largo de las piezas en un determinado patrón de corte.
3. Aumento del ancho de las piezas incluida en un determinado patrón de corte.
4. Cambios en los esquemas de corte: Se refiere a que los patrones de corte pueden ser re- optimizados, con el objetivo de aumentar la eficiencia en la utilización de la materia prima o aumentar las utilidades para el aserradero.

5. Cambios globales en las estrategias de producción: Una reducción en el espesor de corte y en el sobredimensionamiento pueden llevar a una reformulación completa de las estrategias de producción al interior de un aserradero.
- *Calidad superficial del corte.* Si es de baja calidad, se debe cepillar o reprocesar las piezas. En este punto influye la vibración de las sierras, lo cual provoca que las maderas no se corten limpiamente y que las escuadrías presenten irregularidades en su superficie.
 - *Calibrado de sierras.* Un calibrado deficiente puede conducir a obtener madera defectuosa en cuanto a forma y dimensiones.

2.2.3 Beneficio Económico

Un aspecto que tiene gran relevancia como la maximización del rendimiento de la materia prima, es el beneficio económico para el aserradero por efectos de cumplir con cierto pedido. En otras palabras, maximizar el valor de los productos obtenidos. Esto puede muchas veces llevar a sacrificar el rendimiento de materia prima, pero aumentar el margen de utilidad del aserradero (Todoroki y Rönnqvist, 2002).

CAPÍTULO 3. MARCO TEÓRICO

En este capítulo se comienza presentando una revisión de la literatura reciente relacionada con el problema de corte de piezas a partir de materias, mencionando los distintos enfoques de modelamiento y técnicas de solución. Posteriormente se presenta una revisión de trabajos relacionados con la optimización de la producción de madera aserrada.

3.1 El Problema de corte de piezas a partir de materias primas

El problema de corte de piezas, es conocido en la literatura como “Cutting Stock Problem” (CSP). Consiste en determinar cómo debe ser cortado un conjunto de piezas, cuyas formas pueden ser regulares o irregulares, a partir de un conjunto de formas más grandes, las que también pueden ser regulares o irregulares, con el objetivo de maximizar la utilización del material, o lo que es equivalente, minimizar la pérdida de éste. Alternativamente, puede considerarse el objetivo de maximizar el valor total que se obtiene al cortar determinadas piezas. La regularidad o irregularidad tanto de las piezas como de las formas u objetos más grandes está dada por la geometría de éstas. En general, según Hopper y Turton (2001), se entiende por forma regular a aquella que puede ser descrita por pocos parámetros, por ejemplo, rectángulos o circunferencias, mientras que las formas irregulares son aquellas que incluyen asimetrías y concavidades.

Un problema relacionado con el de corte de piezas, es el de empaque, el cual consiste en determinar una distribución eficiente de piezas dentro de una región, forma o espacio, y sin que éstas se superpongan. Diversos autores enfatizan la fuerte relación entre los problemas de corte y empaque, resultante a partir de la dualidad de material y espacio. En este sentido, los problemas de corte pueden ser vistos como utilizar el espacio disponible proporcionado por un gran objeto, empacando ítems más pequeños. Por otra parte, los problemas de empaque pueden ser vistos como cortar objetos grandes en ítems más pequeños.

En los problemas de corte y empaque, se debe tomar decisiones respecto de qué piezas cortar y desde qué ítem más grande cortarlas, generando situaciones altamente

combinatorias. Además, surge un problema de tipo geométrico, el cual se refiere a cómo cortar las piezas (Gomes y Oliveira, 2006).

Estos problemas pueden ser caracterizados principalmente de acuerdo a: Dimensionalidad, definida como el mínimo número de dimensiones relevantes para describir la geometría del sistema; regularidad o irregularidad de las piezas como de las formas o ítems más grandes; el número total, tipo y variedad de piezas, entre otros. A modo de ejemplo, de acuerdo al número de dimensiones relevantes, los problemas de corte y empaque se pueden clasificar en unidimensional, bidimensional o tridimensional.

Dependiendo del problema particular, o de la industria en la que se requiere aplicar, pueden existir distintas restricciones, y distintos objetivos a alcanzar. Sin embargo, en general, se pueden encontrar algunas restricciones comunes:

- Las piezas deben ubicarse dentro de la región o placa;
- No se permite superposición entre las piezas;
- Tipos de cortes factibles de aplicar, por ejemplo, si se permite o no cortes tipo guillotina.

3.2 Aplicaciones

La aplicación de los problemas de corte está presente en numerosas industrias, en particular en aquellas donde se requiere el corte de materias primas en las etapas iniciales del proceso productivo. Algunos ejemplos de aplicación industrial de los problemas de corte y empaque son:

- Corte unidimensional en la industria del Papel;
- Corte rectangular bidimensional en la industria de muebles, textil y vidrio;
- Corte y empaque irregular bidimensional en las industrias de muebles, calzado y confección de vestuario;
- Empaque tridimensional de containers y carga de camiones;
- Etc.

3.3 Problema de corte de piezas regulares

Consiste en cortar un conjunto de piezas rectangulares a partir de una lámina rectangular más grande, con el objetivo de maximizar la utilización del material o el valor total de las piezas cortadas. La figura 3.1 muestra un ejemplo de corte regular ortogonal tipo guillotina, es decir, que cuando se efectúa cada corte se separan al menos dos trozos de material, y un ejemplo de corte regular ortogonal no guillotina. En la figura 3.2 se presenta un layout no ortogonal.




Figura 3.1 Casos layout ortogonal: (a) Layout guillotina; (b) Layout no guillotina. Fuente: Hopper y Turton (2001).




Figura 3.2 Layout no ortogonal. Fuente: Hopper y Turton (2001)

3.4 Problema de corte de piezas irregulares

El problema de corte de piezas irregular se refiere tanto a si las piezas son de forma irregular o si la placa es irregular. En general, comparte las mismas restricciones principales del problema regular, en orden a obtener un layout en el cual las piezas no se superpongan ni salgan de las fronteras de la lámina o placa. En las figuras 3.3 y 3.4 se presentan dos ejemplos de corte de piezas irregular, en el primer caso la placa es regular y en el segundo no.




Figura 3.3. Ejemplo layout caso lámina regular, piezas irregulares. Fuente: Gomes y Oliveira (2006).




Figura 3.4 Ejemplo layout caso lámina irregular, piezas irregulares. Fuente: Anand et al. (1999).

La principal complejidad del problema de corte de piezas irregular es la geometría de las piezas. En este sentido se han desarrollado métodos que permiten tratar la compleja

geometría, aplicando conceptos como el de “no-fit polygon” (Bennell et al., 2001), el cual indica la zona en la que dos polígonos se intersectan, o utilizando un sistema de rejilla o cuadrícula, dada por una matriz binaria, donde los 0 indican puntos donde es factible localizar una pieza y los 1 indican los puntos donde es infactible (Fischer y Dagli, 2004).

3.5 Formulaciones y modelamiento

En este punto hay dos enfoques claros. Una posibilidad es formular el problema como un modelo de Programación Matemática, independiente del método de resolución utilizado, sea éste exacto o heurístico. Otra forma es aplicar lo que se podría definir como “modelamiento heurístico”, para el cual se requiere definir una representación de solución factible y el espacio de solución, y una función de evaluación de la calidad de las soluciones. Este enfoque es apropiado cuando los métodos de solución a ser utilizados son heurísticas de búsqueda local o metaheurísticas.

Dentro de la programación matemática, los enfoques más comúnmente utilizados son los de Programación Lineal Entera y Programación Cuadrática, aunque para esta última, es posible, mediante sustitución de variables, modificar el modelo de forma que resulte uno de Programación Lineal Entera. Estos enfoques son utilizados para variantes específicas de CSP, especialmente para casos de corte unidimensional o bidimensional regular, y/o cuando se conocen claramente las restricciones de corte dadas por las máquinas. Yanasse y Morabito (2006), presentan una serie de modelos (cuadráticos y lineales) para una variante del CSP bidimensional regular guillotina, conocida como “1- group”, que se refiere a que los patrones deben ser factibles de ser cortados en dos etapas, primero a lo largo de la placa (o longitudinalmente), y luego a lo ancho (de manera transversal al largo). Holthaus (2002) aborda el CSP unidimensional con diferentes tipos de largos stock, formulando un modelo de Programación Lineal Entera. Morabito y García (1998) tratan un caso de CSP bidimensional, con orientación fija de las piezas, aplicado a la industria brasileña de tableros, el cual se formula como un problema de Programación Lineal Entera. Belov y

Scheithauer (2006) consideran tanto el CSP unidimensional y bidimensional guillotina “dos-etapas” (otro nombre con que se conoce a la variante 1-group).

3.6 Métodos de resolución para el problema de corte de piezas

El problema de corte de piezas es del tipo NP-completo (Hopper y Turton, 2001). El imponer restricciones adicionales dependiendo de su aplicación particular hace más complejo el problema, por lo que puede considerarse también a sus variantes como NP-completo. Esto quiere decir que para todos los algoritmos actualmente conocidos que encuentran soluciones óptimas de estos problemas, el número de pasos computacionales crece exponencialmente de acuerdo al tamaño de la instancia.

Respecto a los métodos de solución, han sido propuestas varias aproximaciones, dependiendo del tipo y tamaño del problema. Es así como para ciertos problemas e instancias pequeñas se han desarrollado métodos exactos, o sea, capaces de encontrar la solución óptima. Sin embargo, los métodos más ampliamente desarrollados han sido las aproximaciones heurísticas, capaces de encontrar buenas soluciones en un tiempo computacional razonable. Estos métodos heurísticos pueden ser algoritmos desarrollados para un tipo particular de problemas o ser metaheurísticas, que son métodos de tipo general, utilizados para resolver una gran variedad de problemas combinatoriales.

En general, los métodos heurísticos son más apropiados para problemas de corte con características más complicadas (forma de las piezas, rotación permitida para las piezas, tamaño del problema, mayor flexibilidad de los cortes posibles, entre otras), para los cuales no es posible encontrar un modelo matemático apropiado, o si existe, el tiempo computacional que tomaría encontrar la solución óptima es prohibitivo.

3.6.1 Métodos exactos

Se han utilizado métodos exactos principalmente para casos particulares de CSP regular, ya sea unidimensional o bidimensional. Los casos de CSP corresponden en general a problemas de optimización de “gran tamaño”, en que la formulación de Programación Lineal Entera (PLE) (en los casos en que es factible obtenerla) presenta gran cantidad de “columnas” o “filas”. Para estos problemas pueden aplicarse métodos para convertirlos en uno o más problemas de tamaño más manejable (como las técnicas de Dantzig- Wolfe, Benders, o Relajación Lagrangeana). En particular, para problemas de corte, por sus características, es factible aplicar la técnica de descomposición planteada por Dantzig y Wolfe (1960), la cual es un procedimiento sistemático para resolver programas lineales de gran tamaño que contienen restricciones de estructura especial. Las restricciones son divididas en dos conjuntos: restricciones generales (o “complicantes”) y restricciones de estructura especial. La estrategia del procedimiento de descomposición es operar en dos programas lineales separados: uno sobre el conjunto de restricciones generales y otro sobre el conjunto de restricciones especiales. Se intercambia información entre ambos programas lineales hasta que se alcanza un punto donde la solución al problema original es obtenida. El programa lineal sobre las restricciones generales recibe el nombre de “problema maestro”, y el programa lineal sobre las restricciones especiales es llamado “subproblema”. El problema maestro pasa un nuevo conjunto de coeficientes de costo al subproblema y recibe una nueva columna basada en esos coeficientes de costo. Por esta razón es que este procedimiento es conocido además como técnica de “generación de columnas”. Mayor información sobre la técnica de descomposición se puede encontrar en Bazaraa (1990).

Diversos autores han encontrado soluciones para casos particulares de CSP mediante métodos exactos. Yanasse y Morabito (2006), aplican modelos de PLE para casos de CSP bidimensional regular guillotina “1- group”. Los modelos fueron codificados en lenguaje de modelamiento GAMS y resueltos mediante la herramienta CPLEX. Holthaus (2002) considera el CSP unidimensional, en el cual, para los casos en que la materia prima posee

largos iguales, se logra resolver el problema en forma óptima, aplicado métodos de descomposición.

3.6.2 Heurísticas Particulares

Son algoritmos desarrollados para variantes específicas del problema. Algunos de estos métodos son las heurísticas “Bottom- Left”, “Bottom- Left- Fill” y “Best Fit”, descritas en Burke et al. (2004).

- “Bottom Left”

Utilizado principalmente en problemas de corte regular. Se trata de una heurística de ubicación de piezas, la cual, efectuando sucesivos movimientos de deslizamiento, busca el espacio más abajo y a la izquierda donde sea posible ubicar la pieza. La figura 3.5 muestra un ejemplo de este método, en el cual, se tiene una nueva pieza a ubicar en la placa, y comenzando del extremo superior derecho de ésta, va efectuando movimientos hacia abajo y luego a la izquierda, hasta que encuentra una ubicación para la pieza.




Figura 3.5 Ejemplo heurística “bottom left”. Fuente: Burke et al. (2004).

- “Bottom Left Fill”

Corresponde a una versión mejorada de “bottom – left”. En este método se mantiene una lista de puntos ordenados de manera “bottom -left” donde es posible ubicar una pieza. Al momento de ubicar la siguiente pieza, el algoritmo comienza con el punto más a la izquierda y abajo guardado en la lista, y coloca la pieza en ese punto. Se chequea si la pieza se superpone a alguna otra o si sobrepasa los límites de la lámina. Si es factible se deja la pieza en ese punto, si no, se revisa el resto de los puntos de la lista. “Bottom left fill” con

frecuencia entrega mejores “layouts” que “bottom left”, ya que proporciona la posibilidad de aprovechar mejor el espacio de la lámina al permitir cubrir los “agujeros” que usualmente puede dejar “bottom –left”. A modo de ejemplo, la figura 3.6 muestra una comparación entre “bottom – left” y “bottom – left fill” para una situación particular.

Burke et al. (2004) presenta otra heurística particular, denominada “best- fit” (BF) para el problema de “cutting stock” rectangular. (BF) es un procedimiento comparable a métodos como “bottom left” (BL), “bottom left” mejorado y “bottom left fill” (BLF) (estas últimas dos metodologías, se basan en la original “bottom-left”), en el sentido de que son estrategias de ubicación de las piezas en el rectángulo stock. Aunque tienen algunas diferencias, en general, consisten en que en primer lugar se establece una secuencia de las piezas a ubicar. Luego de acuerdo a esa secuencia, se colocan en la placa según un criterio tipo “bottom left”, es decir, se busca el sitio más al fondo y a la izquierda posible en que es factible colocar la siguiente pieza de la secuencia. El método propuesto selecciona dinámicamente (a diferencia de los métodos mencionados anteriormente) el próximo rectángulo a ubicar. Es esencialmente un algoritmo “greedy” que produce empaques de buena calidad.




Figura 3.6 Comparación entre heurísticas “bottom left” (BL) y “bottom left fill” (BLF). Fuente: Burke et al. (2004)

3.6.3 Metaheurísticas

Dentro de este grupo, los métodos más comúnmente utilizados en problemas de corte son Algoritmos Genéticos (Anand et al., 1999; Parada et al., 2002), Simulated Annealing (Gomes y Oliveira, 2006) y Tabu Search (Álvarez- Valdés et al. 2002). Una característica común en estas técnicas es la importancia que tiene una adecuada representación de una solución factible. Es así como en la literatura se pueden encontrar diversas formas de representación, dependiendo del tipo de problema de corte, por ejemplo, para el corte regular guillotina en Parada et al. (1998), se utiliza una representación de árbol binario para un patrón de corte factible.

Otro enfoque para la utilización de metaheurísticas es mediante la interacción con algoritmos constructores, capaces de construir soluciones factibles del problema, las que son codificadas según la representación de solución elegida y de esta forma la metaheurística manipula estas soluciones. Este enfoque de función constructora es utilizado por Fischer y Dagli (2004), para un problema de corte irregular, aplicando un algoritmo de ubicación para las piezas, y la solución obtenida es codificada en dos arreglos, el primero de ellos guarda el orden en que las piezas son ubicadas, y el segundo la rotación de éstas, los que luego son manipulados por una implementación de Algoritmos Genéticos. En Burke et al. (2004), para el caso de corte regular se efectúan pruebas en las que se usa como algoritmo constructor la heurística “bottom left fill”, y las soluciones codificadas, consistentes en la secuencia de ubicación de las piezas, son manipuladas por Algoritmos Genéticos o Simulated Annealing.

Una ventaja que se puede mencionar respecto al uso de metaheurísticas es que muchas veces no es posible obtener un modelo matemático para un determinado problema, como ocurre en el caso del corte de piezas irregulares (convexas y no convexas). Anand et al. (1999) presentan una aproximación a través de Algoritmos Genéticos para la resolución del problema de corte irregular no convexo.

Otra característica importante de estos métodos, es que son capaces de encontrar buenas soluciones en tiempos razonables. Bean (2000) propone una solución para un tipo de problema de corte unidimensional, aplicado en una empresa fabricante de cables para distintos usos, en la cual se debe definir cómo cortar los rollos de cable que se tienen en stock, con el objetivo de minimizar el valor de la pérdida de cable y los costos de “setup” de las máquinas de corte, satisfaciendo a su vez los pedidos de los clientes (restricciones de demanda). Para ello se desarrolló un modelo matemático, y se compararon sus resultados con una implementación de Algoritmos Genéticos. Respecto a los resultados computacionales, el modelo matemático entrega soluciones óptimas, a diferencia del algoritmo genético, que si bien no asegura la optimalidad, obtiene buenas soluciones en un 3% promedio de tiempo computacional respecto al método exacto.

3.6.4 Métodos Híbridos

Dentro de esta categoría se pueden mencionar los métodos híbridos, los cuales combinan el uso de metaheurísticas con técnicas de optimización como programación matemática. Gomes y Oliveira (2006) presentan un algoritmo híbrido para resolver el problema de “strip packing” irregular, perteneciente a los problemas de corte y empaque, donde las placas se consideran como rectángulos de largo infinito, siendo el objetivo minimizar el largo del “layout”. Este problema corresponde a una aplicación pensada para la industria de vestuario. Específicamente se usa Simulated Annealing para guiar la búsqueda en el espacio de solución, y programación lineal para generar vecindades durante el proceso de búsqueda.

Existen casos en donde se utiliza un enfoque heurístico para encontrar soluciones a un problema de corte, que ha sido posible formularlo mediante Programación Matemática. Beasley (2004) propone una solución para el problema de corte de piezas regular bidimensional restringido, con el objetivo de maximizar el valor total de las piezas cortadas. En este artículo, se realiza una formulación de tipo programación no lineal y el método de solución corresponde a una “heurística basada en poblaciones”, la cual trabaja

con una población de soluciones y las combina para generar nuevas soluciones. Holthaus (2002) considera el CSP unidimensional con diferentes tipos de largos stock, para el cual se formula un modelo de Programación Lineal Entera, el cual es resuelto en forma heurística basándose en métodos de descomposición para resolver el problema relajado de Programación Lineal.

3.7 Optimización del corte de rollizos

En la industria forestal se han aplicado modelos de optimización desde hace varias décadas. La naturaleza de estos problemas ha evolucionado, tanto en diversidad como en su complejidad. Rönnqvist (2003) efectúa una amplia revisión acerca de optimización en las distintas áreas del sector forestal, tales como planificación de cosecha, trozado de árboles, planificación de la producción en las distintas industrias, diseño de rutas para camiones, planificación operativa en la industria del aserrío, entre otras.

La optimización de los esquemas de corte para la industria del aserrío, ha sido abordada en la literatura principalmente a través de dos enfoques: Por medio del desarrollo de modelos de optimización, los cuales tienen el objetivo de maximizar la producción tanto en rendimiento como en valor, y mediante la utilización de herramientas de simulación, las que permiten estimar la producción obtenida bajo distintos escenarios.

3.7.1 Desarrollo de modelos de optimización

Dependiendo de las características particulares del problema considerado, los modelos de optimización desarrollados pueden o no incluir la etapa de trozado de árboles. Las técnicas de solución utilizadas principalmente corresponden a algoritmos basados en programación dinámica, métodos de descomposición y técnicas de ramificación y acotamiento (branch and bound).

Faaland y Briggs (1984) desarrollan un modelo de optimización para el problema de trozado de árboles y el aserrío de rollizos de forma conjunta. Se plantea que los procesos de trozado y aserrado están interrelacionados, ya que se debe considerar el proceso de aserrado para decidir la combinación de trozos a obtener. El método de solución está basado en Programación Dinámica. El modelo asume una perspectiva bidimensional del árbol, proporcionada por un scanner, y secciones circulares para éste. Además, el valor asignado a un rollizo es el máximo valor de todas las piezas cortadas a partir del cilindro más largo que puede ser inscrito en el rollizo. Los esquemas de corte utilizados son del tipo “live-sawing”, que se muestran en la figura 3.7.




Figura 3.7 Algunos tipos de Patrones de corte genéricos. Fuente: Todoroki y Rönnqvist (2002).

Geerts (1984) presenta una solución matemática para un problema de corte bidimensional en un espacio irregular, aplicable a la industria del aserrío. Para optimizar el corte primario del rollizo, se usa un algoritmo de programación dinámica unidimensional, con el objetivo de maximizar el valor de las piezas obtenidas en esta etapa, siendo éste el primer nivel de optimización. La optimización del corte de las piezas obtenidas durante el aserrío primario en productos finales, forma un segundo nivel de optimización. La salida de este nivel es usada como la variable a ser optimizada en el primer nivel.

Reinders y Hendriks (1989) proponen un algoritmo desarrollado para optimizar la conversión de árboles en madera. Se basa en sub- algoritmos de programación dinámica anidada. El criterio de selección del patrón de corte es la maximización del valor de la madera obtenida basándose en una lista de precios y dimensiones de los productos a ser aserrados. El problema general de convertir troncos de árboles en tablas de madera es tratado como un problema de “knapsack” tridimensional. Se efectúa una descomposición del problema en tres niveles. El primer nivel consiste en encontrar posiciones para cortar el árbol en un determinado número de trozas o rollizos. En el segundo nivel, los trozos son cortados en piezas más pequeñas mediante cortes longitudinales. En el tercer nivel estas piezas son cortadas definiendo un problema de “knapsack” unidimensional. Para resolver este problema de corte de piezas de tres niveles, se usa un modelo compuesto por tres rutinas de programación dinámica anidadas, que interactúan entre sí mediante su función de evaluación y las decisiones que deben ser tomadas en las distintas etapas.

Maness y Adams (1991) desarrollan un modelo que aborda el problema de trozado y aserrío de forma integrada. Consiste en una solución para la planificación operativa (programación) de la producción que permita a un aserradero común maximizar sus utilidades, considerando su tecnología y características de proceso, información de mercado y materia prima disponible. Para esto se confeccionan tres modelos individuales: Un optimizador de patrones de corte, un modelo para encontrar la política de trozado óptima y un modelo de asignación de trozos, que consiste en un programa lineal, el cual actúa como problema maestro, cuyo propósito es distribuir materiales a varias estaciones de manufactura, y seleccionar las estrategias apropiadas de trozado y aserrado para maximizar los objetivos de la administración, basándose en la información proporcionada por los dos modelos anteriores, y sujeto a restricciones relacionadas con el sistema productivo y el mercado.

Haberl et al. (1991) formulan un modelo de programación matemática para la optimización de las utilidades obtenidas por la producción de madera aserrada, considerando los rechazos esperados de productos, debido al no cumplimiento de los requerimientos de calidad, y los costos de setup, al cambiar de un tipo de rollizo a otro.

El problema específico que se resuelve en este artículo, consiste en determinar el número de rollizos de cada tipo que se deben cortar para cumplir con la orden de producción, suponiendo conocidos los mejores esquemas de corte para cada tipo de rollizo, de acuerdo a las piezas que se requiere obtener. Para encontrar buenas soluciones se propone un algoritmo basado en “branch and bound”.

La aplicación de este método en un aserradero, implica que se deben determinar previamente los mejores esquemas de corte para cada tipo de rollizo, mediante un procedimiento de programación dinámica.

Todoroki y Rönnqvist (1999) tratan el problema de optimización de cortes primarios y secundarios, para lo cual desarrollan una formulación basada en Programación Dinámica, con el objetivo de maximizar ya sea el valor total de los productos obtenidos, o la recuperación de volumen (rendimiento de la materia prima). Se asume que los esquemas de corte permitidos son del tipo “live- sawing”, lo cual favorece la aplicación de programación dinámica.

Todoroki y Rönnqvist (2002) Describen un sistema orientado a la optimización tanto en volumen como en valor de la obtención de productos finales en un aserradero. En otras palabras, la atención está centrada en los cortes secundarios. El aserrío primario es simulado mediante el software AUTOSAW (Todoroki, 1990), que es también donde se implementa el modelo para la obtención de productos finales.

3.7.2 Aplicación de herramientas de simulación

Se han implementado programas computacionales capaces de simular, en forma automática o interactiva, la producción en un aserradero, cambiando diversos parámetros, como espesores de corte, esquemas permitidos, características de la materia prima, entre otros. Lewis (1985) desarrolla una herramienta llamada “Best Opening Face System” (BOF), la cual puede ser utilizada para la evaluación de desempeño potencial, en áreas como gestión

de la producción, diseño de instalaciones y maquinaria, con el objetivo de maximizar la producción ya sea en valor o en volumen.

Todoroki (1990) describe el sistema AUTOSAW, para simulación del proceso de aserrío, el cual está compuesto de tres subprogramas: AUTOSET, que permite la creación y/o modificación de archivos que contienen las especificaciones para la estrategia de aserrío; AUTOSAW, que puede ser usado ya sea para simulaciones de aserrado automáticas, las que se realizan en base a parámetros establecidos, o bien de forma interactiva, en que el usuario cambia las condiciones de simulación a voluntad; finalmente, SAWNOUT, permite analizar los resultados de las simulaciones de aserrío.

3.7.3 Consideraciones respecto al caso particular

Como se ha mencionado, existen varios estudios cuyo propósito es optimizar, ya sea en valor o en volumen, la producción de madera aserrada. Sin embargo, y como lo plantea Rönnqvist (2003), las características del sector forestal difieren de un país a otro (tamaño y número de empresas involucradas, acceso y características de la materia prima, tecnología utilizada, entre otras). En este sentido, las soluciones a problemas de optimización en el sector forestal para un país responden a requerimientos específicos, no siendo necesariamente aplicables directamente en situaciones similares en otros países. Este es el caso de la industria del aserrío. Los estudios encontrados en la literatura se enfocan en situaciones con características muy específicas, distintas a la realidad local. Entre las principales diferencias están los tipos de esquemas de corte permitidos, control de la cantidad producida y el grado de integración entre los procesos de trozado y aserrío.

- Tipos de esquemas de corte permitidos:

En estudios como el de Faaland y Briggs (1984), y Todoroki y Rönnqvist (1999), se asume que los esquemas de corte permitidos son del tipo “live- sawing”. En Chile, son utilizados

generalmente esquemas del tipo “cant- sawing”, los que en general son utilizados en aserraderos con una alta tasa de producción (Todoroki y Rönnqvist, 2002).

- Control de la cantidad producida:

En la mayoría de los artículos revisados no se considera explícitamente la cantidad demandada de los distintos productos durante el horizonte de programación. En trabajos como los de Reinders y Hendriks (1989) y Todoroki y Rönnqvist (1999), el objetivo es maximizar el volumen o valor de la producción en base a una lista de precios de los distintos productos, considerando la disponibilidad y características de la materia prima. En Maness y Adams (1991), la cantidad producida se controla en base a relaciones entre el precio y el volumen máximo esperado a vender a ese precio, para los distintos productos.

Respecto al caso chileno, en general, al momento de programar la producción, se conoce con certeza el volumen y tipo de productos requeridos, por lo que esta información es utilizada directamente.

- Integración con otros procesos:

Este punto se refiere a que, debido a características específicas del problema considerado, se requiere integrar la optimización del trozado de árboles, ya que en algunos casos, los árboles (sin ramas) son trasladados a aserraderos, donde se cuenta con equipamiento especializado para el trozado. Tal es el caso de los estudios de Faaland y Briggs (1984), Reinders y Hendriks (1989) y Maness y Adams (1991). Se tiene que, en la industria del aserrío chilena en general, la materia prima llega previamente trozada, en rollizos de diferentes dimensiones y calidad.

CAPÍTULO 4. PROPUESTA DE SOLUCIÓN

4.1 Definición del problema

Como ya se ha mencionado, dentro de la programación de la producción en un aserradero, uno de los aspectos más importantes consiste en definir cómo se cortarán los rollizos disponibles, es decir, determinar un programa de corte a fin de satisfacer el conjunto de pedidos del aserradero, minimizando la pérdida de materia prima, lo que se traduce en importantes ahorros en costo. Específicamente, el problema tratado en este estudio, esquematizado en la figura 4.1, consiste en determinar un conjunto de esquemas de corte, de forma de obtener las piezas que satisfagan los pedidos (demanda), con el objetivo, en este caso, de maximizar la utilización de la materia prima disponible (rollizos).

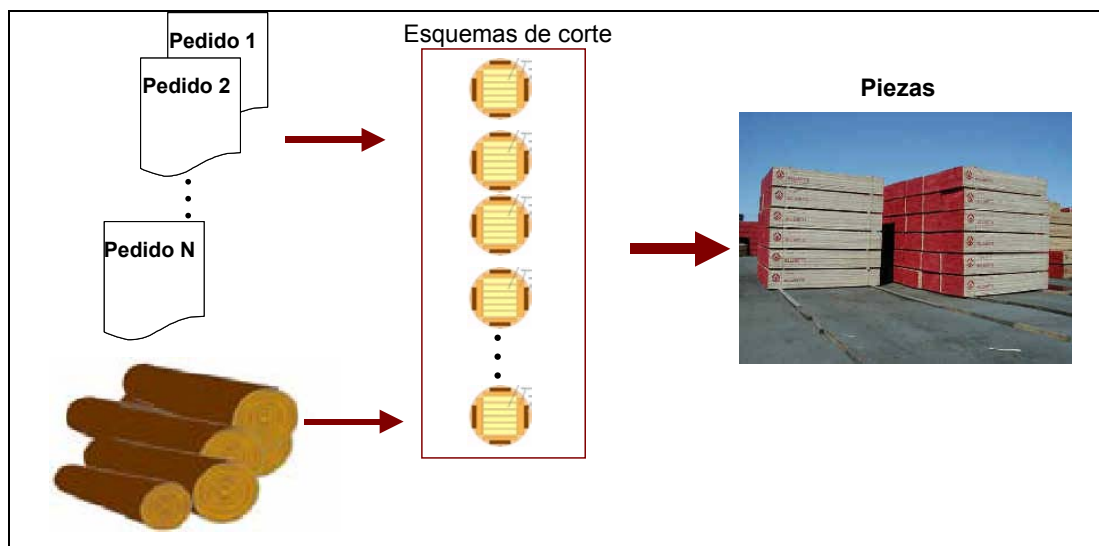


Figura 4.1 Representación proceso de programación de esquemas de corte.

El corte de rollizos en un aserradero puede ser tratado como una particularización del problema de corte de piezas. Entre sus características específicas, se tienen las siguientes:

- Existe alta heterogeneidad de la materia prima disponible (presencia de defectos como protuberancias, nudos, etc.).

- Dado que los productos tienen asociados un grado de calidad, éstos deben ser obtenidos desde zonas específicas del rollizo. En general, las piezas con mayor valor comercial se extraen de la zona periférica del rollizo, que es de donde se obtiene madera de mejor calidad. Por lo tanto, además de maximizar la utilización de materia prima, se debe también considerar, incluso priorizar, la maximización de la utilidad o beneficio económico.
- Las piezas a obtener presentan distintos valores económicos.
- Se debe respetar el proceso particular de corte de cada aserradero (dada la tecnología) en particular, sin embargo, en general la programación del corte debe ser tipo guillotina.
- Los rollizos, debido a su naturaleza, no presentan diámetros iguales, por lo que debe efectuarse una clasificación de acuerdo a su diámetro.

Los modelos teóricos revisados para diversos problemas de corte, presentados en el capítulo 3, no son aplicables directamente a este problema, dado que, en general, respecto a la geometría que manejan, o son demasiado simplificados, como es el caso del corte de piezas regulares, o demasiado complejos, como los casos de corte irregular, en que se utilizan herramientas de geometría computacional para trabajar con las complejas formas (figuras poligonales cóncavas y convexas) tanto de la lámina como de las piezas. Por otra parte, para el caso de corte regular e irregular, el problema que se resuelve en la mayoría de los trabajos científicos consiste en encontrar un único “layout”, es decir, encontrar una buena distribución de las piezas (decidir qué piezas ubicar del conjunto disponible) para una sola lámina disponible. En el caso particular del corte de rollizos, el problema consiste en encontrar un conjunto de “layouts”, o esquemas de corte, que permitan satisfacer los pedidos, con el objetivo de minimizar la pérdida de materia prima. En el caso de los estudios que desarrollan soluciones al problema de optimización de la producción de

madera aserrada, se trata de propuestas de solución para casos específicos, no siendo aplicables directamente al problema particular.

Para abordar este problema se han establecido una serie de supuestos respecto de: los rollizos, la generación de esquemas de corte y las escuadrías o productos a obtener. Estos supuestos se presentan a continuación.

Respecto de los rollizos:

- Se considera el diámetro menor del rollizo, tanto para su clasificación, como para la generación de esquemas de corte. El área de la sección transversal se considera la de una circunferencia.
- No se consideran defectos como protuberancias, deformaciones, curvaturas etc.

Relativo a las escuadrías:

- Se clasifican en laterales y centrales, dependiendo de la zona donde se deben obtener, dado el grado de calidad requerido.

Relativo a los esquemas de corte:

- Las piezas a obtener se clasifican en laterales y centrales. El esquema de corte a obtener se asemeja al presentado en la figura 4.2, es decir, una base central, compuesta por un conjunto de piezas centrales iguales, y una zona periférica, en donde se ubican las piezas laterales.
- Los cortes son tipo guillotina.
- Se debe establecer un máximo de piezas laterales a obtener por zona del rollizo (Lateral izquierda, lateral derecha, superior e inferior) y un máximo y mínimo de piezas centrales a obtener de un rollizo. El número de piezas que se puede obtener desde un rollizo depende de las características de éste, así como de las máquinas y del sistema productivo del aserradero en particular.

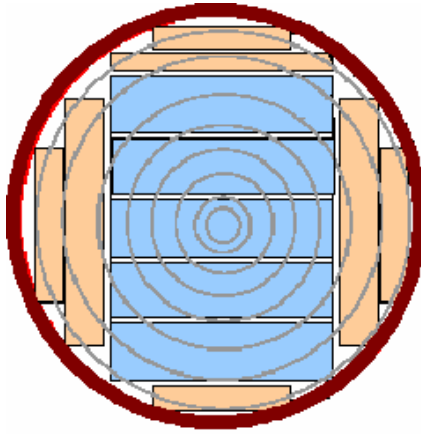


Figura 4.2 Representación de un esquema de corte.

4.2 Caracterización del problema

El problema puede ser representado de la siguiente forma:

Se tiene un conjunto de piezas (escuadrías) E , que deben ser obtenidas a partir de un conjunto de Rollizos R . Además, el conjunto E está compuesto por dos subconjuntos:

L_E : Conjunto de piezas laterales, es decir, $L_E \subset E$.

C_E : Conjunto de piezas centrales, es decir, $C_E \subset E$.

$$E = L_E \cup C_E.$$

Algunos parámetros identificados para los elementos de E son:

- Ancho, medido en centímetros.
- Espesor, medido en centímetros.
- Largo, medido en metros.
- Volumen geométrico, medido en metros cúbicos.
- Centro de Área transversal de escuadría (CA_x, CA_y) , considerando coordenadas cartesianas, con el vértice inferior izquierdo en el punto $(0,0)$.

En la figura 4.3 se presenta un esquema para los parámetros de los elementos del conjunto E .




Figura 4.3 Parámetros para las escuadrías.

Los parámetros identificados para el conjunto R son los siguientes:

- Diámetro menor de rollizo, medido en centímetros.
- Largo.
- Volumen (JAS), para rollizos cuyo largo es menor a 6 metros, se calcula de acuerdo a la expresión (4.1):

$$V = \frac{D^2 L}{10.000} [m^3] \quad (4.1)$$

Donde:

D : Diámetro, en centímetros.

L : Largo, en metros.

- Centro de la circunferencia dada por el diámetro menor del rollizo, considerando coordenadas cartesianas, con un punto de la circunferencia ubicado en el eje x y otro ubicado en el eje y .

En la figura 4.4 se presenta un esquema con los parámetros para los elementos de R .




Figura 4.4 Parámetros para los rollizos.

4.3 Solución propuesta

Se propone abordar este problema, dada su complejidad, mediante el uso de metaheurísticas, en particular, Simulated Annealing y Algoritmos Genéticos, con el objetivo de probar el desempeño de ambos métodos en este problema. Se deciden utilizar estas metaheurísticas, debido a que en la literatura revisada han sido aplicadas con buenos resultados en problemas de corte (Anand et al., 1999; Parada et al., 1998, entre otros).

En general, al aplicar metaheurísticas, existen dos puntos importantes a definir previamente: La forma en que se representarán las soluciones del problema, y la función de evaluación que se utilizará para evaluar la calidad de estas soluciones. Es recomendable que la representación de la solución incluya sólo la información necesaria que represente su calidad. Ambas metaheurísticas utilizan una representación de solución particular. Respecto

a la función de evaluación, ésta debe ser definida para que evalúe la calidad de las soluciones según criterios de eficiencia, dado que el objetivo es maximizar la utilización de la materia prima.

4.4 Generación de soluciones

Para generar soluciones factibles se utiliza un método que se puede denominar como función constructora, que es un algoritmo capaz de generar soluciones factibles para el problema, a partir de un conjunto de datos de entrada. Estas soluciones son codificadas según la representación de la solución previamente definida y su calidad es medida de acuerdo al valor de la función de evaluación asociado. La metaheurística, ya sea Simulated Annealing o Algoritmos Genéticos, utiliza la solución codificada y el valor de la función objetivo como información según el funcionamiento particular de cada una.

Para este problema en particular, la función constructora diseñada, a partir de la información de los pedidos, correspondiente a los productos que se requiere obtener, y del stock de rollizos, es capaz de generar un conjunto de esquemas de corte que permita cumplir con la demanda. Con la información de los pedidos, asigna piezas a rollizos seleccionados de forma factible, como se esquematiza en la figura 4.5.




Figura 4.5 Esquema función constructora.

Previo a la utilización de la función constructora, los elementos de los subconjuntos C_E y L_E se ordenan de acuerdo a su ancho, luego por espesor, y finalmente por largo. Por su parte, los elementos de R se ordenan de acuerdo a diámetro y luego a su largo.

La función constructora desarrollada genera cada esquema de corte en dos etapas:

- Construcción zona central. Esta etapa consiste en ubicar las piezas centrales que irán en el esquema.
- Construcción zona lateral. A partir de zona central construida, se agregan las piezas laterales.

Este procedimiento se repite hasta que se hayan construido los esquemas necesarios, o se determine de que, dados los datos proporcionados, no es posible construir una solución factible.

- **Construcción zona central**

Para la construcción de una zona central (ver figura 4.6), en primer lugar se realiza una estimación acerca de las piezas centrales que en promedio debieran ser ubicadas (sin considerar su tipo) en los rollizos disponibles, n , dada por la expresión (4.2):

$$n = \left\lceil \frac{n^{\circ} \text{ total piezas centrales}}{n^{\circ} \text{ total rollizos disponibles}} \right\rceil \quad (4.2)$$

Posteriormente se selecciona el tipo de rollizo de mayor diámetro disponible, y el tipo de pieza central de mayor ancho que sea posible ubicar en ese rollizo. Luego se establece el número de piezas centrales iguales a ubicar en la base, tomando en consideración las alturas máxima (h_{\max}) y mínima (h_{\min}), representadas en la figura 4.7, para la zona central, definidas por las expresiones (4.3) y (4.4), respectivamente:

$$h_{\max} = \sqrt{(d_{\text{rollizo}})^2 - (\text{ancho}_{\text{pieza}})^2} \quad (4.3)$$

$$h_{\min} = 0,4 \cdot d_{\text{rollizo}} \quad (4.4)$$

Donde:

d_{rollizo} : Diámetro rollizo seleccionado.

$\text{ancho}_{\text{pieza}}$: Ancho del tipo de pieza central seleccionada.

Se determina h , que corresponde a la altura de la zona central que se pretende ubicar en el rollizo, dada por la expresión (4.5):

$$h = n \cdot \text{espesor}_{\text{central}} + (n + 1) \cdot EC \quad (4.5)$$

Donde:

$\text{espesor}_{\text{central}}$: Espesor del tipo de pieza central seleccionada.

EC : Espesor de corte.

Si $h_{\min} < h < h_{\max}$, entonces se ubican n piezas centrales del tipo seleccionado en la zona central. En otro caso, se asignan n_{\min} piezas a la zona central, dado por la expresión (4.6):

$$n_{\min} = \left\lceil \frac{h_{\min}}{\text{espesor}_{\text{central}}} \right\rceil \quad (4.6)$$




Figura 4.6. Construcción zona central.




Figura 4.7. Construcción zona central.

- **Construcción zona lateral**

Para construir una zona lateral, ésta se subdivide en cuatro zonas: superior, inferior, izquierda y derecha. Esta división se muestra gráficamente en la figura 4.8.




Figura 4.8 Subdivisión zona lateral.

En primer lugar se construye la zona superior, agregando piezas laterales disponibles seleccionadas de acuerdo a su ancho, hasta completar el máximo de laterales permitidos por zona (definido previamente), o mientras no se viole la restricción de frontera, dada por la expresión (4.7), descrita en la figura 4.9, lo que significa que la nueva escuadría a ubicar no debe sobrepasar los límites de la circunferencia dada por el diámetro menor del rollizo. El mismo procedimiento se efectúa para las zonas inferior, izquierda y derecha. En caso de que existan piezas laterales disponibles y no se cuente con una zona central para construir un determinado esquema, se deben construir bases ficticias, a partir de los datos de las piezas centrales. Estas bases ficticias no son consideradas al momento de calcular el rendimiento de la materia prima.

$$(d_{cc} + e_l)^2 + \left(\frac{a_l}{2}\right)^2 \leq r^2 \quad (4.7)$$

Donde:

d_{cc} : Distancia centro circunferencia a cota de referencia

e_l : Espesor lateral

a_l : Ancho lateral

r : Radio rollizo involucrado

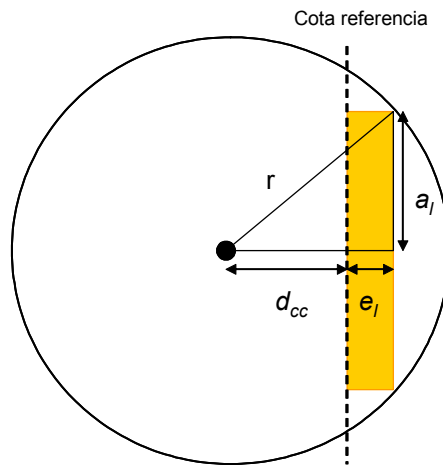


Figura 4.9 Restricción para no sobrepasar límites de la región.

El procedimiento de construcción de esquemas se repite mientras existan piezas por asignar.

La tabla 4.1 presenta la información que entrega la función constructora respecto de una solución para el problema. La primera columna asigna un número al esquema, para diferenciarlo de los demás; la segunda columna indica el tipo de rollizo asociado al esquema; la tercera y cuarta columna indican el tipo y cantidad de centrales asignados, respectivamente; la quinta columna muestra el volumen total de piezas centrales asociadas al esquema; las siguientes doce columnas muestran el tipo de pieza lateral y su ubicación en el esquema; finalmente, las últimas dos columnas presentan el volumen total de piezas

laterales presentes en el esquema y la cantidad de esquemas de un determinado tipo que deben ser procesados.

Tabla 4.1. Esquema de solución proporcionada por Función Constructora.

n° esquema	tipo rollizo	tipo central	cantidad central	vol. Central (m3)	superior			inferior			izquierda			derecha			vol. Lateral (m3)	Cantidad Esquemas
					1	2	3	1	2	3	1	2	3	1	2	3		
1	6	5	7	0,112	12	12	8	12	12	8	8	4	0	8	4	0	0,1248	96
2	6	4	7	0,1008	12	12	8	12	12	8	8	8	0	8	8	0	0,1312	39
3	5	4	7	0,1008	12	10	4	12	10	4	8	4	0	8	4	0	0,1136	88
4	5	4	7	0,1008	12	10	4	12	10	4	8	3	0	8	3	0	0,112	1
5	5	4	7	0,1008	12	10	3	12	10	3	8	3	0	8	3	0	0,1104	7
6	5	3	7	0,0896	12	10	3	12	10	3	8	8	0	8	8	0	0,1184	43
.
.
.
.
18	2	2	7	0,0784	5	0	0	5	0	0	5	0	0	5	0	0	0,0384	26
19	2	1	7	0,0672	5	0	0	5	0	0	5	1	0	5	1	0	0,0488	92
20	1	1	7	0,0672	1	0	0	1	0	0	5	0	0	5	0	0	0,0296	18
21	1	1	7	0,0672	0	0	0	0	0	0	5	0	0	5	0	0	0,0192	17

Un esquema de la función constructora es presentado en la figura 4.10. Es importante mencionar que este método genera tantos esquemas de corte como lo requiera la información de entrada, por lo que, en teoría, los esquemas generados pueden ser todos diferentes, pero en la práctica, dada la naturaleza de los datos, es posible que se generen muchos esquemas iguales.

La función constructora, respecto a la generación de un determinado esquema, opera de manera similar a la forma en que construye los esquemas el modelo optimizador de patrones de corte presentado en Maness y Adams (1991). Sin embargo, la diferencia está en que el algoritmo propuesto en el presente estudio sólo se encarga de la tarea de generar los esquemas, sin optimizar explícitamente, dejando esta tarea a las metaheurísticas (Simulated Annealing o Algoritmos Genéticos).

Algoritmo Generación Esquemas

```
Mientras existan piezas en  $C_E$  o  $L_E$  y existan rollizos en  $R$ 
{
  Seleccionar desde  $R$  el rollizo de mayor diámetro disponible;
  Seleccionar desde  $C_E$  el tipo de pieza central de mayor ancho que
  sea posible ubicar en la zona central;
  Determinar altura máxima ( $h_{\max}$ ) que puede tomar la zona
  central.  $h_{\max} = \sqrt{(d_{\text{rollizo}})^2 - (\text{ancho}_{\text{pieza}})^2}$ ;
   $n = \left\lceil \frac{n^{\circ} \text{ total piezas centrales}}{n^{\circ} \text{ total rollizos disponibles}} \right\rceil$ ;
   $h = \text{espesor}_{\text{pieza}} \cdot n$ ;
  Si  $h_{\min} < h < h_{\max}$ 
    Asignar  $n$  piezas centrales del tipo seleccionado desde  $C_E$  en la
    zona central;
  Si no
    Asignar  $n_{\min} = \left\lceil \frac{h_{\min}}{\text{espesor}_{\text{pieza}}} \right\rceil$  piezas centrales del tipo seleccionado
    desde  $C_E$  a zona central;
  Para cada subzona lateral (superior, inferior, derecha e izquierda)
  {
    Mientras se cumpla con número máximo de piezas por zona
    {
      Seleccionar desde  $L_E$  la pieza lateral de mayor ancho
      disponible y que cumpla con restricción de frontera dada
      por la expresión (4.7), y asignarla a subzona;
    }
  }
  Si existen piezas en  $C_E$  o  $L_E$  y no existen rollizos en  $R$ , o Si no
  es posible asignar las piezas de  $C_E$  o  $L_E$  a los rollizos
  disponibles en  $R$ 
  {
    Informar solución infactible;
    Fin;
  }
  Si se han asignado todas las piezas
  {
    Informar solución factible;
    Fin;
  }
}
```

Figura 4.10. Esquema Función Constructora.

4.5 Implementación de Simulated Annealing

Esta metaheurística tiene su origen en un trabajo de Kirkpatrick (1983). Ha demostrado ser una herramienta efectiva para resolver una amplia gama de problemas de optimización combinatoria. Simulated Annealing (SA) es una variante de la búsqueda local que permite movimientos ascendentes para evitar quedar atrapado prematuramente en un óptimo local.

Las bases de SA fueron publicadas por Metropolis et al. (1953), donde se presenta un algoritmo para simular el enfriamiento de un material en un “baño de calor”. En Dowsland (1993) se explica este proceso, conocido como “annealing”: Si un material sólido es calentado pasado su punto de fusión y luego enfriado hasta que alcance un estado sólido, las propiedades estructurales del sólido enfriado dependen de la tasa de enfriamiento. En esencia, el algoritmo de Metropolis et al. (1953) simula el cambio en la energía del sistema cuando está sujeto a un proceso de enfriamiento, hasta que converge a un estado estable “frío”.

Los algoritmos de búsqueda local tradicionales, como el presentado en la figura 4.11, comienzan desde una solución inicial, se genera una solución vecina, y si ésta es mejor a la encontrada anteriormente, es reemplazada por la nueva solución. Este proceso continúa hasta que se cumpla algún criterio de detención. Esto significa que la búsqueda puede terminar en un óptimo local.

```
Algoritmo de búsqueda local descendente simple  
Inicio;  
    Seleccionar estado inicial  $i \in S$ ;  
    Repetir {  
        Generar un estado  $j$  en la vecindad de  $i$ ;  
        Calcular  $\delta = f(j) - f(i)$ ;  
        Si  $\delta < 0$  entonces  $i = j$ ;  
    } Hasta  $f(j) > f(i)$ , para todo  $j$  en la vecindad de  $i$ ;  
Fin;
```

Figura 4.11 Algoritmo de búsqueda local simple. Fuente: Dowsland (1993).

Un modo de evitar este problema es permitir que algunos movimientos se desplacen a soluciones peores. Estos movimientos deben hacerse de un modo controlado, mediante una función que hará disminuir la probabilidad de permitirlos a medida que se avanza en la búsqueda. La fundamentación de este control se basa en trabajos sobre termodinámica estadística. Sean dos estados de un sistema, i y j , con energía asociada $E(i)$ y $E(j)$, respectivamente. Se asume que el sistema cambia su configuración de un estado i a un estado j con probabilidad $P = \exp\left(-\frac{\delta}{kt}\right)$, con $\delta = E(j) - E(i)$, k es la constante de Boltzmann, y t la temperatura. Si $\delta < 0$, o sea, hay un incremento energético, la probabilidad de aceptar este incremento está dada por P . Entonces, es posible establecer una relación entre los elementos de un sistema de simulación termodinámica y los elementos requeridos para utilizar este enfoque en problemas de optimización, la cual se presenta en la figura 4.12.

Simulación Termodinámica	Optimización
<ul style="list-style-type: none"> • Estados del sistema • Energía 	<ul style="list-style-type: none"> • Soluciones factibles • Costo (Se requiere función objetivo expresada en términos de minimización)
<ul style="list-style-type: none"> • Cambio de estado • Temperatura • Estado congelado 	<ul style="list-style-type: none"> • Solución vecina • Parámetro de control • Solución Heurística

Figura 4.12 Relación entre elementos de simulación termodinámica y optimización. Fuente: Dowsland (1993).

Dowsland (1993) plantea que para implementar el algoritmo de la figura 4.13 en un problema particular, es necesario tomar una serie de decisiones, las que se clasifican en genéricas y específicas. Las decisiones genéricas se refieren principalmente a la forma de controlar la temperatura, incluyendo su valor inicial y la función de temperatura; el número de iteraciones para cada nivel de temperatura, y el criterio de término del algoritmo. Las decisiones específicas comprenden la definición del espacio de solución, la vecindad de una solución, la función objetivo o de costo, y la forma de obtener la solución inicial.

Algoritmo básico Simulated Annealing

```
Inicio;

  Seleccionar estado inicial  $i \in S$ ;

  Seleccionar temperatura inicial  $t = t_0$ ;
  Seleccionar una función de temperatura T;
  Repetir { Inicializar contador de repeticiones  $n = 0$ ;
    Repetir { Generar un estado  $j$  en la vecindad de  $i$ ;
      Calcular  $\delta = f(j) - f(i)$ ;
      Si  $\delta < 0$  entonces  $i = j$ 
      Si no { Generar  $r \sim U(0,1)$ ;
        Si  $r < \exp(-\delta/t)$  entonces  $i = j$ ;
      }
       $n = n + 1$ ;
    } Hasta que  $n = N(t)$ ;
     $t = T(t)$ ;
  } Hasta que condición de termino se cumpla;

Fin;
```

Figura 4.13. Algoritmo básico Simulated Annealing. Fuente: Dowsland (1993).

4.5.2 Decisiones genéricas

Entre las decisiones genéricas a tomar para resolver un problema con Simulated Annealing están las relacionadas con los parámetros que dirigen el programa de enfriamiento, los que deben ser definidos adecuadamente, así como la función de temperatura.

- **Temperatura inicial y final**

Los valores de la temperatura inicial y final son definidos experimentalmente.

- **Función de temperatura**

La función de temperatura elegida es una de las más comúnmente utilizadas en la literatura, y corresponde a la expresión (4.8):

$$T(t) = \alpha \cdot t \quad (4.8)$$

Donde:

α : Parámetro a fijar, $0 < \alpha < 1$

t : Temperatura

Para esta función de temperatura, en la literatura (Dowland, 1993) se recomiendan valores altos de α , entre 0,8 y 0,99, ya que, empíricamente, se obtienen buenos resultados.

- **Número de iteraciones para cada temperatura**

Este es un parámetro a fijar experimentalmente.

- **Criterio(s) de término para el algoritmo**

El criterio de término considerado para el algoritmo es alcanzar la temperatura final, establecida previamente.

4.5.3 Decisiones específicas

- **Representación de la solución**

La representación de la solución elegida para este estudio consiste en un arreglo, el cual indica el número de rollizos de cada tipo que deben ser utilizados para satisfacer el conjunto de pedidos. Entonces, una solución S queda definida por el vector $S = [s_1, s_2, \dots, s_R]$ con s_j el número de rollizos tipo j utilizados para satisfacer el conjunto de pedidos y R el número de tipos de rollizos disponibles. A modo de ejemplo, la solución mostrada en la figura 4.14 indica que para cumplir con los pedidos se han utilizado 40 rollizos tipo 1; 25 rollizos tipo 2; 28 rollizos tipo 3, etc.

Esta representación tiene asociado el valor de la función objetivo o de evaluación, que indica la calidad de la solución. Este valor es calculado una vez que la solución ha sido construida.

$$S = [S_1 \quad s_2 \quad s_3 \quad \dots \quad s_R]$$

$$S = [40 \quad 25 \quad 28 \quad \dots \quad 89]$$

Figura 4.14 Representación de solución.

Existe la posibilidad de que una solución generada durante las iteraciones de Simulated Annealing sea infactible, pudiendo presentarse dos casos:

Caso 1: La cantidad asignada a un tipo de rollizo sea mayor que la cantidad efectivamente disponible para ese tipo. Si ello ocurre, se reemplaza el o los valores que correspondan por la cantidad efectivamente disponible. Esta situación se presenta en la figura 4.15.

Solución Actual	S=	40	32	50	39	28	25
Rollizos disponibles=		80	40	44	54	62	38
La solución vecina considera 50 rollizos tipo 3, pero se tienen 44 disponibles, por lo tanto, la solución vecina modificada es:							
Solución Vecina	S'=	40	32	44	39	28	25

Figura 4.15. Reparación de solución generada infactible, caso 1.

Caso 2: Con la cantidad asignada para cada tipo de rollizo no es posible satisfacer los pedidos. Si ello sucede, la solución es reparada mediante el procedimiento descrito en la

figura 4.16, donde S es el vector que define a la solución generada y RD el vector que contiene la cantidad de rollizos de cada tipo efectivamente disponibles.

Procedimiento Reparación de Solución

```
Sea  $i = \text{tipos\_de\_rollizo} - 1$ ;  
Mientras  $S$  sea infactible  
{  
    Si ( $S[i] \geq RD[i]$ )  
    {  
         $S[i] = RD[i]$ ;  
         $i--$ ;  
        Si ( $i < 0$ )  
        {  
             $i = \text{tipos\_de\_rollizo} - 1$ ;  
        }  
    }  
    Si ( $S[i] < RD[i]$ )  
    {  
         $S[i] = S[i] + 1$ ;  
    }  
    construir Esquemas a partir de  $S$ ;  
     $i--$ ;  
    Si ( $i < 0$ )  
    {  
         $i = \text{tipos\_de\_rollizo} - 1$ ;  
    }  
}
```

Figura 4.16. Procedimiento de reparación de solución infactible, caso 2.

- **Vecindad de una solución factible**

Para generar una solución vecina a partir de una solución actual, lo que se hace es seleccionar en forma aleatoria dos posiciones del vector correspondiente a la solución actual e intercambiar sus valores. Esto se ilustra en la figura 4.17, en donde, dada una

solución S , se seleccionan las posiciones 2 y 5 del vector, obteniéndose una solución vecina S' .

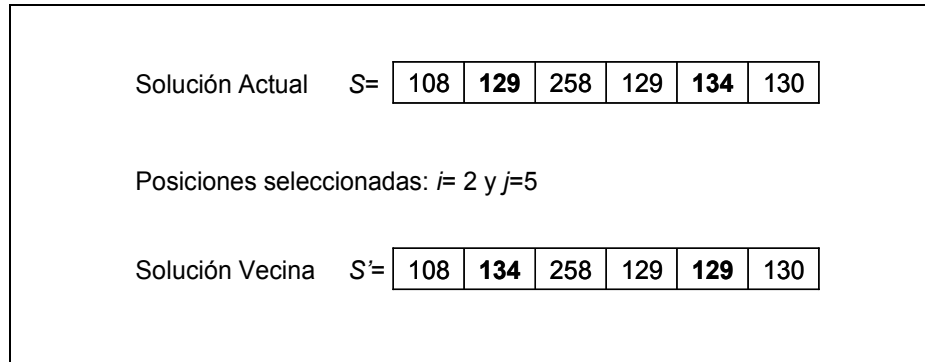


Figura 4.17. Generación de solución vecina.

- **Selección de una solución inicial**

La solución inicial considerada es la que se obtiene construyendo los esquemas de corte a partir de los datos iniciales de escuadrías y stock de rollizos, es decir, aplicando la función constructora a los datos iniciales del problema.

- **Función de evaluación**

La evaluación de las soluciones está relacionada con la eficiencia en el uso de la materia prima, es decir, el volumen de los pedidos, medido en m^3 , dividido por el volumen de materia prima utilizada (rollizos). En el caso de Simulated Annealing, es conveniente expresar la función en términos de “costo”, es decir, una función a minimizar, por lo tanto, simplemente la función de evaluación debe quedar expresada en términos de pérdida de materia prima. Más específicamente, sea el vector solución $S = [s_1, s_2, \dots, s_R]$. El volumen V de materia prima utilizada se calcula según la expresión (4.9), donde v_j es el volumen del rollizo tipo j :

$$V = \sum_{j=1}^R s_j v_j \quad (4.9)$$

Sea V_E el volumen total del conjunto de pedidos, entonces la función objetivo, que expresa la pérdida de materia prima está dada por (4.10):

$$f(S) = 1 - \frac{V_E}{\sum_{j=1}^R s_j v_j} \quad (4.10)$$

4.5.4 Interacción entre función constructora y Simulated Annealing

A modo de resumen, en la figura 4.18 se presenta un esquema general del proceso descrito anteriormente. A partir de la información de rollizos disponibles y piezas requeridas, se construye una solución inicial, la que es evaluada y codificada de acuerdo a la representación de solución mencionada. Luego comienza a operar la metaheurística. A medida que se van generando soluciones vecinas, éstas son construidas por la función, evaluadas y codificadas, y esta información es pasada a la metaheurística. El proceso continúa hasta que se cumpla el criterio de detención. Finalmente, se entrega la solución obtenida.

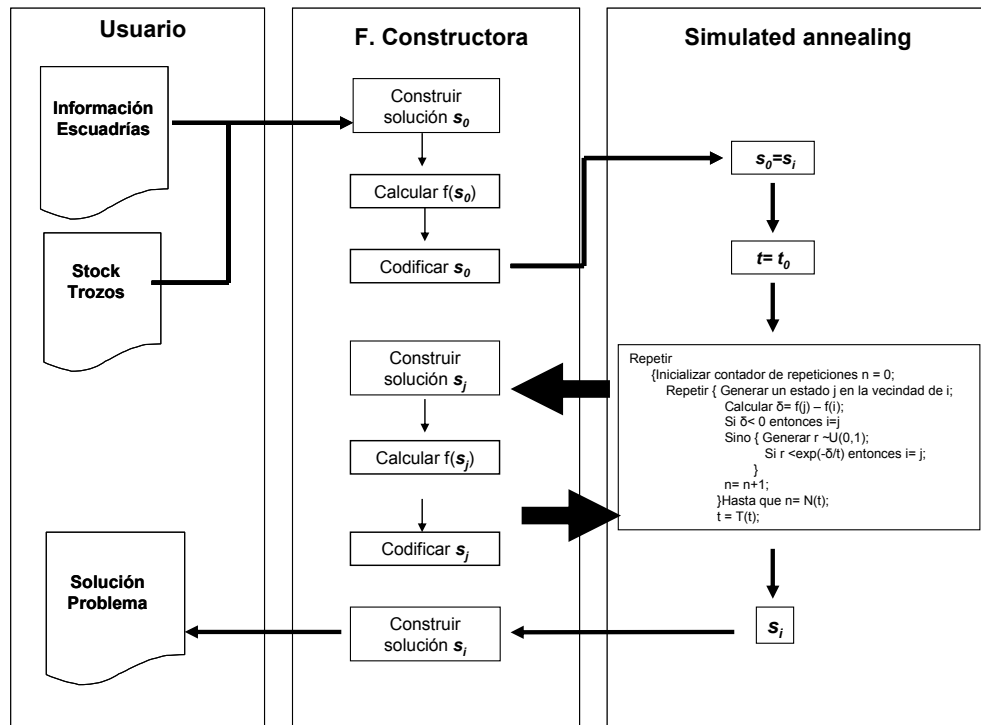


Figura 4.18 Esquema interacción entre función constructora y algoritmo Simulated Annealing.

4.6 Implementación del Algoritmo Genético

Los Algoritmos Genéticos son técnicas de búsqueda inspirados en la mecánica de la selección natural, genética y evolución (Goldberg, 1989). Pueden ser aplicados en problemas de optimización, y en ese caso, una población de soluciones del problema (llamadas individuos, criaturas, etc.), representadas mediante alguna estructura de datos, evolucionan hacia mejores soluciones.

Su nombre se origina a partir de la analogía entre la representación de una estructura compleja por medio de un vector, y la idea de estructura genética de un cromosoma. En muchas aplicaciones este vector, o “cromosoma”, es simplemente un string binario. Los componentes del vector, son llamados “genes”. Los posibles valores que pueden tomar estos componentes o genes se les conoce como “aleles” (Reeves, 1993). El pseudo código de un Algoritmo Genético básico es presentado en la figura 4.19.

La evolución usualmente comienza a partir de una población de individuos generada aleatoriamente, y continúa a través de varias generaciones. En cada generación se crea un nuevo conjunto de criaturas artificiales usando información de los mejores individuos de la generación anterior. Para esto, se evalúa el “fitness”, o “grado de adaptación” de cada individuo de la población, seleccionando individuos en forma estocástica de acuerdo a su “fitness”, los cuales se modifican para formar una nueva población. Esta nueva población es utilizada en la siguiente iteración del algoritmo.

El Algoritmo Genético implementado en este trabajo es similar al descrito por Goldberg(1989), en el cual las soluciones son codificadas en un string binario de tamaño finito.

```
Sean:
P(t): Población de estructuras (equivale a individuos, cromosomas,
soluciones, etc.) en un instante t;
C(t): "Buffer" donde se guardan las estructuras seleccionadas de una
población en un tiempo t;
C'(t): "Buffer" donde se guardan los individuos obtenidos al cruzar y
mutar los individuos de C(t);

Inicio
t=0;
Evaluar estructuras en P(t);
Repetir
{
    t=t+1;
    Seleccionar individuos para reproducción a partir de P(t-1),
    guardándolos en C(t);
    Recombinar y mutar individuos en C(t), formando C'(t);
    Evaluar estructuras en C'(t);
    Formar P(t) a partir de C'(t) y P(t-1);
} Hasta que se cumpla condición de término
Fin
```

Figura 4.19. Seudo código de un Algoritmo Genético básico. Fuente: Eshelman (2000).

4.6.2 Representación y codificación de una solución

Como se mencionó en secciones anteriores, una solución a este problema depende de la cantidad de rollizos de cada tipo utilizados para satisfacer los pedidos. En este sentido, la representación de solución para el Algoritmo Genético se basa en la utilizada para Simulated Annealing, sólo que en este caso se requiere de un paso adicional, conocido como codificación. Las soluciones del problema son codificadas en un string binario, de la siguiente manera: Se tiene una solución S definida por el vector $S = [s_1, s_2, \dots, s_R]$, con s_j el número de rollizos tipo j utilizados para satisfacer el conjunto de pedidos y R el número de tipos de rollizos disponibles. Los valores s_j , expresados en sistema decimal, se convierten a sistema binario, como lo indica la figura 4.20, resultando un string de tamaño finito s , que contiene sólo ceros o unos.

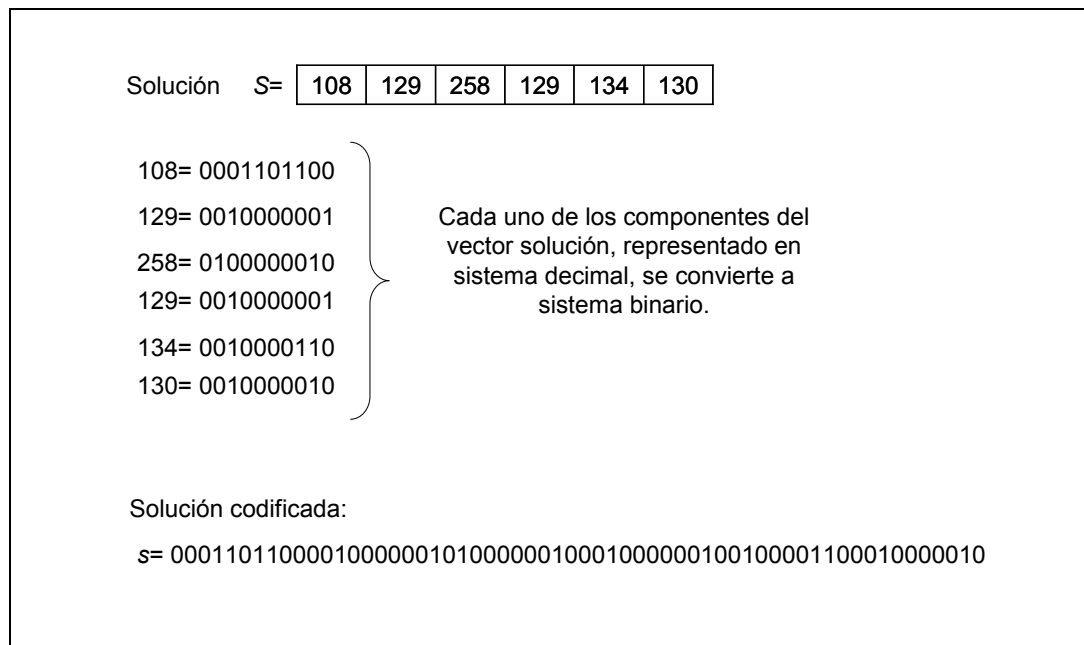


Figura 4.20 Codificación de una solución.

4.6.3 Definición de operadores

En esta implementación, se utilizan operadores de reproducción (selección), cruzamiento y mutación, los cuales se describen a continuación.

- **Reproducción (o selección):**

Es un proceso en el cual los strings individuales son copiados de acuerdo al valor de su función objetivo o “fitness”. Esto significa que los strings con un “fitness” más alto tienen más alta probabilidad de aportar descendientes a la próxima generación.

El esquema de selección utilizado en esta implementación es el de “roulette wheel”, descrito por Goldberg (1989), en donde los strings son seleccionados proporcionalmente a su “fitness”. Además, se aplica el concepto de elitismo, es decir, el mejor individuo de cada generación es forzado a ser miembro de la siguiente generación.

- **Cruzamiento:**

El operador de cruzamiento utilizado en este estudio corresponde al denominado “simple crossover”, descrito en Goldberg (1989). Este operador funciona como se describe a continuación. Dados un par de strings (que corresponden a soluciones codificadas) de tamaño l , se selecciona aleatoriamente una posición k , entre 1 y $l-1$. De esta forma, se crean dos nuevos strings intercambiando los caracteres entre las posiciones $k+1$ y l inclusive. Por ejemplo, en la figura 4.21 se tienen las soluciones s_1 y s_2 , correspondientes a strings de tamaño $l=8$. Ahora, suponer que, al seleccionar aleatoriamente un número k entre 1 y 7, se obtiene $k=3$. De este cruzamiento se obtienen dos nuevos strings, s_1' y s_2' , los cuales pasan a formar parte de la nueva generación.

- **Mutación:**

En Algoritmos Genéticos, la mutación es la alteración aleatoria ocasional del valor de una posición del string. En esta implementación en particular, el operador mutación consiste en cambiar el valor de una determinada posición del string, de 0 a 1, o viceversa. La figura

4.22 muestra un string seleccionado para mutación. Se selecciona aleatoriamente la posición $k = 4$, y se cambia su valor. Dependiendo de la probabilidad de mutación especificada, puede modificarse el valor de una o varias posiciones del string.




Figura 4.21. Descripción del operador de cruzamiento.

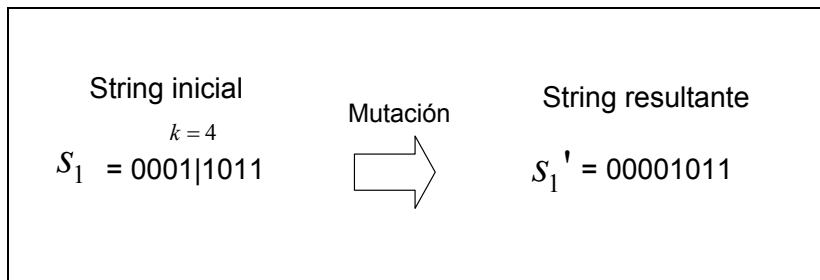


Figura 4.22. Descripción operador de mutación.

4.6.4 Función de Evaluación

El “fitness” o calidad de las soluciones es evaluado de acuerdo a criterios de eficiencia, es decir, el rendimiento volumétrico de la materia prima.

Para evaluar una determinada solución, ésta debe ser “decodificada”, es decir, el string binario debe expresarse en sistema decimal. Esta solución luego es construida y evaluada.

Dado un vector solución $S = [s_1, s_2, \dots, s_R]$, el volumen asociado a cada tipo de rollizo v_j , $j = 1, \dots, R$, y el volumen total de productos V_E , la función de evaluación se calcula mediante la expresión (4.11).

$$f(S) = \frac{V_E}{\sum_{j=1}^R s_j v_j} \quad (4.11)$$

Existe la posibilidad de que se obtengan soluciones infactibles. En ese caso, estas soluciones son penalizadas, asignándoles un rendimiento de 0%.

4.6.5 Inicialización del algoritmo

La inicialización del algoritmo consiste en definir la manera en que se obtendrá la población inicial. En este caso se obtiene generando aleatoriamente un conjunto de strings binarios.

4.6.6 Criterios de término

El criterio de término considerado para el algoritmo es el alcanzar un cierto número de generaciones. Esto corresponde a un parámetro de control del Algoritmo Genético.

4.6.7 Parámetros del algoritmo

El Algoritmo Genético implementado posee cuatro parámetros de control, cuyos valores deben ser determinados mediante experimentación. Estos son:

- Probabilidad de cruzamiento (p_{cross}): La probabilidad de cruzamiento se refiere a que, una vez seleccionados los padres, el cruzamiento entre ellos se realizará con una cierta probabilidad p_{cross} . Si el cruzamiento no ocurre (con probabilidad $1 - p_{cross}$), los padres son copiados directamente a la siguiente población.
- Probabilidad de mutación (p_{mut}): Este parámetro está relacionado con el número de bits que van a ser modificados en un determinado string. A mayor p_{mut} , mayor es la cantidad de bits que serán modificados en el string.
- Tamaño de la población: Se refiere al número de individuos (soluciones) que se manejarán en cada generación.
- Número de generaciones: Está relacionado con el criterio de término para el algoritmo implementado.

4.6.8 Interacción entre función constructora y Algoritmo Genético

La interacción entre la función constructora y el Algoritmo Genético tiene algunas diferencias respecto al caso de Simulated Annealing. La solución inicial no es proporcionada por la función constructora, sino que el Algoritmo Genético genera aleatoriamente una población inicial de soluciones, las cuales, para ser evaluadas, deben ser en primer lugar decodificadas y construidas.

Durante la ejecución del Algoritmo Genético, en cada generación se van obteniendo nuevas soluciones debido a la aplicación de los operadores de cruzamiento y mutación, y para evaluar cada una de estas nuevas soluciones, deben ser previamente decodificadas y construidas.

Finalmente, una vez que se han cumplido los criterios de término, se entrega la mejor solución obtenida.

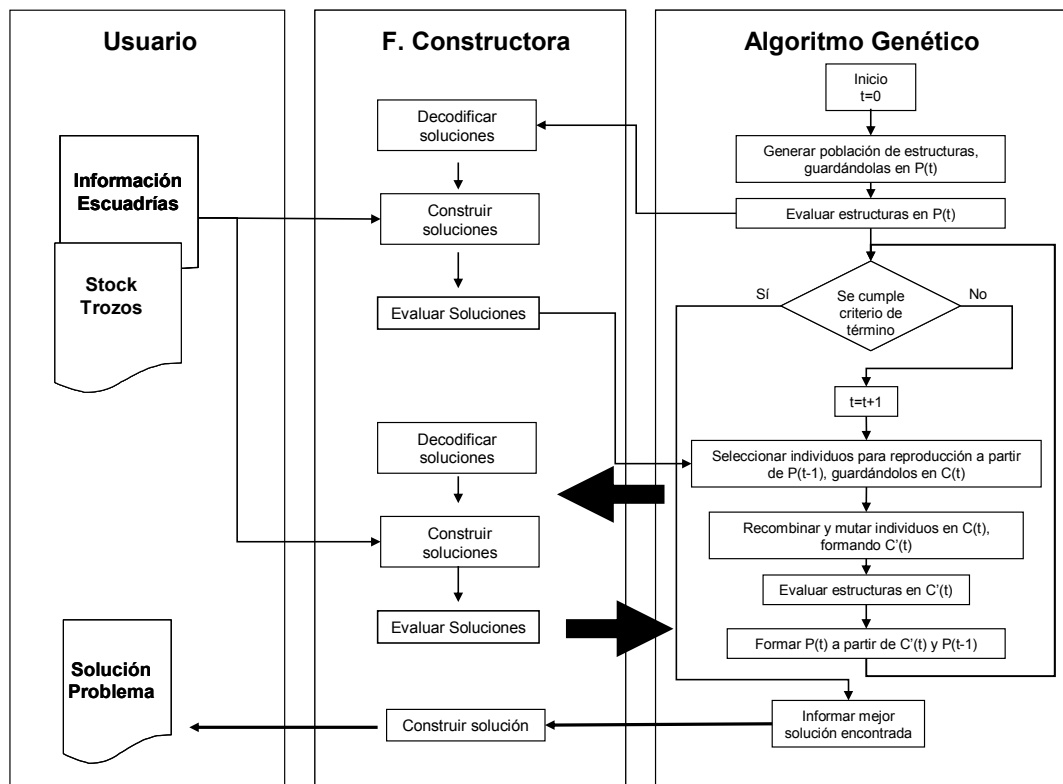


Figura 4.23 Esquema interacción entre Función constructora y Algoritmo Genético.

4.7 Implementación Computacional

Los algoritmos propuestos fueron implementados en lenguaje de programación C++, y las pruebas fueron efectuadas en un PC con CPU Intel Pentium 4 a 2,8 Ghz, 492 MB de RAM y sistema operativo Windows XP.

Para la implementación del Algoritmo Genético se utilizó el “GAlib genetic algorithm package”, escrito por Matthew Wall, en el Instituto de Tecnología de Massachussets (MIT), el cual consiste en un conjunto de librerías en lenguaje C++, con las que es posible implementar varios tipos de Algoritmos Genéticos.

CAPÍTULO 5. RESULTADOS

5.1 Generación de problemas de prueba

Con el fin de evaluar el desempeño de los algoritmos propuestos, se generó un conjunto de problemas de prueba, a partir de información extraída de la literatura (Ramos, 2005) y consultas a expertos. Esta información contiene datos sobre dimensiones de rollizos y productos con los que se trabaja comúnmente en los aserraderos. En este estudio se consideró un total de cinco tipos de piezas centrales, doce tipos de piezas laterales y seis tipos de rollizos. La tabulación de estos datos se encuentra en anexo A1.1.

Un problema está definido por la cantidad de rollizos disponibles de cada tipo, y el tipo y cantidad de productos que se requiere obtener, es decir, la demanda por tipo de producto. El tamaño de un problema está dado por el volumen total de escuadrías que se requiere producir.

La generación de problemas de prueba se realizó de la siguiente forma: Con la información sobre tipos de piezas y rollizos se construyó un conjunto de esquemas de corte “eficientes” en términos de rendimiento volumétrico, en los que están involucrados todos los tipos de piezas y de rollizos. Estos esquemas se construyeron manualmente, pero teniendo en consideración la utilización eficiente de la materia prima. Para cada uno de estos esquemas se calculó el volumen total de las piezas incluidas en el esquema y, con el volumen del rollizo involucrado, se determinó el rendimiento volumétrico asociado a cada esquema. El detalle de estas construcciones se encuentra en anexo A1.2. Basándose en los esquemas construidos, se generaron los problemas de prueba, para lo cual se implementó un programa computacional en lenguaje C++, al cual se le debe proporcionar, como datos de entrada, el volumen de escuadrías de cada esquema y el volumen deseado para el problema que se va a generar. Como salida el programa proporciona el número de veces que debe ser incluido cada uno de los esquemas construidos para alcanzar el volumen requerido del problema que se va a generar, y para esto el algoritmo determina pseudo-aleatoriamente el número de veces

que cada esquema debe ser incluido. De esta manera, para cada problema generado se puede calcular la cantidad de rollizos de cada tipo que como mínimo debe haber en stock, y la cantidad y tipo de piezas incluidas, lo cual pasa a ser la demanda del problema, que se determina de la siguiente forma: Se tiene un conjunto de siete esquemas construidos manualmente E_j , $j = 1, \dots, 7$. Sea ne_j el número de veces que el esquema tipo j está incluido en un determinado problema. Se definen además:

$$R_{rj} = \begin{cases} 1; & \text{Si rollizo tipo } r \text{ está incluido en esquema tipo } j \\ 0; & \text{e.o.c} \end{cases}$$

$ncent_{cj}$: Cantidad de piezas centrales tipo c que están incluidas en esquema tipo j .

$nlat_{lj}$: Cantidad de piezas laterales tipo l que están incluidas en esquema tipo j . En este caso, $c = 1, \dots, 5$ y $l = 1, \dots, 12$.

Sea $dcent_c$ la demanda por pieza central tipo c y $dlat_l$ la demanda por pieza lateral tipo l . Las demandas por tipo de pieza central o lateral se calculan según las expresiones (5.1) y (5.2):

$$dcent_c = \sum_j ne_j ncent_{cj}; c = 1, \dots, 5; j = 1, \dots, 7 \quad (5.1)$$

$$dlat_c = \sum_j ne_j nlat_{cj}; l = 1, \dots, 12; j = 1, \dots, 7 \quad (5.2)$$

La mínima cantidad de rollizos requeridos por tipo (rm_r) se determinan según la expresión (5.3):

$$rm_r = \sum_j ne_j R_{rj}; r = 1, \dots, 6. \quad (5.3)$$

Es posible además calcular el rendimiento esperado para el problema, ya que como se mencionó, la construcción de los esquemas se realizó bajo un criterio de eficiencia. Este rendimiento esperado pasa a ser la mejor solución encontrada para el problema, la cual puede ser comparada con las soluciones entregadas por los algoritmos. El rendimiento

esperado se calcula según la expresión (5.4), donde $vlat_l$ es el volumen de pieza lateral tipo l , $vcent_c$ es el volumen de pieza central tipo c , y $vrol_r$ es el volumen de rollizo tipo r .

$$Eficiencia_esperada = \frac{\left(\sum_{l=1}^{12} vlat_l dlat_l + \sum_{c=1}^5 vcent_c dcent_c \right)}{\sum_{r=1}^6 vrol_r m_r} \quad (5.4)$$

El criterio para la generación de los problemas de prueba, consistió en que el volumen de éstos refleje el nivel de producción en un turno para aserraderos pequeños, medianos y grandes. Es así como se generó un total de 11 problemas de prueba, correspondientes a 3 problemas para aserraderos pequeños, 6 para aserraderos medianos y 2 para aserraderos grandes. Una tabla resumen con las características más relevantes para los problemas generados se presenta en la tabla 5.1. El detalle de estos problemas se presenta en anexo A1.3.

Tabla 5.1. Información problemas de Prueba generados.

N°	Problema	Volumen Rollizos (m3)	Volumen Centrales (m3)	Volumen Laterales (m3)	Volumen Problema (m3)
1	AP1	9,98	1,66	1,32	2,98
2	AP2	22,50	3,83	3,22	7,05
3	AP3	32,11	5,43	4,60	10,04
4	AM1	45,14	6,91	6,70	13,61
5	AM2	63,65	10,25	9,29	19,54
6	AM3	113,66	17,83	16,60	34,43
7	AM4	160,85	27,57	23,20	50,77
8	AM5	205,29	32,14	30,04	62,18
9	AM6	315,19	51,40	46,00	97,40
10	AG1	290,59	60,68	57,20	117,88
11	AG2	354,06	73,95	69,07	143,02

5.2 Establecimiento de parámetros

Como se menciona en el capítulo anterior, tanto Simulated Annealing como Algoritmos Genéticos poseen diversos parámetros de control, cuyos valores deben ser establecidos con el fin de que entreguen buenas soluciones para el problema en estudio y en tiempo de ejecución razonable.

Con el fin de ayudar a encontrar valores apropiados para los parámetros de los algoritmos, se diseñó y efectuó una serie de experimentos estadísticos. Montgomery (1991) plantea que un experimento diseñado es una serie de pruebas en las cuales se inducen cambios en las variables de entrada de un proceso o sistema, de forma que sea posible observar e identificar las causas de los cambios en la salida de ese proceso.

Los algoritmos propuestos pueden considerarse como un proceso, esquematizado en la figura 5.1, en el cual, a partir de información de entrada relativa a un problema determinado, entrega una salida, que en este caso corresponde a una solución de ese problema. Existe además un conjunto de variables que se cree pueden afectar el proceso, que en el caso de los algoritmos, pueden ser los parámetros particulares de cada algoritmo. Estas variables se denominan factores. Ejemplos de factores para Simulated Annealing pueden ser la temperatura inicial, final y el número de iteraciones para cada nivel de temperatura. Respecto a la implementación de Algoritmos Genéticos, pueden ser factores las probabilidades de mutación y cruzamiento, el tamaño de la población, entre otros. Cada uno de estos factores se puede subdividir en niveles, los cuales corresponden a valores o atributos que pueden tener los factores.




Figura 5.1 Esquema general de un proceso o sistema.

El diseño estadístico de experimentos es el proceso de planear un experimento para obtener datos apropiados, que pueden ser analizados mediante métodos estadísticos, con el objetivo de producir conclusiones válidas y objetivas. Montgomery (1991) propone un conjunto de directrices para el diseño de experimentos:

- En primer lugar debe asegurarse una comprensión y correcto planteamiento del problema, lo cual implica establecer claramente los objetivos de la experimentación.
- Elección de factores y niveles. Se deben elegir los distintos factores, sus intervalos y niveles específicos. Esto requiere de un acabado conocimiento del proceso. Tal conocimiento generalmente es una combinación de teoría y experiencia práctica. Es importante investigar todos los factores que pueden ser de interés, y no depender demasiado de la experiencia pasada, en particular durante las primeras etapas de la experimentación.
- Selección de la variable respuesta. El experimentador debe asegurarse de que la variable respuesta realmente provea información útil acerca del proceso en estudio.
- Elección del diseño experimental. Esto depende básicamente de qué es lo que se quiere medir.
- Realización del experimento. Para que el experimento sea llevado a cabo con éxito, es necesaria una cuidadosa planificación. Durante la realización del experimento, éste debe ser vigilado cuidadosamente, de forma que todo se haga conforme a lo planificado, ya que errores en el procedimiento suelen anular la validez experimental.
- Análisis de datos. Para esto deben emplearse métodos estadísticos, ya que proporcionan mayor objetividad en las conclusiones obtenidas. Es importante considerar que los métodos estadísticos, aplicados adecuadamente, no permiten probar algo experimentalmente, sólo hacen posible obtener el probable error de una conclusión, o asignar un nivel de confiabilidad a los resultados. Las técnicas estadísticas, unidas a un buen conocimiento técnico del proceso y al sentido común, suelen llevar a conclusiones razonables.
- Conclusiones y recomendaciones. Se deben extraer conclusiones prácticas de los resultados y recomendar cursos de acción.

Montgomery (1991) plantea que los métodos estadísticos pueden incrementar la eficiencia en la realización de los experimentos, y generalmente, reforzar las conclusiones obtenidas. El uso apropiado de los métodos estadísticos requiere que el investigador considere los siguientes aspectos:

- Uso del conocimiento no estadístico del problema. En algunos casos puede utilizarse una gran cantidad de teoría para explicar las relaciones que hay entre los factores y las respuestas. La estadística no puede sustituir el hecho de reflexionar sobre el problema.
- Mantener el diseño y el análisis tan simples como sea posible. Esto se refiere a que no se debe exagerar en el uso de técnicas demasiado complejas. El uso de técnicas excesivamente elaboradas no mejora la calidad de los resultados si, por ejemplo, se ha efectuado un mal diseño, o los datos no fueron tomados correctamente.
- Reconocer la diferencia entre la significación práctica y la estadística. El uso de métodos estadísticos puede llevar a conclusiones difíciles de llevar a cabo en la práctica.
- Usualmente los experimentos son iterativos. Los experimentos diseñados se utilizan usualmente de manera secuencial, es decir, el primer experimento con un sistema complejo que tiene muchas variables (factores) es usualmente un experimento de diagnóstico diseñado para determinar qué variables son las más importantes. Los experimentos que le siguen se utilizan para refinar la información y determinar los ajustes que deben hacerse a las variables críticas para mejorar el proceso.

En este trabajo, la determinación de valores para los parámetros de los algoritmos propuestos se efectuó apoyándose en una serie de experimentos factoriales. Un experimento factorial es aquel donde en cada ensayo o réplica completa del experimento se investigan todas las combinaciones posibles de los niveles de los factores (Montgomery y Runger, 1996). Estos experimentos permiten extraer conclusiones acerca del efecto que tienen los factores en la salida del proceso (variable respuesta). Si un factor tiene un efecto significativo, éste puede ser de dos clases: Puede corresponder a un

- Un efecto principal, es decir, existe un cambio en la variable respuesta producido por un cambio en el nivel del factor.

- Interacción entre los factores. Ocurre cuando el efecto de uno de los factores depende del nivel elegido para otro factor. La interacción puede ocurrir entre dos o más factores.

La experimentación, para el caso de ambos algoritmos, se realizó siguiendo un esquema secuencial, es decir, comenzando con un primer experimento general, con el fin de establecer el comportamiento de la variable respuesta respecto a cambios en los factores, y luego efectuando nuevos experimentos, los cuales se diseñaron tomando en consideración las conclusiones y resultados obtenidos en los experimentos previos.

Es importante tener en consideración que esta metodología no asegura la obtención de valores óptimos para los parámetros de los algoritmos, sino que se trata de una guía para encontrar valores apropiados.

5.2.2 Establecimiento de parámetros para Simulated Annealing

Con el fin de definir los valores apropiados para los parámetros de control para Simulated Annealing, se diseñó y efectuó una serie de experimentos multifactoriales, con varios niveles para cada factor. El objetivo es poder encontrar valores para los parámetros de Simulated Annealing que permitan obtener soluciones cuya función objetivo esté lo más cercano posible a la mejor solución conocida para los problemas de prueba, y en lo posible en tiempos de ejecución razonable, inferior a 5 minutos, dado que es un problema que en la práctica debe ser frecuentemente resuelto. La variable respuesta de estos experimentos generalmente es la calidad de la solución, medida por el valor de la función objetivo asociado a la solución obtenida. Sin embargo, para algunos experimentos se utilizó como variable respuesta el tiempo de ejecución del algoritmo, con el fin de conocer el efecto que tienen los distintos factores en el tiempo de ejecución. En general, los factores considerados para los experimentos son:

- Parámetro de la función de temperatura α (ALFA).
- Temperatura inicial (T0).

- Temperatura final (TF).
- Número de iteraciones para cada nivel de temperatura (NT).
- Tamaño del problema (COMPLPROB).

5.2.2.1 Experimento 1

Selección de la variable respuesta:

Valor de la función objetivo (FO) que se obtiene al aplicar Simulated Annealing con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se muestran en la tabla 5.2:

Tabla 5.2. Factores y niveles para experimento 1.

Parámetro	Valores
ALFA	0,90; 0,92; 0,94; 0,96; 0,98
T0	10; 150; 300; 450.
TF	1; 0,1; 0,01; 0,001
NT	10, 180, 360, 500
COMPLPROB	1, 2, 3

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- ALFA: Según la literatura consultada (Dowsland, 1993), en general se obtienen buenos resultados con valores entre 0,8 y 0,99.
- T0: Si bien de acuerdo a experimentaciones previas, se han obtenido buenos resultados, es decir, soluciones con entre 20% y 25% de pérdida con temperaturas iniciales bajas, no superiores a 20, se desea evaluar el desempeño con temperaturas superiores, a fin de tener una mayor seguridad al momento de establecer el valor para este parámetro.
- TF: De manera similar al caso anterior, se han obtenido buenos resultados preliminares con temperaturas finales bajas (inferiores a 1), por lo que se decide experimentar con este conjunto de niveles.

- NT: Se decide experimentar con estos niveles para NT, con el fin de abarcar un rango amplio de valores.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

Para el caso de Simulated Annealing, se decide efectuar un total de tres réplicas de este experimento.

Principales Resultados:

Del análisis de efectos principales, se desprende que, para un nivel de confianza de 95%, todos los factores, a excepción de TO (por sí sólo), tienen un efecto significativo en la función objetivo. Mayores detalles sobre el análisis de efectos principales se encuentran en anexo A2.1.

La figura 5.2 presenta gráficos de medias e intervalos de confianza para los factores considerados en el experimento. Estos gráficos, como su nombre lo indica, muestran los intervalos de confianza contruidos para los valores de la variable respuesta que se obtienen para los distintos niveles del factor. Estos gráficos son útiles en la interpretación de los resultados, ya que permiten visualizar las eventuales diferencias entre los niveles del factor. A modo de ejemplo, en el caso de T0, se observa que no hay una clara diferenciación entre los distintos niveles del factor, ya que los intervalos de confianza para los distintos valores se superponen.

Respecto del factor ALFA, se tiene que con los niveles altos seleccionados para este parámetro, se obtienen los mejores resultados para la función objetivo, como lo sugiere el gráfico respectivo.

En cuanto a TF, se observa que con los niveles bajos considerados para este factor se obtienen mejores resultados para FO.

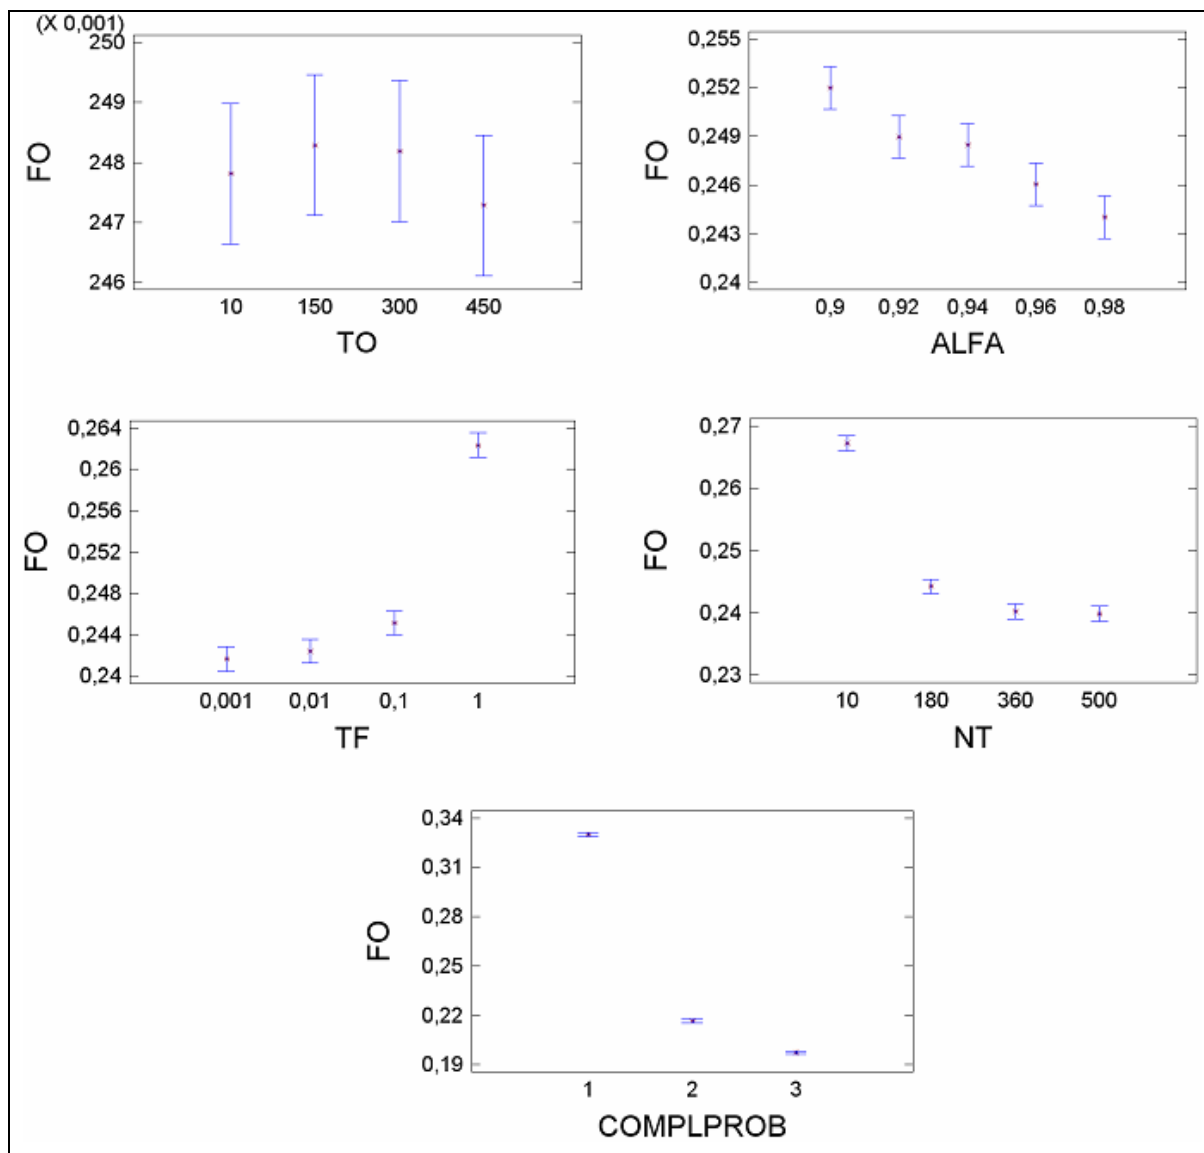


Figura 5.2. Gráficos de medias e intervalos de confianza para los niveles de los factores considerados en Experimento 1.

En el caso del factor NT, se obtienen mejores resultados para los niveles 360 y 500, como se aprecia gráficamente.

Respecto al factor COMPLPROB, se tiene que se obtienen mejores resultados para los problemas de complejidad media y alta.

El análisis de interacciones (para mayores detalles, ver anexo A2.1) indica que para un nivel de confianza de 95% existe interacción significativa entre ALFA y T0. Esto se puede ver en el correspondiente gráfico de interacciones presentado en la figura 5.3. Un gráfico de interacción presenta las respuestas promedio de un factor versus otro, para cada uno de los niveles de éstos. Estos gráficos, como su nombre lo indica, pueden ser útiles para visualizar las interacciones entre dos factores. En general, si las líneas tienden a intersectarse, puede indicar la existencia de interacción entre dos factores. Respecto a la interacción entre los factores ALFA y T0, el gráfico respectivo indica que se obtendrían mejores resultados para los niveles altos de ALFA (0,96 y 0.98), y bajo de T0 (10).

Existe también interacción significativa entre los factores T0 y TF, como se observa en el gráfico correspondiente, presentado en la figura 5.3, en el cual se puede apreciar que en general se obtienen mejores resultados con los niveles bajos de TF.

Según el análisis de interacciones, se tiene que ésta es significativa entre los factores NT y TF, situación que se puede observar gráficamente, sugiriendo que se obtendrían mejores soluciones para valores altos de NT y TF bajos.

Existe interacción significativa entre los factores TF y COMPLPROB, y NT y COMPLPROB. Se observa que para problemas de baja complejidad, los niveles de TF no son relevantes, sin embargo, para problemas de complejidad alta, se obtienen soluciones de mejor calidad con los niveles más bajos de TF. Una situación parecida ocurre en la interacción existente entre los factores NT y COMPLPROB, donde se observa que no influye el valor de NT en la calidad de la solución del problema de complejidad baja, pero en el caso de los problemas de complejidad media y alta se obtendrían mejores soluciones con los niveles altos de NT.

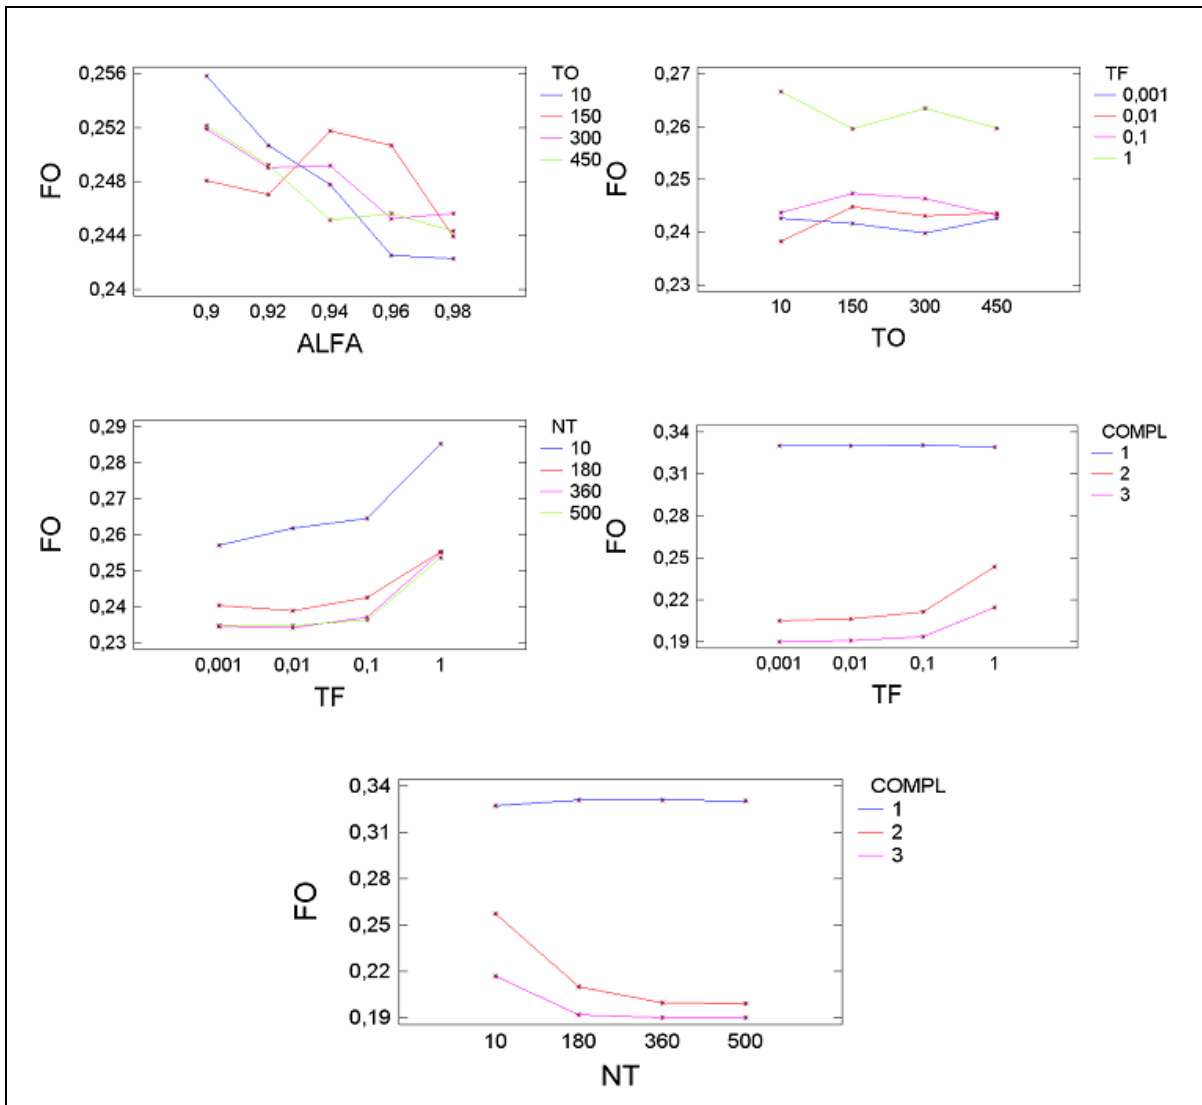


Figura 5.3. Algunos gráficos de interacción entre factores para Experimento 1.

Existen además interacciones entre tres y cuatro factores, como se puede observar en el anexo A2.1.

Como conclusiones generales de este experimento, se puede mencionar que con niveles bajos de TF se obtendrían mejores soluciones. Si bien T0 por sí sólo no influiría en la calidad de las soluciones, sí interactúa con otros factores, como TF. Respecto al factor ALFA, se tiene que se obtienen buenos resultados con los niveles altos, en particular 0,98.

Dado que con este primer experimento no se tiene claridad respecto de los valores apropiados para todos los parámetros, se decide diseñar un segundo experimento factorial, con nuevos niveles para los factores.

Se efectuó además un experimento con el fin de conocer la influencia de los factores en el tiempo de ejecución de Simulated Annealing, cuyos detalles se encuentran en anexo A2.1. Los resultados de este experimento indican que todos los factores considerados tienen un efecto significativo en el tiempo de ejecución.

5.2.2.2 Experimento 2

Selección de la variable respuesta:

Valor de la función objetivo (FO) que se obtiene al aplicar Simulated Annealing con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se muestran en la tabla 5.3. Dado que ALFA y TF tienen valores fijos en este experimento, no se consideran como factores, siendo éstos T0, NT y COMPLPROB. Se consideraron valores fijos para ALFA y TF, ya que de acuerdo a los resultados del primer experimento, se obtienen soluciones de buena calidad para niveles altos para ALFA y bajos para TF.

Tabla 5.3. Factores y niveles para experimento 2.

Parámetro	Valores
ALFA	0,98
T0	10; 350
TF	0,001
NT	100, 200
COMPLPROB	1, 2, 3

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- T0: Se decide experimentar con un nivel alto y otro bajo para T0, con el objetivo de intentar clarificar si efectivamente este factor no tiene un efecto significativo en la calidad de las soluciones, como lo indica el experimento 1.
- NT: Se decide experimentar con estos niveles para NT, ya que si bien el experimento 1 indicaba que se obtendrían buenos resultados con los niveles altos considerados en esas pruebas, dado que NT influye en el tiempo de ejecución, se decide experimentar con niveles más bajos para este factor.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

Se decide efectuar un total de cuatro réplicas de este experimento.

Principales Resultados:

Del análisis de efectos principales, se desprende que, para un nivel de confianza de 95%, se tiene que sólo COMPLPROB tiene un efecto significativo en el valor de la función objetivo. Esta situación se muestra en la figura 5.4, la cual muestra los gráficos de medias en intervalos de confianza para los factores considerados en este experimento. En dichos gráficos no se observa que T0 y NT tengan un efecto claro en el valor de la función objetivo. Por el contrario, sí se aprecia que COMPLPROB influye en la calidad de la solución obtenida.

Respecto a las interacciones, se tiene que para un nivel de confianza del 95%, no hay evidencia para afirmar que existan interacciones significativas entre los factores, si bien los valores-p son relativamente cercanos a 0,05.

En resumen, no se puede aún definir valores para NT y T0, por lo que se decide efectuar un tercer experimento factorial, con nuevos niveles para los factores. Mayor información sobre los resultados de este experimento, como el análisis de efectos principales e interacciones, se presenta en anexo A2.2.

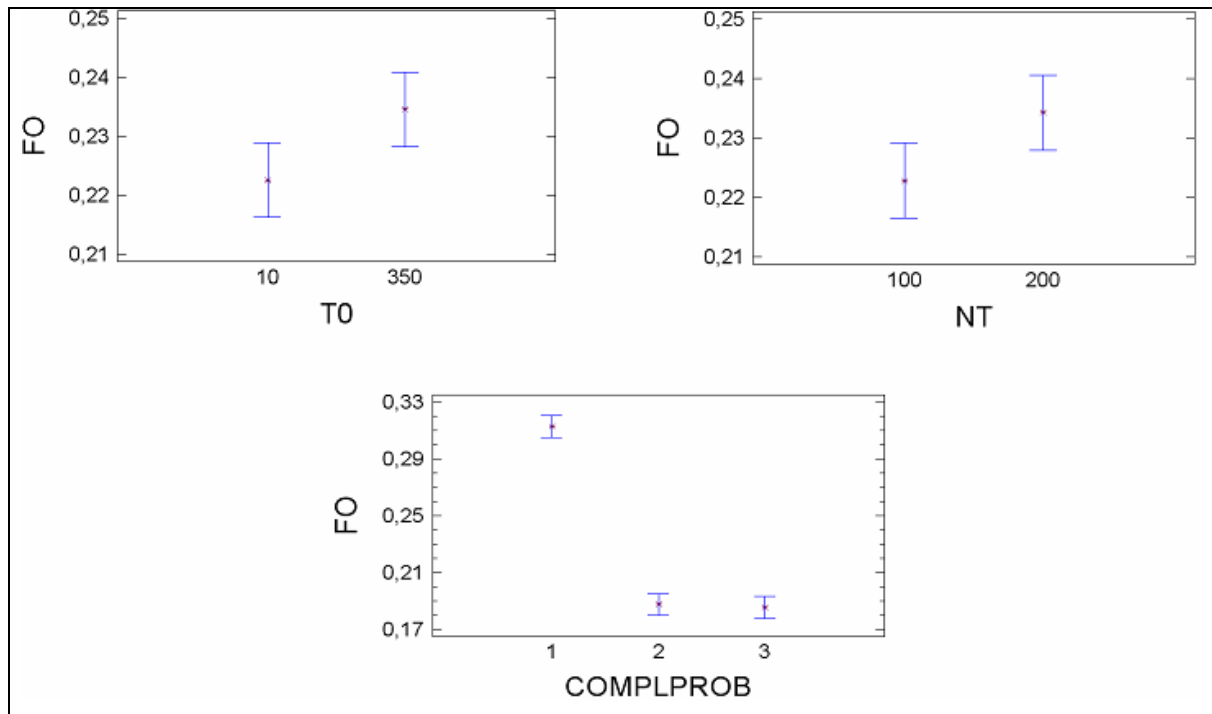


Figura 5.4. Gráficos de medias con intervalos de confianza para los factores de Experimento 2.

5.2.2.3 Experimento 3

Selección de la variable respuesta:

La variable respuesta en este experimento es el valor de la función objetivo (FO) que se obtiene al aplicar Simulated Annealing con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se muestran en la tabla 5.4. Dado que ALFA y TF tienen valores fijos en este experimento, no se consideran como factores, siendo éstos T0, NT y COMPLPROB. Se consideraron valores fijos para ALFA y TF, al igual que en el experimento 2, ya que de acuerdo a los resultados del primer experimento, se obtienen soluciones de buena calidad para niveles altos para ALFA y bajos para TF. En particular, TF ahora se fija en 0,01 en vez de 0,001, ya que al analizar la evolución de la búsqueda que efectúa el algoritmo, no encuentra mejores soluciones a temperaturas demasiado bajas, es decir, la solución final la obtiene mucho antes de que la temperatura llegue al nivel 0,001.

Tabla 5.4. Factores y niveles para experimento 3.

Parámetro	Valores
ALFA	0,98
T0	10; 1,5
TF	0,01
NT	10, 100, 1000
COMPLPROB	1, 2, 3

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- T0: Se decide experimentar con niveles más bajos para T0, considerando que en los experimentos anteriores este factor no tiene un efecto significativo en la calidad de las soluciones obtenidas.
- NT: De acuerdo a los resultados del primer experimento, este factor no tenía un efecto significativo (para los niveles considerados) en la calidad de la solución. Entonces, se eligen estos tres niveles, de manera de abarcar un amplio rango de valores para NT.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

Se decide efectuar un total de cuatro réplicas para este experimento.

Principales Resultados:

Mayor información sobre este experimento se presenta en anexo A2.3. Para un nivel de confianza del 95%, se tiene que, para los niveles considerados para cada factor, tienen un efecto significativo en el valor de la función objetivo los factores NT y COMPLPROB. Nuevamente, T0, para los niveles considerados, no tiene un efecto significativo en la calidad de las soluciones. Para el caso de NT, en este experimento se obtienen los mejores resultados con el nivel 10.

Como en los experimentos anteriores, Simulated Annealing obtiene soluciones de mejor calidad para los problemas de complejidad mediana y alta, como se observa en el gráfico de la figura 5.20.

La figura 5.5 muestra los gráficos de medias e intervalos de confianza para los factores de este experimento.

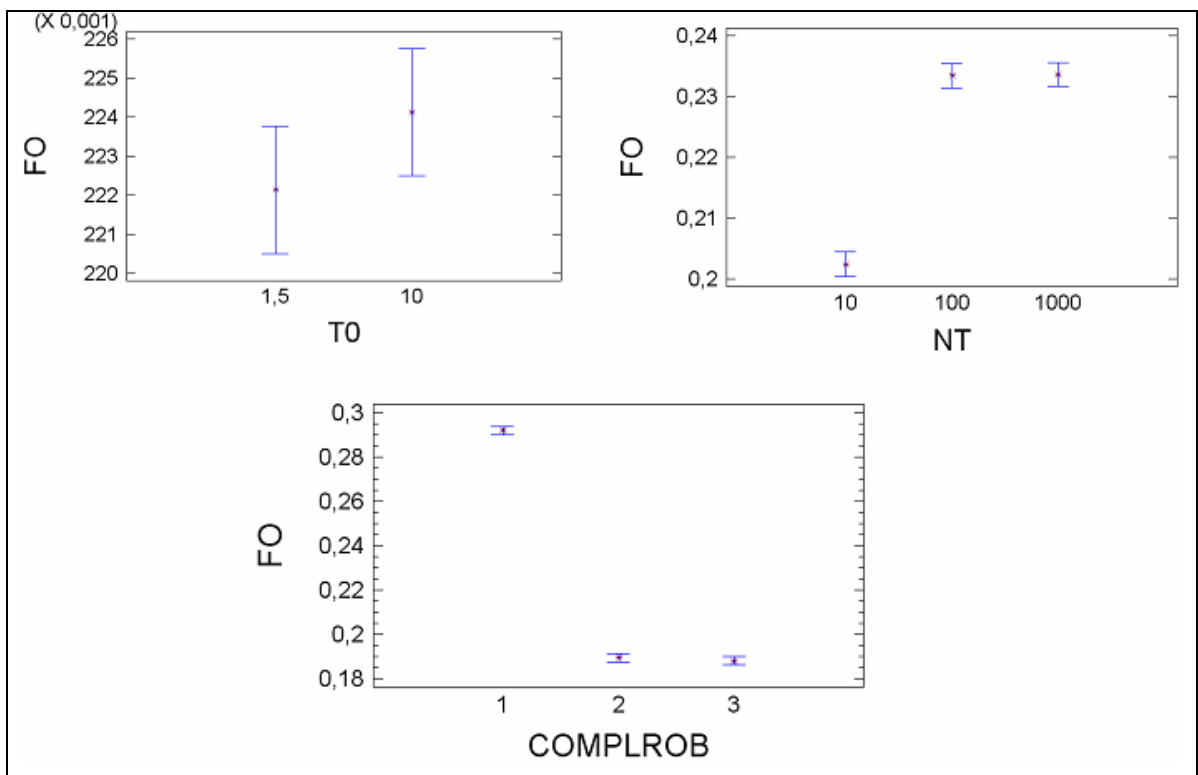


Figura 5.5. Gráficos de medias e intervalos de confianza para los factores de Experimento 3.

Analizando las interacciones entre los factores, se tiene que para un nivel de confianza del 95%, existe interacción significativa entre los factores NT y COMPLPROB, como se muestra en el gráfico de la figura 5.6, en el cual se observa que, de los tres niveles considerados para NT, el más adecuado para los tres tipos de problemas sería el nivel 10.




Figura 5.6. Gráfico de interacción de COMPLPROB versus NT.

Como conclusión general se puede mencionar que al parecer T_0 no influye significativamente en la calidad de las soluciones, y que valores bajos de NT serían lo más apropiado para los problemas de distinta complejidad.

Con el fin de tener mayor certeza en el valor seleccionado para ALFA, se decide diseñar un cuarto experimento, con un nuevo set de niveles para los factores.

5.2.2.4 Experimento 4

Selección de la variable respuesta:

Valor de la función objetivo (FO) que se obtiene al aplicar Simulated Annealing con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se muestran en la tabla 5.5. Dado que TF y NT tienen valores fijos en este experimento, no se consideran como factores, siendo éstos ALFA, T0 y COMPLPROB.

Tabla 5.5. Factores y niveles para experimento 4.

Parámetro	Valores
ALFA	0,98; 0,99; 0,999
T0	10; 1,5
TF	0,01
NT	10
COMPLPROB	1, 2, 3

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- ALFA: Se decide experimentar con estos niveles para este factor, con el fin de tener una mayor certeza de si se está eligiendo valores apropiados para ALFA.
- T0: Aunque según los resultados de los experimentos anteriores, T0 no tiene un efecto significativo en la calidad de la solución, se decide insistir con los niveles considerados en el experimento 3, con el fin de encontrar si existe alguna interacción con alguno de los demás factores.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

Se decide efectuar un total de cuatro réplicas para este experimento.

Principales Resultados:

Mayores detalles respecto a los resultados de este experimento, se presentan en anexo A2.4. Respecto al análisis de efectos principales, se tiene que, para un nivel de confianza del 95%, el factor ALFA no tiene un efecto significativo en la función objetivo. El factor T0 tampoco tiene un efecto significativo en la calidad de las soluciones.

En este experimento, sólo COMPLPROB tiene un efecto significativo en el valor de la función objetivo. La figura 5.7 presenta los gráficos de medias e intervalos de confianza para los factores considerados en este experimento.

Respecto a las interacciones entre los factores, se tiene que para un nivel de confianza del 95%, existe una interacción significativa entre los factores ALFA y COMPLPROB, como se puede observar gráficamente en la figura 5.8, la cual indica que sería apropiado un nivel de 0,99 para problemas de complejidad baja, y de 0,999 para problemas de complejidad media y alta.

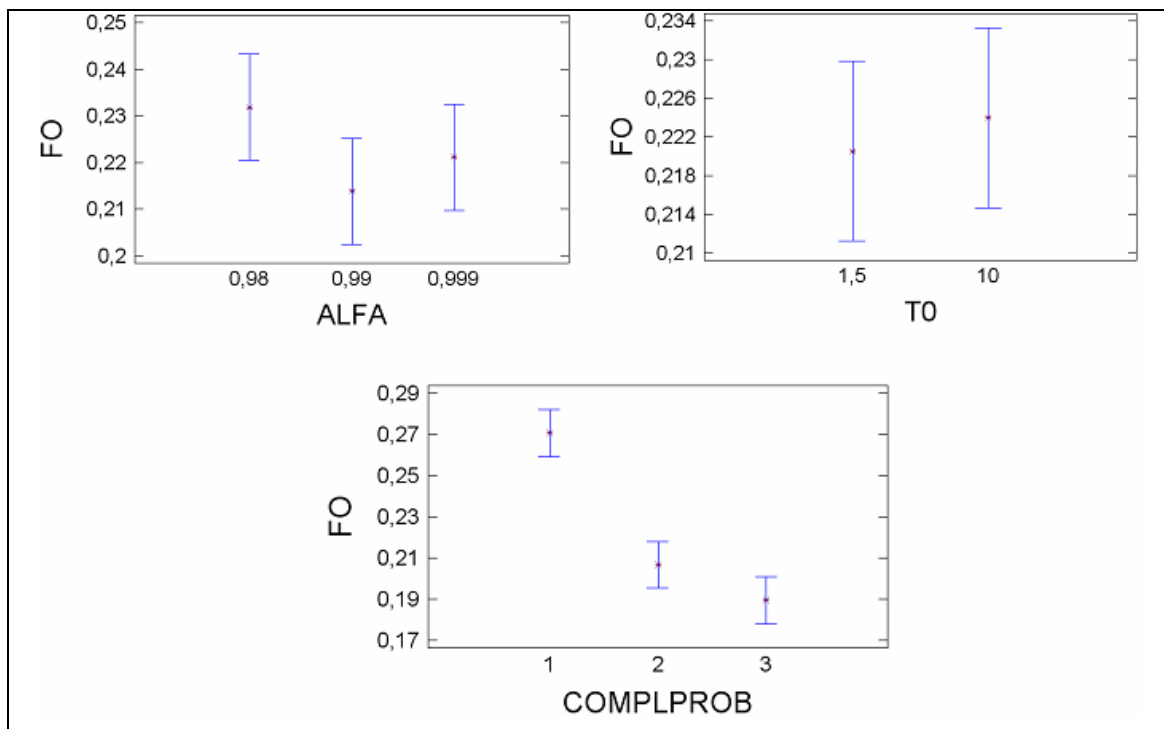


Figura 5.7. Gráfico de medias con intervalos de confianza para factores de Experimento 4.

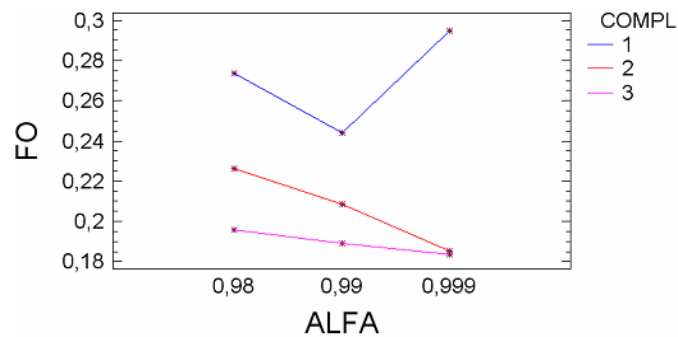


Figura 5.8. Gráfico de interacción entre COMPLPROB versus ALFA.

5.2.2.5 Experimento 5

Selección de la variable respuesta:

La variable respuesta en este experimento es el valor de la función objetivo (FO) que se obtiene al aplicar Simulated Annealing con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se presentan en la tabla 5.6. Dado que T0 y TF tienen valores fijos en este experimento, no se consideran como factores, siendo éstos ALFA, NT y COMPLPROB. El parámetro T0 se fija arbitrariamente en 10, debido a que en todos los experimentos anteriores T0 no tiene un efecto significativo en la calidad de la solución.

Tabla 5.6. Factores y niveles para experimento 5.

Parámetro	Valores
ALFA	0,98; 0,99
T0	10
TF	0,01
NT	10; 100; 500
COMPLPROB	1, 2, 3

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- ALFA: Se decide experimentar con estos niveles para este factor, ya que según el experimento anterior, un nivel de 0,99 sería el apropiado para los problemas de complejidad baja, media y alta, sin embargo, esto aumentaría demasiado el tiempo de ejecución, por lo que se agrega el nivel 0,98, que fue con el cual se obtuvieron mejores resultados en el primer experimento.
- NT: Los niveles para este factor, fueron seleccionados con el objetivo de determinar si existe interacción entre NT y el factor ALFA.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

Se decide efectuar un total de cuatro réplicas en este experimento.

Principales resultados:

El detalle del análisis de varianza para este experimento se encuentra en anexo A2.5. Para un nivel de confianza del 95%, los factores ALFA y NT no tienen un efecto significativo en la calidad de las soluciones. El factor COMPLROB sí tiene un efecto significativo en la función objetivo, tal como en los experimentos anteriores. La figura 5.9 presenta los gráficos de medias e intervalos de confianza correspondientes a este experimento.

Respecto al análisis de interacciones, se tiene que para un nivel de confianza del 95%, no existe interacción significativa entre los factores ALFA y NT (valor-p calculado de 0,8). Sin embargo, gráficamente pudiera pensarse de que existiría una interacción entre ambos factores, como se observa en el gráfico de interacción respectivo, presentado en la figura 5.10.

Por otra parte, existe interacción significativa entre los factores ALFA y COMPLPROB, y los factores NT y COMPLPROB, como lo muestran los gráficos correspondientes, en la figura 5.10.




Figura 5.9. Gráficos de medias e intervalos de confianza para los factores de Experimento 5.

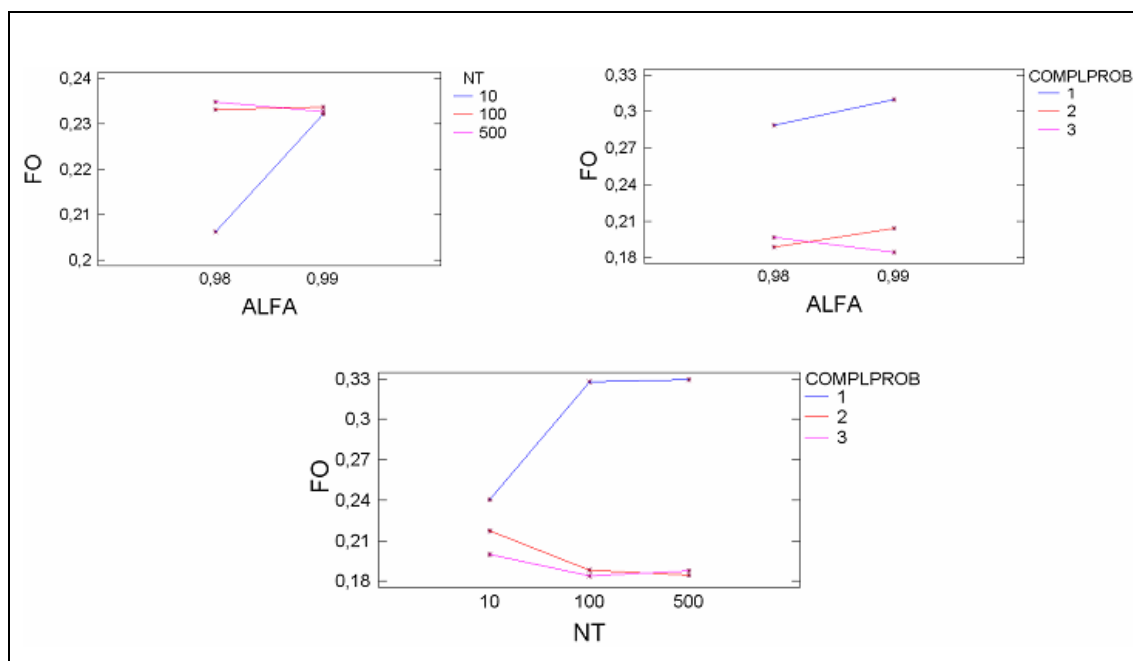


Figura 5.10. Algunos gráficos de interacción entre factores de Experimento 5.

5.2.2.6 Parámetros para Simulated Annealing

Considerando los resultados de los experimentos efectuados, se decide establecer de manera preliminar valores para los parámetros de Simulated Annealing, y son los que se muestran en la tabla 5.7:

Tabla 5.7. Parámetros preliminares para Simulated Annealing.

Parámetro	Valores
Parámetro α	0,98
Temperatura inicial	10
Temperatura final	0,01
Iteraciones para cada nivel de temperatura	10; 100

Según los resultados de los experimentos efectuados, no se encontró evidencia de que el parámetro de la temperatura inicial tuviese un efecto significativo en la calidad de las soluciones. La razón por la cual se decide fijar su valor en 10 se debe a que esta implementación de Simulated Annealing, aplicada a los problemas en estudio, obtiene en general mejores resultados con temperaturas bajas. Para comprender mejor esta situación, se debe recordar el funcionamiento de esta metaheurística, descrito en el capítulo 4. Sean s_i y $f(s_i)$ la solución actual almacenada y el valor de la función de evaluación asociado a esa solución, respectivamente, y s_j y $f(s_j)$ la nueva solución encontrada y el valor de la función de evaluación asociado. Simulated Annealing, en cada iteración busca una nueva solución, y si ésta es mejor que la que se tenía almacenada, se acepta como nueva solución y reemplaza a la anterior. Si la nueva solución encontrada es peor que la actual, es posible aceptarla, pero con una cierta probabilidad P . Más formalmente: Sea $\delta = f(s_j) - f(s_i)$; si $\delta < 0$, quiere decir que se encontró una solución con pérdida menor, por lo tanto se acepta, y ahora $s_i \leftarrow s_j$. Si $\delta > 0$, se debe generar un número $r \sim U[0,1]$, y si $r < P$, con $P(\delta, T) = \exp(-\delta \cdot 100/T)$, siendo T el nivel de temperatura, entonces se acepta esta solución, es decir, $s_i \leftarrow s_j$.

Analizando lo que sucedería con el comportamiento de δ para distintos valores de temperatura, se tiene que al trabajar con temperaturas altas, la probabilidad de aceptar soluciones peores P es también alta, como se presenta en el gráfico de la figura 5.11. Por esta razón es que, para esta implementación de Simulated Annealing, aplicada a los problemas estudiados, es recomendable trabajar con rangos de temperatura bajos, esto quiere decir, asignar valores bajos para la temperatura inicial, y especialmente para la temperatura final, ya que si se trabaja con rangos altos de temperatura, la probabilidad P apenas disminuirá. A modo de ejemplo, si se fija la temperatura inicial en 100, y la temperatura final en 10, significa que la probabilidad de aceptar una solución peor en que $\delta = 0,01$ (esto quiere decir, por ejemplo, saltar de una solución con 20% de pérdida a una con 21% de pérdida, o de una solución con 41% de pérdida a una con 42%) disminuirá apenas desde $P = 0,99$, a $P = 0,90$, lo cual provoca además de haya una alta variabilidad en la calidad de las soluciones finales encontradas por la metaheurística. En cambio, si por ejemplo se fija la temperatura inicial en 10 y la temperatura final en 0,01, la probabilidad de aceptación de soluciones peores, considerando $\delta = 0,01$, disminuirá de $P = 0,90$, a $P = 3,7 \cdot 10^{-44}$. Idealmente, debe lograrse que a medida que transcurre la búsqueda, la probabilidad de aceptar soluciones peores decrezca lo suficiente, lo cual se consigue al fijar temperaturas iniciales y finales bajas.

Respecto al número de iteraciones para cada nivel de temperatura (NT), eventualmente se requieren distintos valores dependiendo del problema a resolver. Por esta razón, se decidió aplicar la metaheurística a todo el conjunto de problemas de prueba, y evaluar qué valor es mejor para cada uno de ellos. Se diseñó un experimento factorial con dos factores: NT y tipo de problema. Mayor información sobre este experimento se presenta en anexo A2.6. Los resultados promedio para cada problema se muestran en tabla 5.8.




Figura 5.11. Probabilidad de aceptación de soluciones peores versus nivel de temperatura, para distintos valores de δ .

Tabla 5.8. Resultados promedio para problemas de prueba, para NT=10 y NT=100.

Problema	NT=10		NT=100	
	% Pérdida Promedio	Tiempo Promedio (s)	% Pérdida Promedio	Tiempo Promedio (s)
AP1	21,16%	4	20,01%	29
AP2	23,00%	5,2	32,93%	30,6
AP3	31,79%	4,2	32,93%	34,6
AM1	18,49%	6,2	18,86%	56,6
AM2	28,70%	5,8	20,53%	49,4
AM3	22,43%	7,4	18,33%	67
AM4	21,03%	6	32,08%	37,8
AM5	23,75%	7,2	18,88%	68,8
AM6	22,24%	11,4	20,76%	73,2
AG1	21,34%	10,6	18,80%	79,4
AG2	18,85%	8,8	18,67%	100,8

De acuerdo a los resultados del experimento realizado, el factor NT, por sí solo, no tiene un efecto significativo en la calidad de las soluciones. Sin embargo, sí lo tiene el tipo de problema que se está resolviendo. Además, existe interacción entre los factores NT y tipo de problema, es decir, para algunos problemas es más indicado el valor NT=10 y para otros se obtienen mejores resultados con NT=100, como en caso de los cuatro problemas de

mayor complejidad. Por otra parte, se ve claramente la influencia que tiene en el tiempo de ejecución el parámetro NT. Por lo tanto, si se tuviera que elegir un criterio para definir un único parámetro para todos los problemas, sería elegir el valor para NT con el cual obtienen mejores resultados para los problemas más complejos. Considerando esto, se determina que 100 es el valor adecuado para NT. Los parámetros definitivos se presentan en la tabla 5.9.

Para evaluar el desempeño de Simulated Annealing, y observar el modo en que converge a las soluciones, se volvió a ejecutar esta metaheurística, una vez, para todos los problemas de prueba.

Tabla 5.9. Parámetros definitivos para Simulated Annealing.

Parámetro	Valores
Parámetro	0,98
Temperatura inicial	10
Temperatura final	0,01
Iteraciones para cada nivel de temperatura	100

En el caso del problema AP1, se tiene que en esta prueba la metaheurística converge a una solución con pérdida de 20,13%, sin lograr alcanzar la mejor solución conocida para este problema, la cual tiene una pérdida de 18,73%. La figura 5.12 muestra el gráfico función objetivo versus temperatura para esta ejecución del algoritmo.




Figura 5.12. Gráfico Función Objetivo versus temperatura problema API.

Respecto al problema AP2, Simulated Annealing converge a una solución que presenta una pérdida de 32,51%, mientras que con la mejor solución conocida para este problema se tiene una pérdida de 18,68%. La figura 5.13 muestra la evolución de la función objetivo para este problema, en términos la temperatura.




Figura 5.13. Gráfico Función Objetivo versus temperatura problema AP2.

En el caso del problema AP3, la solución entregada por Simulated Annealing tiene una pérdida de 33,02%, mientras que con la mejor solución conocida para este problema se tiene una pérdida de 18,42%. La evolución de la búsqueda se presenta en la figura 5.14.

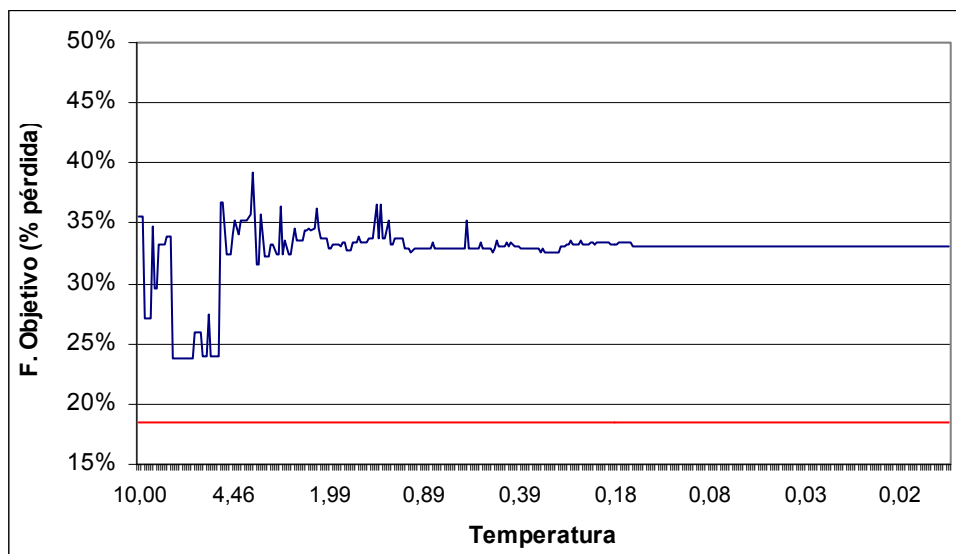


Figura 5.14. Gráfico Función Objetivo versus temperatura problema AP3.

Para el problema AM1, la metaheurística converge a una solución cuya pérdida es de 17,43%, logrando en esta ejecución superar a la mejor solución conocida para este problema, la cual tiene una pérdida de 18,00%. Esta situación se muestra gráficamente en la figura 5.15.

Respecto al problema AM2, Simulated Annealing converge a una solución cuya pérdida es de 18,16%. La mejor solución conocida para este problema tiene una pérdida de 17,88%. En la figura 5.16 se grafica la evolución de la función objetivo respecto a la temperatura para esta ejecución del algoritmo.




Figura 5.15. Gráfico Función Objetivo versus temperatura problema AM1.




Figura 5.16. Gráfico Función Objetivo versus temperatura problema AM2.

En cuanto al problema AM3, la metaheurística converge a una solución con pérdida de 18,54%, mientras que con la mejor solución conocida para este problema se tiene una pérdida de 17,96%, como se observa en la figura 5.17.




Figura 5.17. Gráfico Función Objetivo versus temperatura problema AM3.

Respecto al problema AM4, cuya mejor solución conocida tiene una pérdida de 18,52%, Simulated Annealing logra converger a una solución con pérdida de 21,57%. La evolución de la función objetivo con respecto a la temperatura para esta ejecución se presenta en la figura 5.18.

Para el problema AM5, la metaheurística converge a una solución con pérdida de 19,26%. Mientras que la mejor solución obtenida en este caso tiene una pérdida de 17,95%. Esta situación es presentada gráficamente en la figura 5.19.




Figura 5.18. Gráfico Función Objetivo versus temperatura problema AM4.

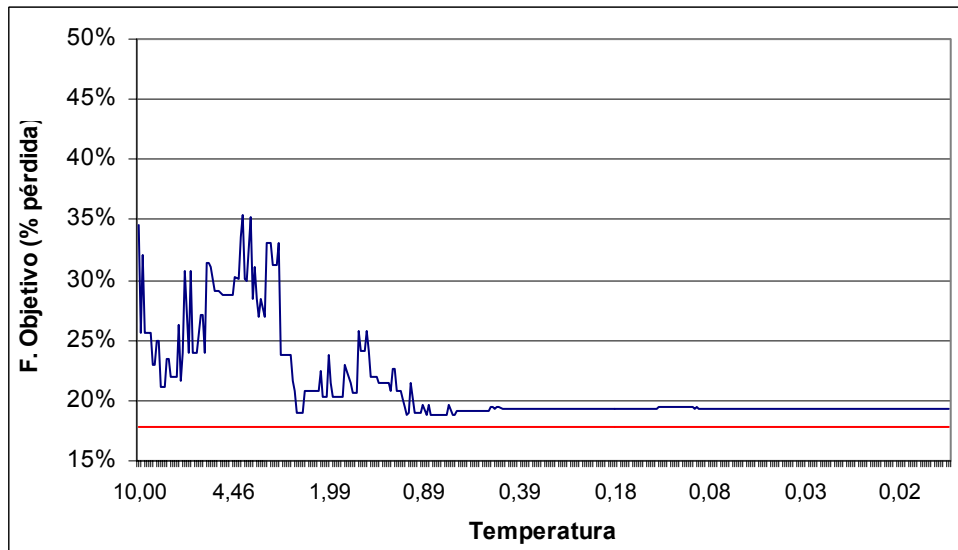


Figura 5.19. Gráfico Función Objetivo versus temperatura problema AM5.

En el caso del problema AM6, la solución final entregada por Simulated Annealing tiene una pérdida de 18,62%, mientras que la mejor solución conocida presenta una pérdida de 18,13%. La evolución de la búsqueda en términos de la pérdida porcentual en función de la temperatura se presenta en la figura 5.20.




Figura 5.20. Gráfico Función Objetivo versus temperatura problema AM6.

Para el problema AG1, Simulated Annealing logra encontrar una solución con pérdida de 18,31%. La mejor solución conocida para este problema presenta una pérdida de 17,88%. La figura 5.21 muestra una gráfica de la función objetivo versus la temperatura.

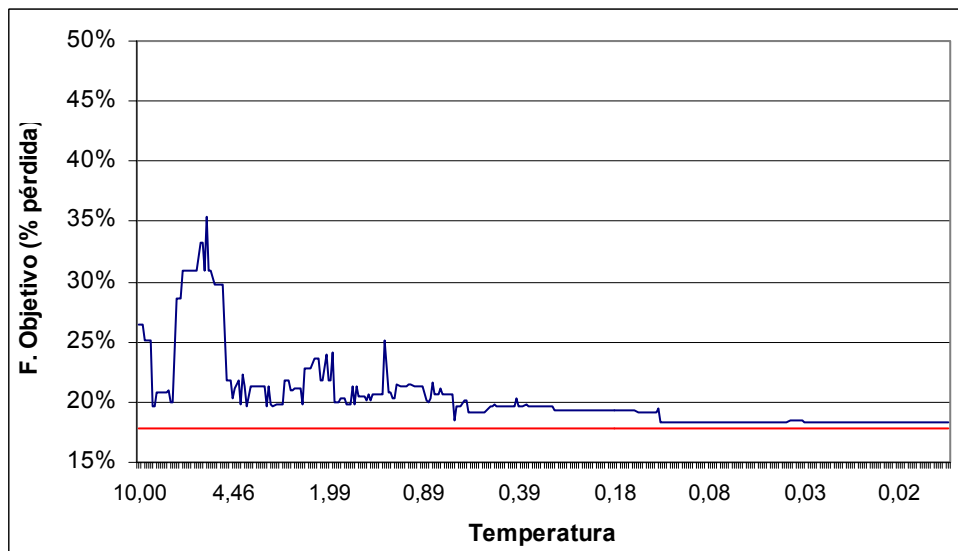


Figura 5.21. Gráfico Función Objetivo versus temperatura problema AG1.

Por último, en el caso del problema AG2, el algoritmo es capaz de encontrar una solución con una pérdida de 18,55%, mientras que la mejor solución conocida presenta una pérdida de 17,87%. Esta situación se presenta gráficamente en la figura 5.22.

En general se puede mencionar que Simulated Annealing converge a buenas soluciones, cercanas al 20% de pérdida, excepto para los problemas AP2 y AP3, para los cuales encuentra soluciones con pérdida superior a 30%, lo cual puede ser excesivo, dado que no se consideran factores que inciden en el rendimiento, como por ejemplo, el espesor de corte. Sin embargo, para los problemas de complejidad media y alta, esta metaheurística logra encontrar buenas soluciones.

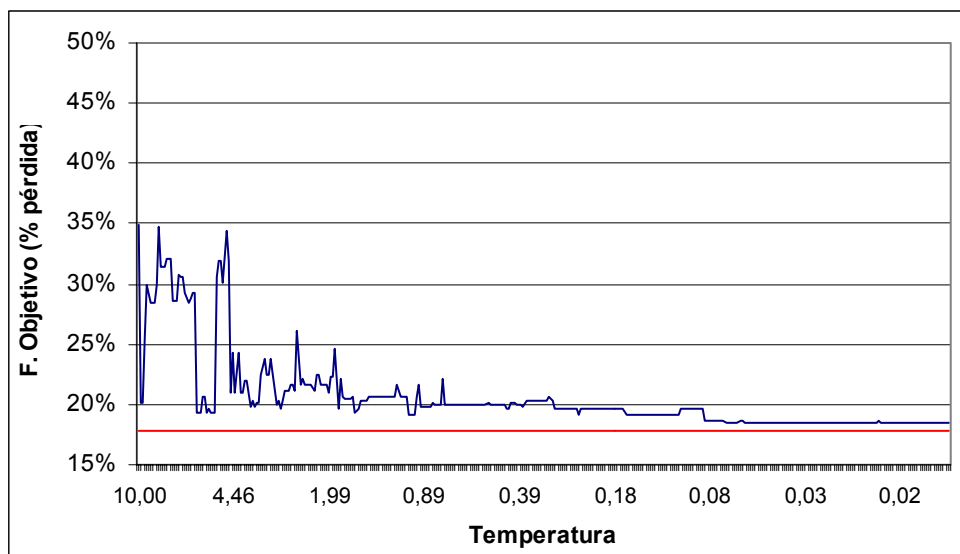


Figura 5.22. Gráfico Función Objetivo versus temperatura problema AG2.

5.2.3 Establecimiento de parámetros para el Algoritmo Genético

Con el objetivo de facilitar la tarea de definir valores adecuados para los parámetros del Algoritmo Genético implementado, se diseñó y efectuó una serie de experimentos multifactoriales, con varios niveles para cada factor. El objetivo es poder encontrar valores para los parámetros del Algoritmo Genético de manera de obtener buenas soluciones, es decir, soluciones para las cuales la función objetivo esté lo más cercano posible a la mejor solución conocida para los problemas de prueba, y en tiempos de ejecución razonable, en lo posible inferiores a 5 minutos, dado que es un problema que debe ser frecuentemente resuelto en la realidad. En estos experimentos, generalmente la variable respuesta es la calidad de la solución medida por el valor de la función objetivo asociado a la solución obtenida. Sin embargo, también se consideró en algunos casos como variable respuesta al tiempo de ejecución del algoritmo, con el fin de conocer el modo en que influyen los distintos factores en el tiempo de ejecución. En general, los factores considerados para los experimentos son:

- Probabilidad de mutación (PMUT).
- Probabilidad de cruzamiento (PCROSS).
- Tamaño de la Población (POPSIZE).
- Número de generaciones (NGENER).
- Tamaño del Problema (COMPLPROB).

Tanto PMUT como PCROSS pueden tomar valores entre 0 y 1. POPSIZE y NGENER pueden en teoría tomar cualquier entero positivo, pero se debe considerar la capacidad de memoria de la máquina y el tiempo de ejecución, ya que mientras mayor sea el valor de POPSIZE, implica trabajar con más soluciones a la vez, demandando más memoria y mayor tiempo de ejecución, y mientras mayor sea el valor de NGENER, implica también un mayor tiempo de ejecución.

5.2.3.1 Experimento 1

Selección de la variable respuesta:

En este experimento la variable respuesta corresponde al valor de la función objetivo (FO) que se obtiene al aplicar el Algoritmo Genético con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se muestran en la tabla 5.10.

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- **PMUT:** Se decide experimentar con un amplio rango de valores para este factor, ya que no se cuenta con información previa que entregue una guía acerca de los valores para este parámetro con los que se obtengan buenos resultados.
- **PCROSS:** De manera similar al caso anterior, dado que no se cuenta con información previa acerca de qué valores entregan buenos resultados, es que se decide experimentar con esos niveles.
- **POPSIZE:** Se decide experimentar con los niveles indicados, con el fin de confirmar la idea de que, a mayor número de individuos en la población, se trabaja con mayor número de soluciones a la vez, por lo que eso facilitaría el encontrar mejores soluciones.
- **NGENER:** Se seleccionaron esos niveles ya que eventualmente, al permitir un mayor número de generaciones, y por ende un mayor tiempo de ejecución, se podrían encontrar mejores soluciones.
- **COMPLPROB:** Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Tabla 5.10. Factores y niveles para experimento 1.

Parámetro	Valores
PMUT	0,2; 0,4; 0,6; 0,8.
PCROSS	0,2; 0,4; 0,6; 0,8.
POPSIZE	500; 1000; 1500; 2000.
NGENER	100; 200; 300; 400.
COMPLPROB	1, 2, 3

Número de réplicas:

El número de réplicas del experimento se fijó en tres, ya que de acuerdo a experimentaciones preliminares, la variabilidad de las soluciones obtenidas con el Algoritmo Genético es baja, para un mismo conjunto de valores para los parámetros.

Principales Resultados:

Mayores detalles respecto al análisis de efectos principales se encuentran en anexo A3.1. De acuerdo al análisis de varianza, en particular, respecto a los efectos principales, para un nivel de confianza de 95%, se tiene que todos los factores considerados tienen un efecto significativo en el valor de la función de evaluación. La figura 5.23 muestra los gráficos de medias e intervalos de confianza para los factores de este experimento.

Respecto a PMUT, se tiene que se obtienen mejores resultados con un nivel de 0,2. Por su parte, en el caso de PCROSS, se observa que los mejores valores de la función objetivo se obtienen en promedio para un nivel de 0,2, como se muestra en el gráfico respectivo.

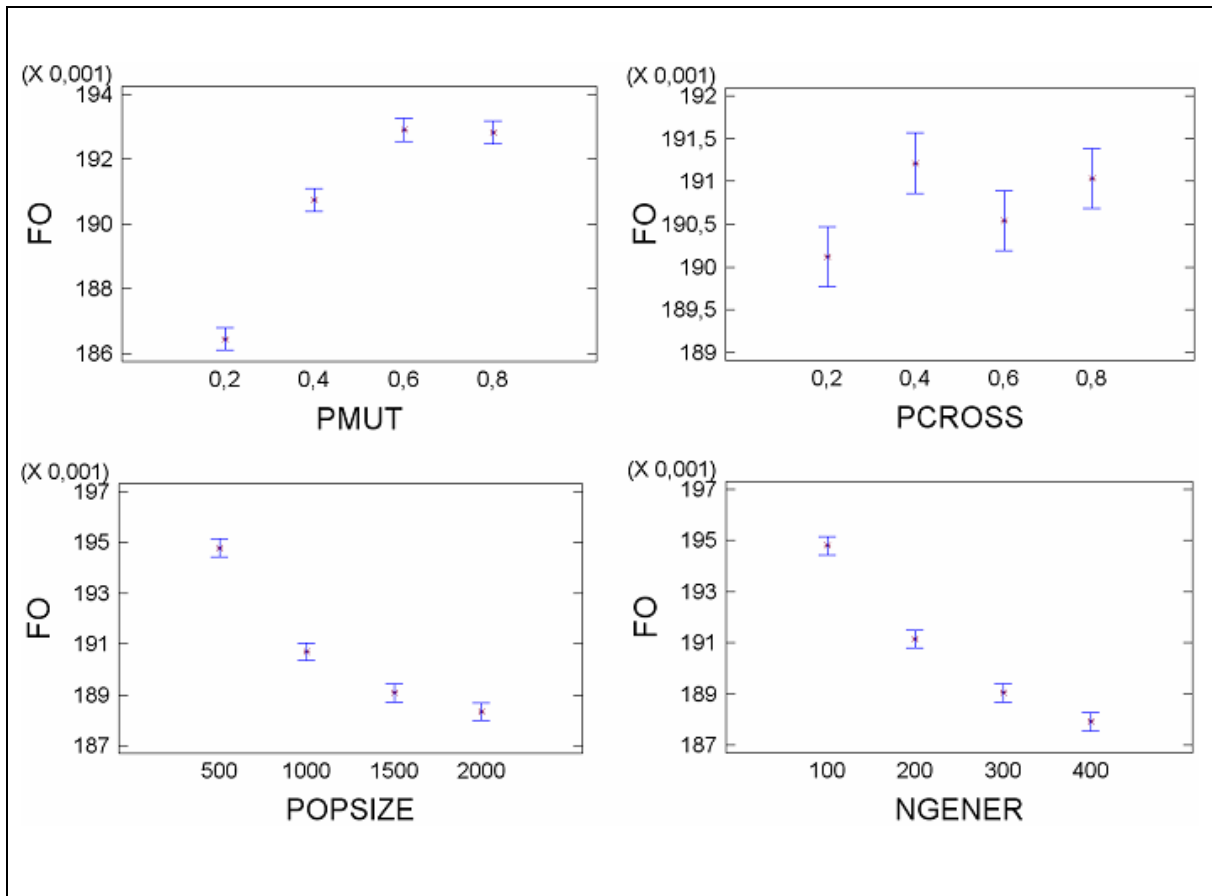


Figura 5.23. Gráfico de medias e intervalos de confianza para los factores de Experimento 1.

En el caso de POPSIZE y NGENER, se aprecia claramente que se obtienen mejores soluciones mientras mayor es su valor, en este caso, 2000 y 400, respectivamente.

En cuanto a las interacciones entre los factores, se tiene que, para un nivel de confianza de 95%, existe interacción significativa entre los factores PMUT y POPSIZE. Al analizar el gráfico de interacción, mostrado en la figura 5.24, se observa que a medida que POPSIZE aumenta y PMUT disminuye, mejora el valor de la función objetivo, sin embargo, se aprecia que al aumentar POPSIZE dejando PMUT constante, la “mejora marginal” de la función objetivo es cada vez menor.

Existe una interacción significativa entre los factores PMUT y NGENER, donde ocurre una situación similar al caso anterior, presentada en el gráfico respectivo de la figura 5.24.

De acuerdo al análisis de varianza, también existe interacción significativa entre los factores PMUT y COMPLPROB. En el gráfico respectivo, se observa que con el nivel 0,2 para PMUT se obtienen mejores resultados para los tres grados de complejidad.

Otra interacción significativa se produce entre los factores PCROSS y COMPLPROB. Al analizar el gráfico de interacción mostrado en la figura 5.24, no se observa claramente con qué niveles de PCROSS se pudiera obtener buenas soluciones.

Existe también interacción significativa entre los factores POPSIZE Y NGENER. Como se observa en el gráfico respectivo, presentado en la figura 5.24, se obtienen mejores soluciones mientras mayor sean POPSIZE y NGENER, sin embargo, para POPSIZE, la calidad de las soluciones tendería a estabilizarse para los niveles 1500 y 2000.

Además, de acuerdo al análisis de varianza existe interacción entre los factores POPSIZE y COMPLPROB. Al observar el gráfico de interacción, mostrado en la figura 5.24, se aprecia que en general, para los tres tipos de complejidad, valores altos de POPSIZE son apropiados.

Mayores detalles acerca del análisis de interacciones para este experimento se presentan en anexo A3.1.

En resumen, se puede concluir a partir de este experimento que con niveles bajos de PMUT y PCROSS, y niveles altos de POSIZE y NGENER se obtendrían mejores soluciones.

Se efectuó además un experimento con el fin de conocer la influencia de los factores en el tiempo de ejecución del Algoritmo Genético, cuyos resultados se presentan en anexo A3.1.

Dado que ya se conoce la forma en que POPSIZE y NGENER influyen en el valor de la función objetivo, se decide diseñar un nuevo experimento, dejando fijos los valores para estos dos parámetros.

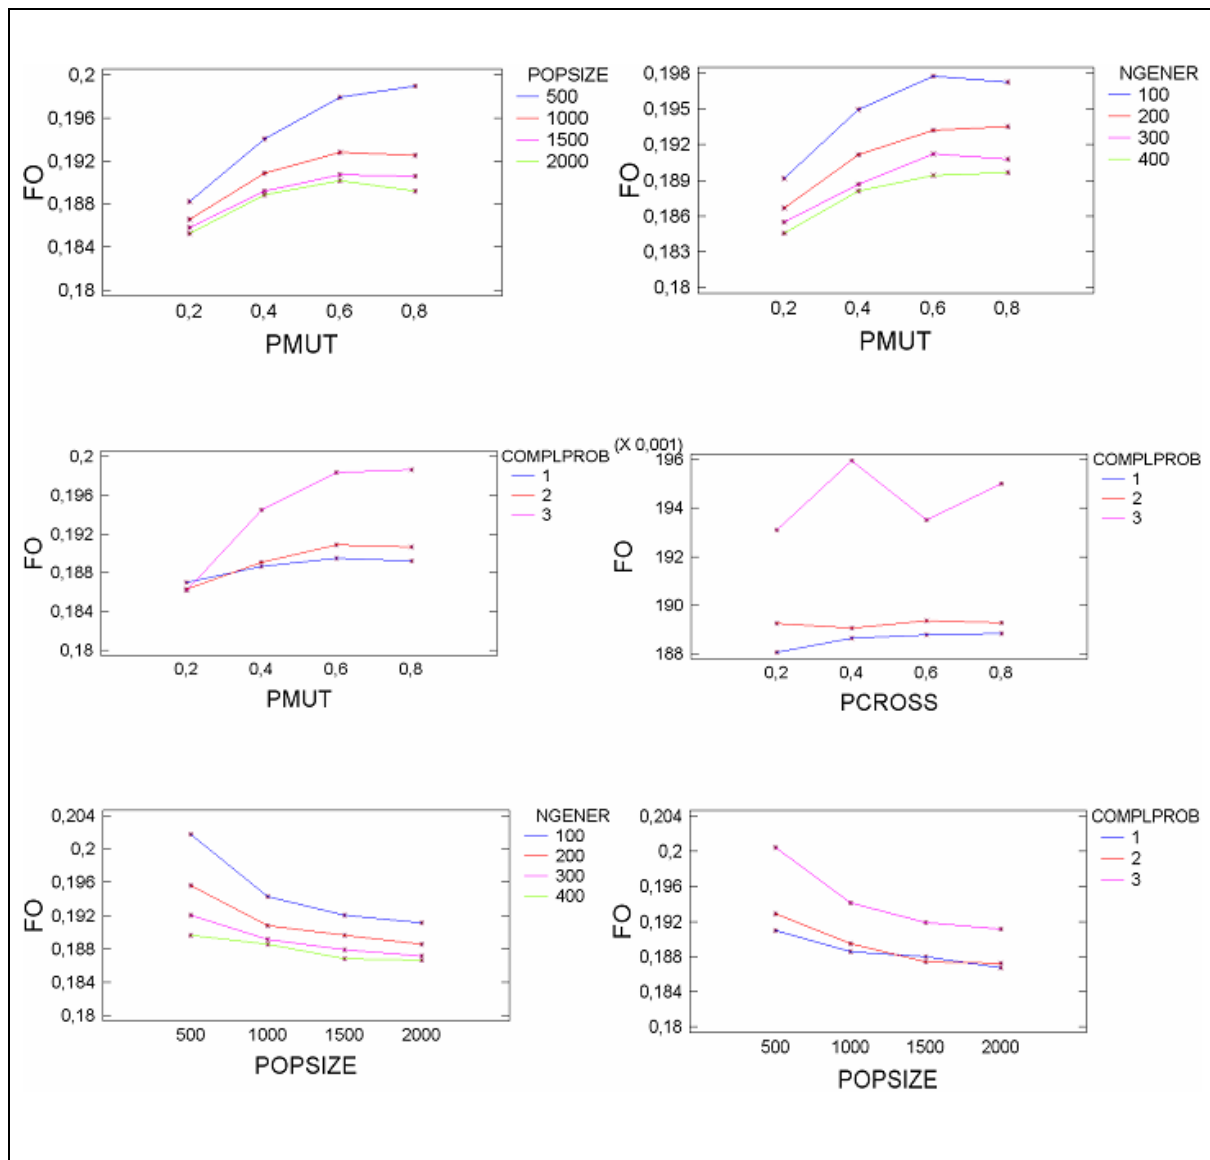


Figura 5.24. Algunos gráficos de interacción entre factores de Experimento 1.

5.2.3.2 Experimento 2

Selección de la variable respuesta:

Valor de la función objetivo (FO) que se obtiene al aplicar el Algoritmo Genético con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se muestran en la tabla 5.11. En este caso, POPSIZE y NGENER tienen valores fijos, por lo que no se los considera como factores en el experimento.

Tabla 5.11. Factores y niveles para experimento 2.

Parámetro	Valores
PMUT	0,05; 0,1
PCROSS	0,1; 0,3
POPSIZE	2000
NGENER	400
COMPLPROB	1, 2, 3

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- PMUT: En el primer experimento se concluyó que se obtenían mejores resultados con valores bajos de PMUT, por lo que se decide experimentar con niveles aún más bajos para este factor, y observar si se repite el mismo comportamiento.
- PCROSS: Una de las conclusiones del experimento 1 fue que se obtendrían buenos resultados con valores bajos de PCROSS. Por esta razón es que se decide probar con estos dos niveles, uno inferior a 0,2, que era el nivel con que se obtenían las mejores soluciones en el primer experimento, y otro nivel superior a 0,2.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

Se decide efectuar tres réplicas en este experimento.

Principales Resultados:

Según el análisis de efectos principales, con un nivel de confianza de 95%, PMUT y COMPLPROB tienen un efecto estadísticamente significativo en el valor de la función

objetivo. Por otra parte, no hay evidencia de que PCROSS tenga un efecto significativo en la calidad de las soluciones, dados los niveles considerados para este factor. Mayores detalles sobre el análisis de efectos principales para este experimento se encuentran en anexo A3.2. La figura 5.25 presenta los gráficos de medias e intervalos de confianza para los factores considerados en este experimento.

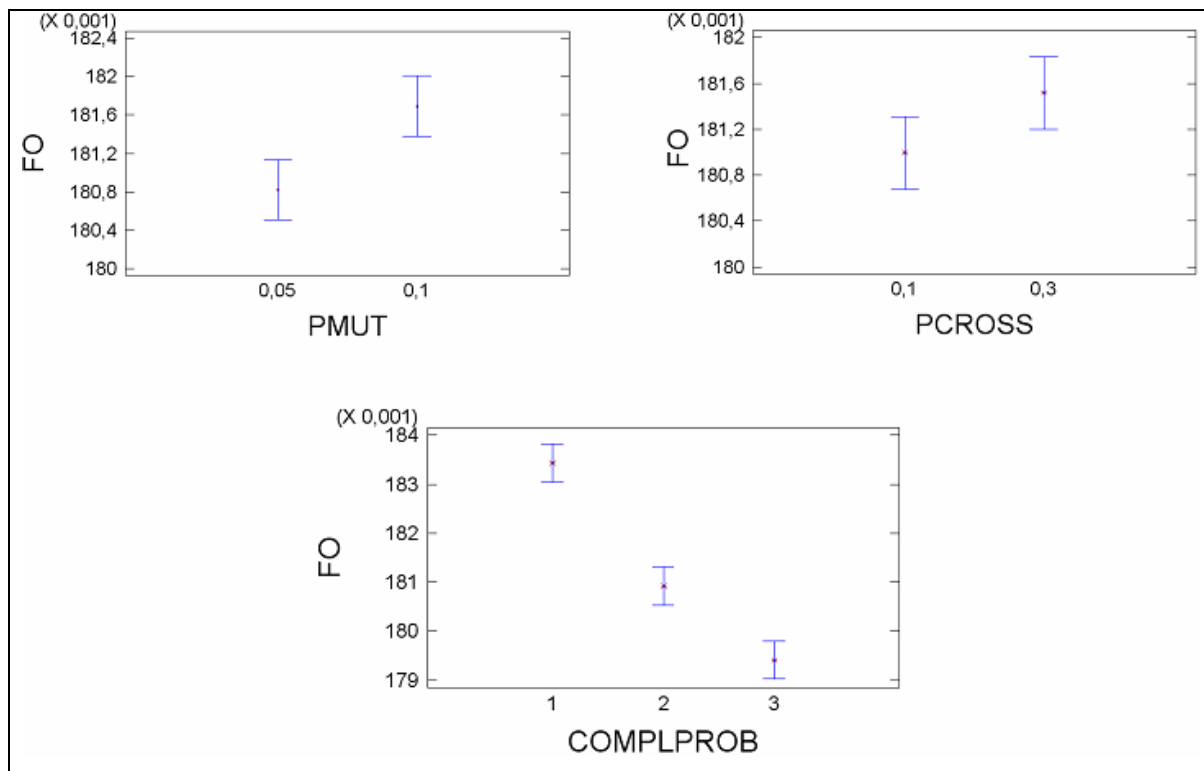


Figura 5.25. Gráficos de medias e intervalos de confianza para los factores de Experimento 2.

Respecto a las interacciones entre los factores, dado que todos los valores-p son mayores que 0,05, como se presenta en anexo A3.2, no hay evidencia para afirmar que existan interacciones significativas.

En resumen, se puede decir que con un valor de 0,05 para PMUT, se obtienen mejores valores para la función objetivo. Sin embargo, en el caso de PCROSS, aún no se tiene claridad respecto a los valores más apropiados. Por esta razón es que se decide realizar un tercer experimento.

5.2.3.3 Experimento 3

Selección de la variable respuesta:

La variable respuesta en este experimento es el valor de la función objetivo (FO) que se obtiene al aplicar el Algoritmo Genético con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se muestran en la tabla 5.12.

Tabla 5.12. Factores y niveles para experimento 3.

Parámetro	Valores
PMUT	0,01; 0,05; 0,1
PCROSS	0,1; 0,3
POPSIZE	500; 1000
NGENER	100; 200
COMPLPROB	1, 2, 3

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- PMUT: Dado que en los primeros dos experimentos se concluyó que se obtenían mejores resultados con valores bajos de PMUT, se decide experimentar con niveles aún más bajos para este factor, con el fin de observar si se repite el mismo comportamiento.
- PCROSS: Una de las conclusiones del experimento 1 fue que se obtendrían buenos resultados con valores bajos de PCROSS. Por esta razón es que se decide probar con estos dos niveles, uno inferior a 0,2, que era el nivel con que se obtenían las mejores soluciones en el primer experimento, y otro nivel superior a 0,2. Se trata de los mismos niveles considerados para este factor en el experimento 2, porque se desea buscar si PCROSS tiene un efecto significativo, dadas las condiciones del presente experimento.
- POPSIZE: Si bien se tiene claridad respecto del efecto de POPSIZE en la calidad de las soluciones, se decide seleccionar dos niveles para este factor, principalmente para observar interacciones con otros factores.

- NGENER: Si bien se tiene claridad respecto su efecto en las soluciones obtenidas, se decide seleccionar dos niveles para este factor, por la misma razón que en el caso de POPSIZE.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

El número de réplicas del experimento se fijó en tres.

Principales Resultados:

Para un nivel de confianza de 95%, de acuerdo al análisis de varianza no hay efectos principales significativos, ni interacciones significativas entre los distintos factores. Mayores detalles acerca de este experimento, se presentan en anexo A3.3.

Considerando los resultados del experimento actual y de los anteriores, es posible comenzar a definir valores para algunos de los parámetros del Algoritmo Genético. Si el objetivo es obtener buenas soluciones, entonces es necesario utilizar valores bajos de PMUT, por ejemplo 0,05, y valores altos de NGENER y POPSIZE. Sin embargo, para PCROSS aún no hay claridad respecto a qué valores son apropiados para este parámetro. Por esta razón es que se decide diseñar un cuarto experimento.

5.2.3.4 Experimentos 4 y 5

Con el objetivo de poder determinar valores apropiados para PCROSS, se diseñaron dos experimentos, 4 y 5. En ambos casos no fue posible encontrar evidencia de que PCROSS tuviese un efecto significativo en la calidad de la solución. El detalle de los experimentos 4 y 5, se presentan en los anexos A3.4 y A3.5, respectivamente.

5.2.3.5 Parámetros para Algoritmo Genético

Los valores definitivos para los parámetros de la implementación de Algoritmos Genéticos aplicada en este estudio, fueron seleccionados tomando en consideración los resultados de los experimentos realizados. Estos valores se presentan en la tabla 5.13.

Tabla 5.13. Valores para los parámetros del Algoritmo Genético.

Parámetro	Valores
Probabilidad de mutación	0,05
Probabilidad de cruzamiento	0,6
Tamaño de Población	1500
Número de generaciones	*

Para la probabilidad de mutación se establece un valor bajo, en este caso 0,05, debido a que en los experimentos se obtuvieron buenas soluciones con este valor. Respecto a la probabilidad de cruzamiento se eligió arbitrariamente el valor 0,6, ya que en los experimentos realizados no se encontró evidencia de que este parámetro influya significativamente en la calidad de las soluciones obtenidas. El tamaño de la población se fijó en 1500, ya que, según resultados del experimento 1, sobre ese valor la calidad de las soluciones tiende a estabilizarse. Finalmente, para el caso del número de generaciones, no se tiene un valor definido, sino que éste debe ser fijado teniendo en cuenta los recursos del sistema con que se está trabajando, y el tiempo que sea posible esperar para obtener una solución, ya que si bien a mayor número de generaciones se obtienen mejores soluciones, se consume también mayor tiempo de ejecución.

Con el fin de confirmar que los valores para los parámetros del Algoritmo Genético son apropiados, se evaluó el desempeño del algoritmo aplicándolo una vez a todos los problemas de prueba considerados. Los valores seleccionados para los parámetros del Algoritmo Genético se muestran en la figura 5.66. Mayores detalles sobre estas pruebas se encuentran en anexo A3.6.

Tabla 5.14. Parámetros utilizados para evaluar desempeño de Algoritmo Genético.

Parámetro	Valor
Probabilidad de cruzamiento	0,6
Probabilidad de mutación	0,05
Tamaño de la Población	1500
Número de Generaciones	4000

Se tiene que para todos los problemas de prueba, a excepción de los problemas AM2, AM5 y AG1, el Algoritmo Genético logra superar a la mejor solución conocida para el problema.

Para el caso del problema AP1, la metaheurística rápidamente alcanza la mejor solución conocida para el problema, la cual tiene una pérdida de 18,73%. Específicamente, en la generación 24, el Algoritmo Genético logra superar esta solución. La figura 5.26 muestra el gráfico Función Objetivo versus número de generaciones para AP1. La solución final obtenida corresponde a una pérdida de 18,25%.




Figura 5.26. Gráfico Función Objetivo versus número de generaciones para problema AP1.

Respecto al problema AP2, el Algoritmo Genético logra superar a la mejor solución conocida en la generación 54. La figura 5.27 muestra la evolución de la función objetivo para este problema, en términos del número de generaciones. La solución final obtenida para este problema corresponde a una pérdida de 18,18%.




Figura 5.27. Gráfico Función Objetivo versus número de generaciones para problema AP2.

En el caso del problema AP3, el Algoritmo Genético logra encontrar una solución superior a la mejor solución conocida para este problema (con pérdida de 18,42%) en la generación 119. La solución encontrada por el algoritmo tiene una pérdida de 18,02%, como se presenta en la figura 5.28.




Figura 5.28. Gráfico Función Objetivo versus número de generaciones para problema AP3.

Para el problema AM1, se logra rápidamente superar a la mejor solución conocida (con una pérdida de 18,00%) en la generación 21. La mejor solución obtenida en este caso es de 17,33%. La evolución de la función objetivo respecto al número de generaciones se muestra en la figura 5.29.

Respecto al problema AM2, se tiene que no logra alcanzar la mejor solución conocida, la cual tiene una pérdida de 17,88%. La mejor solución que el Algoritmo Genético logra obtener tiene una pérdida de 17,92%. En la figura 5.30 se grafica la evolución de la función objetivo respecto al número de generaciones.




Figura 5.29. Gráfico Función Objetivo versus número de generaciones para problema AM1.

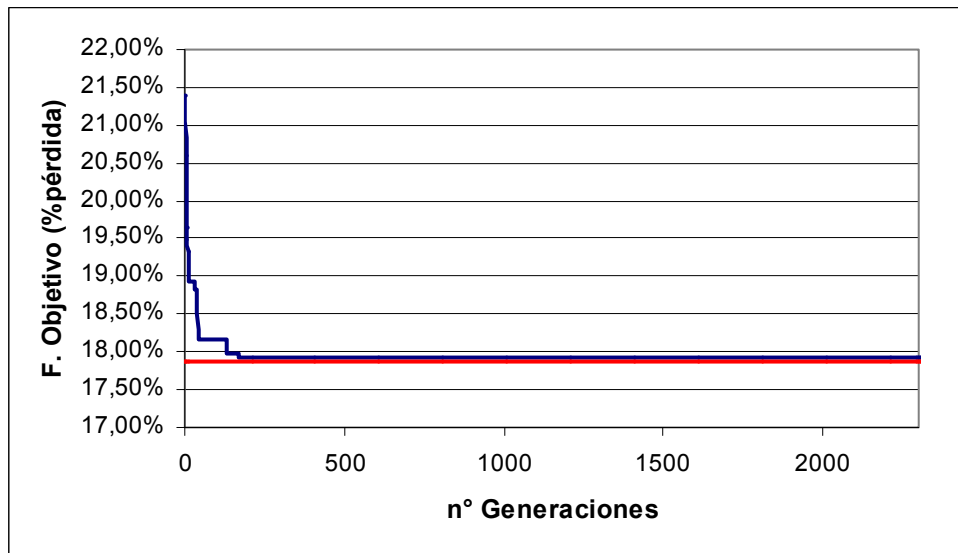


Figura 5.30. Gráfico Función Objetivo versus número de generaciones para problema AM2.

En cuanto al problema AM3, se logra alcanzar una solución superior a la mejor conocida, la cual tiene una pérdida de 17,96% en la generación 410. La mejor solución obtenida por el Algoritmo Genético tiene una pérdida de 17,72%. En la figura 5.31 se grafica la evolución de la función objetivo respecto al número de generaciones.




Figura 5.31. Gráfico Función Objetivo versus número de generaciones para problema AM3.

Respecto al problema AM4, cuya mejor solución conocida tiene una pérdida de 18,52%, se tiene que ésta es superada en la generación 530. Con la solución final obtenida en esta prueba se tiene una pérdida de 18,28%. La evolución de la función objetivo con respecto al número de generaciones para este problema se muestra en la figura 5.32.




Figura 5.32. Gráfico Función Objetivo versus número de generaciones para problema AM4.

Para el problema AM5, el Algoritmo Genético no es capaz de encontrar una solución superior a la mejor conocida, la cual presenta una pérdida de 17,85%. La mejor solución obtenida en este caso tiene una pérdida de 17,95%. La figura 5.33 muestra la evolución de la función objetivo versus el número de generaciones.

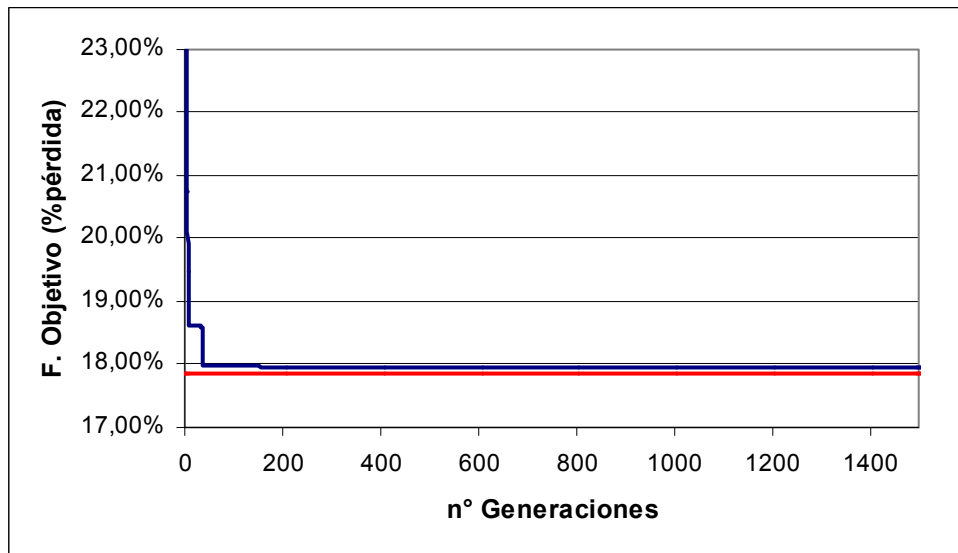


Figura 5.33. Gráfico Función Objetivo versus número de generaciones para problema AM5.

En el caso del problema AM6, el Algoritmo Genético rápidamente logra encontrar una solución superior a la mejor conocida (con una pérdida de 18,13%) en la generación 29. La mejor solución obtenida tiene un pérdida de 17,97%. La evolución de la función objetivo respecto al número de generaciones se muestra en la figura 5.34.




Figura 5.34. Gráfico Función Objetivo versus número de generaciones para problema AM6.

Para el problema AG1, si bien no se logra alcanzar la mejor solución conocida para este problema, la cual presenta una pérdida de 17,883%, el Algoritmo Genético encontró una solución con pérdida de 17,887%, muy cercana a la mejor conocida. En la figura 5.35 se muestra una gráfica de la función objetivo versus el número de generaciones.




Figura 5.35. Gráfico Función Objetivo versus número de generaciones para problema AG1.

Finalmente, para el problema AG2, el algoritmo es capaz de encontrar una solución con una pérdida de 17,84%, superior a la mejor solución conocida, la cual presenta una pérdida de 17,87%. Esta situación se presenta gráficamente en la figura 5.36.

En general se puede mencionar que el Algoritmo Genético converge rápidamente a buenas soluciones, sean éstas cercanas o superiores a la mejor solución conocida. Se puede decir entonces que se ha cumplido con el objetivo de los experimentos realizados, ya que se determinaron valores apropiados para los parámetros del algoritmo de forma de obtener soluciones cercanas a la mejor solución conocida.




Figura 5.36. Gráfico Función Objetivo versus número de generaciones para problema AG2.

5.3 Resultados promedio para Simulated Annealing

Los resultados promedio considerados para Simulated Annealing corresponden a las cinco ejecuciones para cada problema de prueba con los valores establecidos para los parámetros de la metaheurística. Estos resultados se presentan en la figura 5.15, y con mayor detalle en anexo A4.1.

Tabla 5.15. Resultados promedio Simulated Annealing para problemas de prueba.

Problema	Pérdida Promedio (%)	Mejor Solución Conocida	Tiempo Promedio (s)
AP1	20,01%	18,73%	29
AP2	32,93%	18,68%	30,6
AP3	32,93%	18,42%	34,6
AM1	18,86%	18,00%	56,6
AM2	20,53%	17,88%	49,4
AM3	18,33%	17,96%	67
AM4	32,08%	18,52%	37,8
AM5	18,88%	17,85%	68,8
AM6	20,76%	18,13%	73,2
AG1	18,80%	17,88%	79,4
AG2	18,67%	17,87%	100,8

Como se puede observar, Simulated Annealing logra encontrar soluciones con pérdidas en promedio cercanas al 20% para los problemas de prueba, a excepción de los AP2, AP3 y AM4, para los cuales obtiene soluciones con pérdida en promedio superior a 30%, lo cual puede ser excesivo, dado que no se consideran factores como por ejemplo, el espesor de corte, el cual incide negativamente en el rendimiento. Sin embargo, y como se menciona en secciones anteriores, para los problemas de complejidad media y alta, esta metaheurística logra encontrar buenas soluciones y en tiempos de ejecución razonables, inferiores a 2 minutos, en el caso de los problemas de mayor tamaño.

5.4 Resultados promedio para Algoritmo Genético

Los resultados para la implementación de Algoritmos Genéticos se obtuvieron al ejecutar cinco veces el algoritmo para cada problema de prueba, y estableciendo el número de generaciones en 1300, ya que en general, cuando alcanza la mejor solución conocida para alguno de los problemas de prueba, lo logra antes de 1300 generaciones. Los resultados promedio se muestran en la tabla 5.16. Mayor información sobre esta prueba se encuentra en anexo A4.2. Se observa que en promedio el Algoritmo Genético supera la mejor solución conocida para los problemas de prueba, a excepción de los problemas AM2 y AM5. Si bien los tiempos de ejecución promedio están entre 1426 y 2190 segundos (23,8 y 36,5 minutos), se tiene que en general el Algoritmo Genético obtiene buenas soluciones (inferiores a 20% de pérdida) en tiempos muy inferiores.

Tabla 5.16. Resultados promedio obtenidos por el Algoritmo Genético para todos los problemas de prueba.

Problema	Pérdida Promedio (%)	Mejor Solución Conocida	Tiempo promedio (s)
AP1	18,48%	18,73%	1426,6
AP2	18,33%	18,68%	1766,0
AP3	18,06%	18,42%	1964,4
AM1	17,41%	18,00%	2064,4
AM2	17,98%	17,88%	2103,8
AM3	17,87%	17,96%	1966,8
AM4	18,44%	18,52%	2150,4
AM5	17,95%	17,85%	2081,2
AM6	18,07%	18,13%	2190,2
AG1	17,88%	17,88%	2167,0
AG2	17,85%	17,87%	2114,8

5.5 Comparación entre ambos algoritmos

Ya evaluado el desempeño individual tanto de Simulated Annealing como del Algoritmo Genético, interesa establecer cuál de los dos métodos implementados presenta un mejor comportamiento para el problema en estudio. De acuerdo a los resultados presentados en secciones anteriores, el Algoritmo Genético supera a Simulated Annealing en el sentido de que es capaz de encontrar soluciones que entreguen un rendimiento de la materia prima superior a la mejor solución conocida para la mayoría de los problemas de prueba, al ejecutarlo durante un tiempo suficiente, manipulando el tamaño de la población o el número de generaciones. Esto no ocurre en el caso de la implementación de Simulated Annealing utilizada en este estudio, ya que como se ha mencionado, el darle un mayor tiempo de ejecución no garantiza que obtenga mejores soluciones.

Queda entonces efectuar una última comparación, la cual consiste en evaluar el desempeño de ambos algoritmos para un mismo tiempo de ejecución. Para esto, se ejecutó cinco veces cada problema de prueba con ambas metaheurísticas. Para fijar el tiempo de ejecución, se configuró al Algoritmo Genético de manera que su tiempo de ejecución sea similar al de Simulated Annealing corriendo con los valores establecidos para sus parámetros.

Se diseñó un experimento multifactorial, con dos factores (Heurística utilizada y Tipo de Problema); los niveles para el factor Heurística son dos: Simulated Annealing y Algoritmo Genético; los niveles considerados para el tipo de problema son once y corresponden a cada problema de prueba. Los resultados de este experimento se presentan con mayor detalle en anexo A4.3.

Se tiene que, para un 95% de confianza, tanto la heurística utilizada como el problema que se está resolviendo tienen un efecto significativo en el valor de la función objetivo. Respecto a la heurística utilizada, como se observa gráficamente en la figura 5.37, con el Algoritmo Genético es posible obtener en promedio mejores soluciones que con Simulated Annealing.




Figura 5.37. Gráfico de medias e intervalos de confianza para los niveles del factor Heurística.

El problema a resolver tiene también un efecto significativo en el valor de la función objetivo, como se observa en la figura 5.38. En general, para los problemas AM4, AP2 y AP3 se encuentran soluciones inferiores a las del resto de los problemas de prueba, sin embargo, como se verá más adelante, esto se debe a la interacción entre los factores Heurística y Problema, ya que Simulated Annealing es la metaheurística que obtiene soluciones con pérdidas mayores para los problemas mencionados.

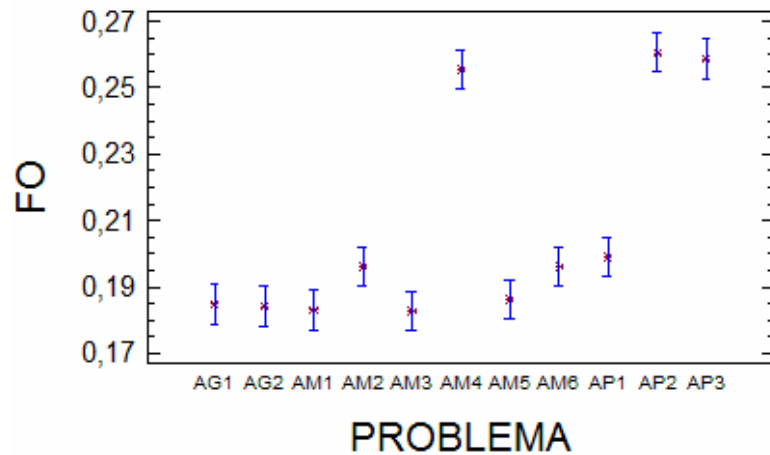


Figura 5.38. Gráfico de medias e intervalos de confianza para los niveles del factor Problema.

Respecto a las interacciones entre los factores, según el análisis de varianza realizado, el cual se presenta en anexo A4.3, sí existe interacción significativa entre la heurística utilizada y el problema en el cual se aplica. Lo que se observa en el gráfico de la figura 5.39, es que el Algoritmo Genético presenta resultados similares para todos los problemas de prueba considerados, a diferencia de Simulated Annealing, que para los problemas AP2, AP3 y AM4 encuentra soluciones con una pérdida promedio superior al 30%.

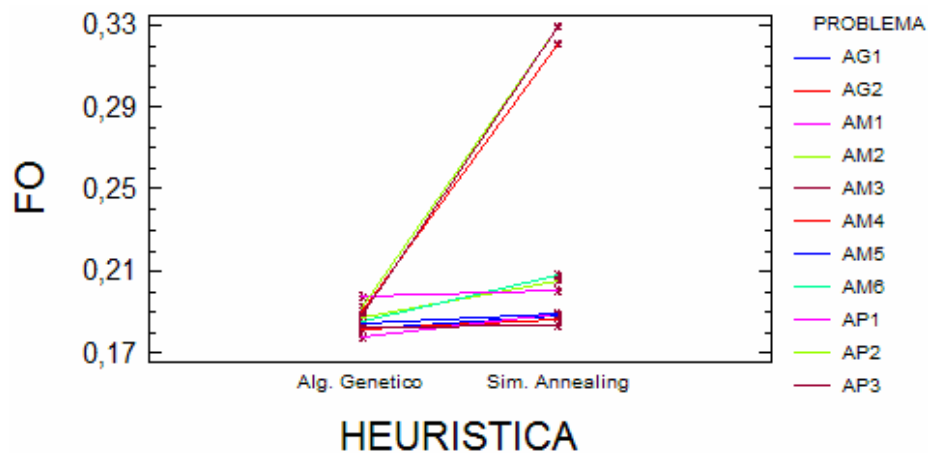


Figura 5.39. Gráfico de interacciones para el factor Heurística versus problema a resolver.

Por lo tanto, de acuerdo a los resultados obtenidos, el Algoritmo Genético es capaz de encontrar mejores soluciones que Simulated Annealing, considerando el mismo tiempo de

ejecución, se puede decir entonces que la implementación de Algoritmos Genéticos es superior a la implementación de Simulated Annealing, dadas las condiciones establecidas para este estudio, es decir, dados los valores de los parámetros utilizados para cada metaheurística.

CAPÍTULO 6. CONCLUSIONES

En el presente estudio se han propuesto e implementado dos algoritmos metaheurísticos para la optimización de los esquemas de corte en aserraderos. Ambos métodos constan de dos partes principales, una función constructora, capaz de generar soluciones factibles para el problema, es decir, un conjunto de esquemas de corte que permitan satisfacer los pedidos, y una metaheurística, que en este caso corresponde a Simulated Annealing y Algoritmos Genéticos, las cuales se encargan de efectuar la búsqueda en el espacio de solución.

Dadas las condiciones de la materia prima y las piezas, el problema de corte de rollizos se puede clasificar como un problema de corte de piezas irregular tridimensional. Una de las mayores dificultades que presentan los problemas de corte irregular es el manejar la compleja geometría tanto de las piezas como de las formas stock donde éstas se ubicarán. Sin embargo, para este estudio se ha simplificado la forma de los rollizos, describiéndolos en base a dos parámetros, extremo de diámetro menor y largo, y además se aprovecharon las características particulares del proceso de corte en un aserradero, en el sentido de que piezas con determinadas características sólo pueden ser obtenidas desde zonas específicas del rollizo (por ejemplo, las piezas de mayor valor deben obtenerse de la zona periférica del trozo), y los cortes deben ser tipo guillotina, por lo que los esquemas de corte o “layouts” generados deben ser ortogonales. Además, el manejo de la posible rotación de las piezas es simple, ya que sólo existen dos formas de ubicar una pieza, en sentido horizontal, en el caso de las zonas superior, inferior y central del rollizo, y vertical, en el caso de las zonas derecha e izquierda.

La solución propuesta pretende ser una herramienta de apoyo para la programación de la producción en un aserradero. Actualmente, esta tarea se realiza manualmente, basándose principalmente en la experiencia y en información histórica referente a esquemas de corte utilizados. Se trata de un modelo general, en el cual distintos aspectos deben ser modificados para su aplicación en un aserradero particular. Tal es el caso del número

máximo de laterales y centrales que es posible obtener, lo que depende de las características tecnológicas de cada aserradero.

Como todo modelo de optimización, presenta limitaciones las cuales deben ser consideradas al momento de aplicarse. Entre éstas se encuentran, además de la simplificación realizada a la forma de los rollizos, el no considerar la calidad de éstos. Otra limitación importante es la clasificación que se hace a los tipos de piezas que se obtienen, distinguiéndose sólo piezas laterales y centrales, dependiendo de la zona del rollizo desde donde deben ser obtenidas, debido a la calidad requerida. En la realidad, la clasificación de las piezas puede ser mucho más extensa.

Al aplicar el algoritmo basado en Simulated Annealing, si bien no logra alcanzar la mejor solución conocida para los problemas de prueba considerados, se obtienen soluciones con rendimientos de 77,02% en promedio para todos los problemas de prueba. Esto se debe fundamentalmente a que para tres de los problemas considerados, la metaheurística encuentra soluciones con rendimientos promedio inferiores a 70%. Sin embargo, para los problemas de complejidad media y alta, es capaz de encontrar soluciones con rendimientos promedio iguales o superiores a 80%. Un aspecto importante de esta implementación de Simulated Annealing es que, de acuerdo a los experimentos realizados, no se encontró evidencia de que obtenga mejores soluciones si se le permite un mayor tiempo de ejecución, por ejemplo al trabajar con valores altos de temperatura inicial o con un alto número de iteraciones para cada nivel de temperatura.

El Algoritmo Genético implementado es capaz de alcanzar y superar la mejor solución conocida para la mayoría de los problemas de prueba considerados, obteniendo soluciones con un rendimiento promedio de casi 82% para todos los problemas. A diferencia de lo que ocurre con Simulated Annealing, si al Algoritmo Genético se le da un mayor tiempo de ejecución, mediante los parámetros de tamaño de la población y número de generaciones, es capaz de encontrar mejores soluciones. Si bien el forzar al algoritmo a que obtenga soluciones superiores a la mejor conocida puede tomar tiempos de ejecución altos (entre 20

y 35 minutos), en general el Algoritmo Genético encuentra buenas soluciones (80% de rendimiento) en tiempos considerablemente menores.

Al comparar el desempeño de los dos algoritmos propuestos, se obtuvo que la implementación de Algoritmos Genéticos es capaz de encontrar mejores soluciones que Simulated Annealing, para iguales tiempos de ejecución.

Si se comparan los rendimientos obtenidos por los algoritmos propuestos con los de la industria del aserrío, los cuales están entre 55% a 65%, se podría pensar que la solución propuesta podría mejorar considerablemente la eficiencia en la utilización de la materia prima. Sin embargo, ambas cifras no son necesariamente comparables, ya que el rendimiento que entrega la solución es un rendimiento esperado, el cual depende fuertemente de la materia prima disponible, especialmente respecto de su calidad. El rendimiento que entrega la solución es el que se obtendría con una materia prima sin defectos, y en el cual todas las piezas están totalmente contenidas dentro del cilindro definido por el diámetro menor y largo de los rollizos y sin considerar factores como el espesor de corte, el cual incide negativamente en el rendimiento volumétrico.

La calidad de las soluciones que obtienen los algoritmos depende fuertemente de los datos de entrada que se les proporcionan, es decir, del listado de escuadrías que se requiere obtener y de rollizos disponibles. Esta afirmación, si bien parece natural para cualquier problema de optimización, es especialmente notoria en el caso de la industria del aserrío, ya que muchas veces se debe sacrificar el rendimiento de la materia prima de forma de cumplir con los pedidos. Esto se confirma al revisar los resultados del experimento de comparación entre ambos algoritmos. En ellos se observa que tres de los problemas de prueba tienen un efecto en el valor de la función objetivo, es decir, la calidad de las soluciones.

Existen dos objetivos en la optimización del corte de rollizos, maximizar el rendimiento volumétrico de la materia prima, y por otra parte maximizar la utilidad generada por producir determinadas piezas. En este sentido, los métodos propuestos son lo

suficientemente flexibles como para poder evaluar también este último objetivo, para lo cual básicamente se debe cambiar la función de evaluación de las soluciones, y considerar datos de entrada adicionales, como precios de las distintas escuadrías y costos de materia prima y producción.

En el caso de la industria del aserrío, a diferencia de otras en que está involucrado el corte de materias primas, como la industria del vidrio o textil, la materia prima presenta una alta heterogeneidad y defectos, lo que incide negativamente en el aprovechamiento de ésta. Por esta razón es que si se aplica en la realidad una solución entregada por los métodos planteados, el rendimiento real puede ser muy diferente al rendimiento asociado a la solución entregada. Por lo tanto, además de definir modelos de optimización de la producción de madera aserrada, se deben desarrollar tecnologías que permitan efectuar una clasificación más realista de la materia prima y obtener mayor información respecto de sus características externas e internas, y de esta forma, efectuar una mejor asignación de productos a las trozas.

REFERENCIAS

- ÁLVAREZ- VALDÉS, Ramón, PARAJÓN, Antonio y TAMARIT, José Manuel. A tabu search algorithm for large – scale guillotine (un)constrained two- dimensional cutting problems. *Computers & Operations Research*, 29(7): 925-947, 2002.
- ANAND, Sam, MC CORD, Christopher y SHARMA, Rohit. An Integrated Machine Vision Based System For Solving The Non-Convex Cutting Stock Problem Using Genetic Algorithms. *Journal of Manufacturing Systems*, 18 (6): 396-415, 1999.
- BAZARAA, M. S., JARVIS, J. J. y SHERALI, H. D. *Linear Programming and Network Flows*. New York, Wiley, 1990. 684 pp.
- BEAN, J. C. A multiple-choice genetic algorithm for a non linear cutting stock problem. *Computing in Science & Engineering*, 2(2): 80-83, 2000.
- BEASLEY, J. E. A population heuristic for constrained two - dimensional non – guillotine cutting. *European Journal of Operational Research*, 156(3): 601- 627, 2004.
- BELOV, G. y SCHEITHAUER, G. A branch-and-cut-and-price algorithm for one-dimensional stock cutting and two-dimensional two-stage cutting. *European Journal of Operational Research*, 171(1): 85–106, 2006.
- BENNELL, J., DOWSLAND, K. y DOWSLAND, W. The irregular cutting stock problem- a new procedure for deriving the no-fit polygon. *Computers & Operations Research*, 28(3): 271-287, 2001.
- BURKE E., KENDALL, G. y WHITWELL, G. A new placement heuristic for the orthogonal stock- cutting problem. *Operations research*, 52(4): 655-671, 2004.
- COWN, D.J., Mc CONCHIE, D. L. y TRELOA. C. Timber recovery from pruned pinus radiata butt logs at mangatu: Effect of log sweep. *New Zealand Journal of Forestry Science* 14(1):109-123, 1984.
- DANTZIG, George B. y WOLFE, Philip. Descomposition principle for linear programs. *Operations Research*, 8(1): 101-111, 1960.
- DOWSLAND, Kathryn. Simulated Annealing. En: REEVES, Colin R. *Modern Heuristic Techniques for Combinatorial Problems*. Gran Bretaña, Blackwell Scientific Publications, 1993. pp. 20-69.
- ESHELMAN, Larry J. Genetic Algorithms. En: BÄCK, Thomas, Fogel, David B. y Michalewicz, Zbigniew. *Evolutionary Computation 1: Basic algorithms and operators*. Gran Bretaña, Institute of Physics Publishing, 2000. pp. 64-80.
- FAALAND, Bruce y BRIGGS, David. Log bucking and lumber manufacturing using dynamic programming. *Management Science* 30(2): 245-257, 1984.
- FISCHER, A. y DAGLI, C. Employing subgroup evolution for irregular – shape nesting. *Journal of Intelligent Manufacturing*, 15(2): 187-199, 2004.
- GEERTS, Jan M. P. Mathematical solution for optimising pattern of a log given its dimensions and its defect core. *New Zealand Journal of Forestry Science*, 14(1): 124-134, 1984.
- GOLDBERG, David. *Genetics Algorithms in Search, Optimization and Machine Learning*. Reading, Massachusetts, Addison Wesley Longman. 1989. 411 pp.
- GOMES, A. Miguel y OLIVEIRA, José. Solving Irregular Strip Packing problems by hybridising Simulated Annealing and linear programming. *European Journal of Operational Research*, 171(3): 811-829, 2006.

- HABERL, J., NOWAK, Chr., STETTNER, H., STOISER, G. y WOSCHITZ, H. A branch & bound algorithm for solving a fixed charge problem in the profit optimisation of sawn timber production. *ZOR – Mathematical Methods of Operations Research* 35(2): 151-166, 1991.
- HAYGREEN, John G. y BOWYER, Jim L. *Forest Products and Wood Science, An Introduction*. Ames, Iowa State University Press. 1996. 484p.
- HOLTHAUS, Oliver. Decomposition approaches for solving the integer one-dimensional cutting stock problem with different types of standard lengths. *European Journal of Operational Research*, 141(2): 295–312, 2002.
- HOPPER, E. y TURTON, B. C. H. A review of the applications of meta- heuristic algorithms to 2D strip packing problems. *Artificial Intelligence Review*, 16(4): 257-300, 2001.
- INFOR, “La Industria Del Aserrío 1999-2000” *Boletín Estadístico* 81, septiembre 2001.
- KIRKPATRICK, S., GELATT, C. D. Jr. y VECCHI, M. P. Optimization by Simulated Annealing. *Science* 220: 671-680, 1983.
- LEWIS, Davis W. *Sawmill Simulation and the best opening face system: A user’s guide*. USDA Forest Service, Forest Products Laboratory, General Technical Report FPL-48, 1985.
- LUNDGREN, Christina. Predicting log type and knot size category using external log shape data from a 3D log scanner. *Scandinavian Journal of Forest Research* 15(1): 119-126, 2000.
- MANESS, Thomas y ADAMS, Darius. The combined optimization of log bucking and sawing strategies. *Wood and Fiber Science*, 23(2): 296-314, 1991.
- MANESS, Thomas C. y LIN, Yingzhong. The influence of sawkerf and target size reduction on sawmill revenue and volume recovery. *Forest Products Journal* 45 (11/12): 43-50, 1995.
- METROPOLIS, N. A., ROSENBLUTH, W., ROSENBLUTH, M. N., TELLER, A. H. y TELLER, E. Equation of state calculation by fast computing machines. *Journal of Chem. Phys* 21: 1087-1091, 1953.
- MONTGOMERY, Douglas C. *Diseño y análisis de experimentos*. México, Grupo Editorial Iberoamérica, 1991. 589 pp.
- MONTGOMERY, Douglas C. y RUNGER, George C. *Probabilidad y estadística aplicadas a la ingeniería*. México, McGraw-Hill, 1996. 895pp.
- MORABITO, R. y GARCÍA, V. The Cutting Stock Problem In A Hardboard Industry: A Case Study. *Computers and Operations Research*, 25(6): 469-485, 1998.
- OJA, Johan, WALLBÄCKSC, Lars, GRUNDBERG, Stig, HÄGERDALC, Erik y GRÖNLUND, Anders. Automatic grading of Scots pine (*Pinus sylvestris* L.) sawlogs using an industrial X-ray log scanner. *Computers and Electronics in Agriculture*, 41: 63 – 75, 2003.
- PARADA, V., PRADENAS, L., SOLAR, M. y PALMA, R. A hybrid algorithm for the non – guillotine cutting problem. *Annals Of Operations Research*, 117, 151-163, 2002.
- PARADA, V., SEPULVEDA, M., SOLAR, M. y GÓMES, A. Solution for the constrained guillotine cutting. *Computers & Operations Research*, 25(1): 37-47, 1998.
- RAMOS, M. y KOLLER, R. Una metaheurística colaborativa para la planificación de la producción en la industria del aserrío. *Congreso Optima 2005*, Valdivia, Chile.

- REINDERS, M.P. y HENDRIKS, Th. H. B. Lumberproduction optimization. *European journal of Operational Research*, 42(3): 243-253, 1989.
- REEVES, Colin R. Genetics Algorithms. En su: *Modern Heuristic Techniques for Combinatorial Problems*. Gran Bretaña, Blackwell Scientific Publications, 1993. pp. 151-196.
- RINNHOFFER Alfred, PETUTSCHNIGG, Alexander y ANDREU, Jean Philippe. Internal log scanning for optimizing breakdown. *Computers and Electronics in Agriculture*, 41: 7-21, 2003.
- RÖNNQVIST, Mikael. Optimization in forestry. *Mathematical Programming*, 97: 67-284, 2003.
- TODOROKI, C. L. AUTOSAW system for sawing simulation. *New Zealand Journal of Forestry Science*, 20(3): 332-348, 1990.
- TODOROKI, C.L. y RÖNNQVIST, E.M. Secondary log breakdown optimization with dynamic programming. *Journal of the Operational Research Society* 48(5): 471-478, 1997.
- TODOROKI, C.L. y RÖNNQVIST, E.M. Combined primary and secondary log breakdown optimization. *Journal of the Operational Research Society* 50(3): 219-229. 1999.
- TODOROKI, C., RÖNNQVIST, M. Dynamic control of timber production at a sawmill with log sawing optimization. *Scandinavian Journal of Forest Research*, 17(1): 79-89, 2002.
- WALL, Mathew. GALib: A C++ Library of Genetic Algorithm Components version 2.4 Documentation Revision B [en línea]. Massachusetts Institute of Technology, 1996 [fecha de consulta: 10 septiembre 2006]. Disponible en: <<http://lancet.mit.edu/ga/>>.
- WALL, Mathew. *GAlib* versión 2.4.6 [en línea]. Massachusetts Institute of Technology, 1996. Disponible en <<http://lancet.mit.edu/ga/>>.
- WILLISTON, E. *Lumber Manufacturing: The design and operation of Sawmills and Planner Mills*. San Francisco, Calif., Miller Freeman Publications. 1988. 486pp.
- YANASSE, H. H. y MORABITO, R. Linear models for 1-group two-dimensional guillotine cutting problems. *International Journal of Production Research*, 44 (17): 3471–3491, 2006.

ANEXOS

Anexo 1 Problemas de prueba

A 1.1 Información sobre rollizos y escuadrías utilizadas

Tipo	Diámetro (cm)	Largo (m)	Volumen Trozo JAS (m3)	Volumen "geométrico"
1	20	4	0,1600	0,1257
2	22	4	0,1936	0,1521
3	24	4	0,2304	0,1810
4	26	4	0,2704	0,2124
5	28	4	0,3136	0,2463
6	30	4	0,3600	0,2827

Figura A1.1.1 Información sobre rollizos utilizados

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)
1	4	12	2	0,0096
2	4	14	2	0,0112
3	4	16	2	0,0128
4	4	18	2	0,0144
5	4	20	2	0,016

Figura A1.1.2 Información sobre centrales utilizados.

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)
1	4	6,5	2	0,0052
2	4	7	2	0,0056
3	4	9	2	0,0072
4	4	10	2	0,008
5	4	12	2	0,0096
6	4	12,5	2	0,01
7	4	13	2	0,0104
8	4	14	2	0,0112
9	4	15	2	0,012
10	4	17	2	0,0136
11	4	18	2	0,0144
12	4	20	2	0,016

Figura A1.1.3 Piezas laterales utilizadas

A 1.2 Esquemas base para generación de problemas de prueba

Construcción 1

ROLLIZO					
Tipo	Diámetro (cm)	Largo (m)	Conicidad (%)	Volumen Trozo JAS (m3)	Volumen geométrico
2	22	4	1	0,1936	0,1521

CENTRALES

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
	6	4	12	2	0,0096	0,0576
Volumen Central=						0,0576

LATERAL

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
1		4	6,5	2	0,0052	0,0000
2		4	7	2	0,0056	0,0000
3	4	4	9	2	0,0072	0,0288
4		4	10	2	0,0080	0,0000
5	2	4	12	2	0,0096	0,0192
6		4	12,5	2	0,0100	0,0000
7		4	13	2	0,0104	0,0000
8	2	4	14	2	0,0112	0,0224
9		4	15	2	0,0120	0,0000
10		4	17	2	0,0136	0,0000
11		4	18	2	0,0144	0,0000
12		4	20	2	0,0160	0,0000
Volumen lateral=						0,0704
Volumen total=						0,1280

Rendimiento esperado	0,8418
----------------------	--------

Construcción 2

ROLLIZO					
Grupo	Diámetro (cm)	Largo (m)	Conicidad (%)	Volumen Trozo JAS (m3)	Volumen geométrico
	28	4	1	0,3136	0,2463

CENTRALES

Espesor (mm)	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
20	7	4	16	2	0,0128	0,0896
Volumen Central=						0,0896

LATERALES

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
1		4	6,5	2	0,0052	0,0000
2		4	7	2	0,0056	0,0000
3		4	9	2	0,0072	0,0000
4	2	4	10	2	0,0080	0,0160
5		0	0	0	0,0000	0,0000
6		4	12	2	0,0096	0,0000
7		4	12,5	2	0,0100	0,0000
8		4	13	2	0,0104	0,0000
9	4	4	14	2	0,0112	0,0448
10		4	15	2	0,0120	0,0000
11	2	4	17	2	0,0136	0,0272
12		4	18	2	0,0144	0,0000
20	2	4	20	2	0,0160	0,0320
Volumen lateral=						0,1200
Volumen total=						0,2096

Rendimiento esperado	0,8509
-----------------------------	--------

Construcción 3

ROLLIZO					
Grupo	Diámetro (cm)	Largo (m)	Conicidad (%)	Volumen Trozo JAS (m3)	Volumen geométrico
4	26	4	1	0,2704	0,2124

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
	5	4	20	2	0,0160	0,08
Volumen Central=						0,08

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
1		4	6,5	2	0,0052	0,0000
2		4	7	2	0,0056	0,0000
3		4	9	2	0,0072	0,0000
4	2	4	10	2	0,0080	0,0160
5		4	12	2	0,0096	0,0000
6		4	12,5	2	0,0100	0,0000
7	2	4	13	2	0,0104	0,0208
8		4	14	2	0,0112	0,0000
9		4	15	2	0,0120	0,0000
10		4	17	2	0,0136	0,0000
11	2	4	18	2	0,0144	0,0288
12	2	4	20	2	0,0160	0,0320
Volumen lateral=						0,0976
Volumen total=						0,1776

Rendimiento esperado	0,8363
-----------------------------	--------

Construcción 4

ROLLIZO					
Grupo	Diámetro (cm)	Largo (m)	Conicidad (%)	Volumen Trozo JAS (m3)	Volumen geométrico
3	24	4	1	0,2304	0,1810

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
	6	4	16	2	0,0128	0,0768
Volumen Central=						0,0768

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
1		4	6,5	2	0,0052	0,0000
2		4	7	2	0,0056	0,0000
3		4	9	2	0,0072	0,0000
4		4	10	2	0,0080	0,0000
5	2	4	12	2	0,0096	0,0192
6	2	4	12,5	2	0,0100	0,0200
7		4	13	2	0,0104	0,0000
8		4	14	2	0,0112	0,0000
9		4	15	2	0,0120	0,0000
10	2	4	17	2	0,0136	0,0272
11		4	18	2	0,0144	0,0000
12		4	20	2	0,0160	0,0000
Volumen lateral=						0,0664
Volumen total=						0,1432

Rendimiento esperado	0,7914
-----------------------------	--------

Construcción 5

ROLLIZO					
Grupo	Diámetro (cm)	Largo (m)	Conicidad (%)	Volumen Trozo JAS (m3)	Volumen geométrico
1	20	4	1	0,1600	0,1257

Espesor (mm)	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
20	5	4	14	2	0,0112	0,056
Volumen Central=						0,056

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
1	4	4	6,5	2	0,0052	0,0208
2		4	7	2	0,0056	0,0000
3		4	9	2	0,0072	0,0000
4		4	10	2	0,0080	0,0000
5		4	12	2	0,0096	0,0000
6		4	12,5	2	0,0100	0,0000
7		4	13	2	0,0104	0,0000
8	2	4	14	2	0,0112	0,0224
9		4	15	2	0,0120	0,0000
10		4	17	2	0,0136	0,0000
11		4	18	2	0,0144	0,0000
12		4	20	2	0,0160	0,0000
Volumen lateral=						0,0432
Volumen total=						0,0992

Rendimiento esperado	0,7894
-----------------------------	--------

Construcción 6

ROLLIZO					
Grupo	Díámetro (cm)	Largo (m)	Conicidad (%)	Volumen Trozo JAS (m3)	Volumen geométrico
6	30	4	1	0,3600	0,2827

Espesor (mm)	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
20	7	4	18	2	0,0144	0,1008
Volumen Central=						0,1008

Tipo	Cantidad	Largo (m)	Ancho (cm)	Espesor (cm)	volumen (m3)	Volumen central
1		4	6,5	2	0,0052	0,0000
2	2	4	7	2	0,0056	0,0112
3		4	9	2	0,0072	0,0000
4		4	10	2	0,0080	0,0000
5		4	12	2	0,0096	0,0000
6		4	12,5	2	0,0100	0,0000
7		4	13	2	0,0104	0,0000
8	4	4	14	2	0,0112	0,0448
9		4	15	2	0,0120	0,0000
10		4	17	2	0,0136	0,0000
11		4	18	2	0,0144	0,0000
12	4	4	20	2	0,0160	0,0640
Volumen lateral=						0,1200
Volumen total=						0,2208

Rendimiento esperado	0,7809
-----------------------------	--------

Construcción 7

ROLLIZO					
Grupo	Diámetro (cm)	Largo (m)	Conicidad (%)	Volumen Trozo JAS (m3)	Volumen geométrico
3	24	4	1	0,2304	0,1810

Esesor (mm)	Cantidad	Largo (m)	Ancho (cm)	Esesor (cm)	volumen (m3)	Volumen central
20	8	4	14	2	0,0112	0,0896
Volumen Central=						0,0896

Tipo	Cantidad	Largo (m)	Ancho (cm)	Esesor (cm)	volumen (m3)	Volumen central
1		4	6,5	2	0,0052	0,0000
2		4	7	2	0,0056	0,0000
3	2	4	9	2	0,0072	0,0144
4		4	10	2	0,0080	0,0000
5		0	0	0	0,0000	0,0000
6		4	12	2	0,0096	0,0000
7		4	12,5	2	0,0100	0,0000
8	2	4	13	2	0,0104	0,0208
9		4	14	2	0,0112	0,0000
10	2	4	15	2	0,0120	0,0240
11		4	17	2	0,0136	0,0000
12		4	18	2	0,0144	0,0000
20		4	20	2	0,0160	0,0000
Volumen lateral=						0,0592
Volumen total=						0,1488

Rendimiento esperado	0,8223
-----------------------------	--------

A 1.3 Problemas de prueba generados

Problema AP1

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	6
2	22	4	0,1936	0,1521	6
3	24	4	0,2304	0,1810	21
4	26	4	0,2704	0,2124	8
5	28	4	0,3136	0,2463	8
6	30	4	0,3600	0,2827	3

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	7
2	4	14	2	63
3	4	16	2	35
4	4	18	2	7
5	4	20	2	21

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	8
2	4	7	2	2
3	4	9	2	20
4	4	10	2	12
5	4	12	2	6
6	4	12,5	2	4
7	4	13	2	18
8	4	14	2	24
9	4	15	2	12
10	4	17	2	6
11	4	18	2	6
12	4	20	2	10

rend. esperado (%)	81,27%
--------------------	--------

Problema AP2

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	28
2	22	4	0,1936	0,1521	13
3	24	4	0,2304	0,1810	21
4	26	4	0,2704	0,2124	13
5	28	4	0,3136	0,2463	16
6	30	4	0,3600	0,2827	23

Piezas centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	56
2	4	14	2	77
3	4	16	2	84
4	4	18	2	63
5	4	20	2	28

Piezas laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	32
2	4	7	2	18
3	4	9	2	24
4	4	10	2	22
5	4	12	2	22
6	4	12,5	2	12
7	4	13	2	14
8	4	14	2	90
9	4	15	2	4
10	4	17	2	12
11	4	18	2	10
12	4	20	2	48

rend. esperado (%)	81,32%
--------------------	--------

Problema AP3

Rollizos Disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	36
2	22	4	0,1936	0,1521	18
3	24	4	0,2304	0,1810	31
4	26	4	0,2704	0,2124	29
5	28	4	0,3136	0,2463	29
6	30	4	0,3600	0,2827	21

Piezas centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	98
2	4	14	2	105
3	4	16	2	126
4	4	18	2	56
5	4	20	2	56

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	56
2	4	7	2	16
3	4	9	2	36
4	4	10	2	44
5	4	12	2	30
6	4	12,5	2	16
7	4	13	2	30
8	4	14	2	114
9	4	15	2	8
10	4	17	2	22
11	4	18	2	22
12	4	20	2	54

rend. esperado (%)	81,58%
--------------------	--------

Problema AM1

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	16
2	22	4	0,1936	0,1521	31
3	24	4	0,2304	0,1810	49
4	26	4	0,2704	0,2124	42
5	28	4	0,3136	0,2463	39
6	30	4	0,3600	0,2827	39

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	77
2	4	14	2	112
3	4	16	2	161
4	4	18	2	105
5	4	20	2	84

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	24
2	4	7	2	30
3	4	9	2	68
4	4	10	2	62
5	4	12	2	42
6	4	12,5	2	18
7	4	13	2	52
8	4	14	2	156
9	4	15	2	20
10	4	17	2	30
11	4	18	2	32
12	4	20	2	90

rend. esperado (%)	82,00%
--------------------	--------

Problema AM2

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	52
2	22	4	0,1936	0,1521	34
3	24	4	0,2304	0,1810	85
4	26	4	0,2704	0,2124	44
5	28	4	0,3136	0,2463	60
6	30	4	0,3600	0,2827	44

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	112
2	4	14	2	224
3	4	16	2	273
4	4	18	2	119
5	4	20	2	91

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	80
2	4	7	2	34
3	4	9	2	82
4	4	10	2	80
5	4	12	2	62
6	4	12,5	2	36
7	4	13	2	64
8	4	14	2	226
9	4	15	2	30
10	4	17	2	46
11	4	18	2	34
12	4	20	2	114

rend. esperado (%)	82,12%
--------------------	--------

Problema AM3

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	72
2	22	4	0,1936	0,1521	70
3	24	4	0,2304	0,1810	170
4	26	4	0,2704	0,2124	85
5	28	4	0,3136	0,2463	80
6	30	4	0,3600	0,2827	90

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	168
2	4	14	2	469
3	4	16	2	371
4	4	18	2	245
5	4	20	2	168

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	112
2	4	7	2	70
3	4	9	2	190
4	4	10	2	128
5	4	12	2	104
6	4	12,5	2	50
7	4	13	2	148
8	4	14	2	374
9	4	15	2	82
10	4	17	2	62
11	4	18	2	66
12	4	20	2	202

rend. esperado (%)	82,04%
--------------------	--------

Problema AM4

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	174
2	22	4	0,1936	0,1521	100
3	24	4	0,2304	0,1810	246
4	26	4	0,2704	0,2124	105
5	28	4	0,3136	0,2463	105
6	30	4	0,3600	0,2827	110

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	448
2	4	14	2	735
3	4	16	2	574
4	4	18	2	301
5	4	20	2	210

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	272
2	4	7	2	86
3	4	9	2	254
4	4	10	2	164
5	4	12	2	172
6	4	12,5	2	94
7	4	13	2	180
8	4	14	2	550
9	4	15	2	98
10	4	17	2	82
11	4	18	2	82
12	4	20	2	254

rend. esperado (%)	81,48%
--------------------	--------

Problema AM5

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	121
2	22	4	0,1936	0,1521	164
3	24	4	0,2304	0,1810	280
4	26	4	0,2704	0,2124	159
5	28	4	0,3136	0,2463	136
6	30	4	0,3600	0,2827	167

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	427
2	4	14	2	637
3	4	16	2	728
4	4	18	2	455
5	4	20	2	315

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	188
2	4	7	2	130
3	4	9	2	356
4	4	10	2	230
5	4	12	2	246
6	4	12,5	2	118
7	4	13	2	224
8	4	14	2	694
9	4	15	2	100
10	4	17	2	106
11	4	18	2	124
12	4	20	2	366

Rend. Esperado (%)	82,15%
--------------------	--------

Problema AM6

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	262
2	22	4	0,1936	0,1521	218
3	24	4	0,2304	0,1810	446
4	26	4	0,2704	0,2124	226
5	28	4	0,3136	0,2463	218
6	30	4	0,3600	0,2827	236

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	749
2	4	14	2	1225
3	4	16	2	1106
4	4	18	2	644
5	4	20	2	441

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	408
2	4	7	2	184
3	4	9	2	518
4	4	10	2	346
5	4	12	2	340
6	4	12,5	2	170
7	4	13	2	354
8	4	14	2	1082
9	4	15	2	178
10	4	17	2	170
11	4	18	2	176
12	4	20	2	538

Rend. Esperado (%)	81,87%
--------------------	--------

Problema AG1

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	185
2	22	4	0,1936	0,1521	197
3	24	4	0,2304	0,1810	410
4	26	4	0,2704	0,2124	193
5	28	4	0,3136	0,2463	231
6	30	4	0,3600	0,2827	231

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	693
2	4	14	2	1344
3	4	16	2	1470
4	4	18	2	840
5	4	20	2	504

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	384
2	4	7	2	240
3	4	9	2	624
4	4	10	2	440
5	4	12	2	414
6	4	12,5	2	210
7	4	13	2	416
8	4	14	2	1356
9	4	15	2	216
10	4	17	2	240
11	4	18	2	200
12	4	20	2	720

Rend. Esperado (%)	82,12%
--------------------	--------

Problema AG2

Rollizos disponibles

Tipo	Diámetro (cm)	Largo (m)	Volumen JAS (m3)	Volumen Geométrico (m3)	Cantidad
1	20	4	0,1600	0,1257	216
2	22	4	0,1936	0,1521	258
3	24	4	0,2304	0,1810	516
4	26	4	0,2704	0,2124	258
5	28	4	0,3136	0,2463	268
6	30	4	0,3600	0,2827	260

Piezas Centrales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	12	2	889
2	4	14	2	1610
3	4	16	2	1799
4	4	18	2	945
5	4	20	2	672

Piezas Laterales

Tipo	Largo (m)	Ancho (cm)	Espesor (cm)	Cantidad
1	4	6,5	2	448
2	4	7	2	270
3	4	9	2	798
4	4	10	2	546
5	4	12	2	542
6	4	12,5	2	274
7	4	13	2	530
8	4	14	2	1588
9	4	15	2	262
10	4	17	2	278
11	4	18	2	268
12	4	20	2	818

Rend. Esperado (%)	82,13%
--------------------	--------

Anexo 2 Establecimiento de parámetros para Simulated Annealing

A 2.1 Experimento 1

A) Influencia de los parámetros de Simulated Annealing en la Función Objetivo.

Analysis of Variance for FO - Type III Sums of Squares					
Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:ALFA	0,0210083	4	0,00525208	10,24	0
B:TO	0,00044587	3	0,000148623	0,29	0,8329
C:TF	0,205314	3	0,068438	133,37	0
D:NT	0,367091	3	0,122364	238,46	0
E:COMPLPROB	9,84796	2	4,92398	9595,86	0
INTERACTIONS					
AB	0,0138648	12	0,0011554	2,25	0,008
AC	0,00960875	12	0,000800729	1,56	0,0964
AD	0,00728782	12	0,000607318	1,18	0,2888
AE	0,0180745	8	0,00225931	4,4	0
BC	0,0131407	9	0,00146007	2,85	0,0025
BD	0,00235925	9	0,000262139	0,51	0,8677
BE	0,0149467	6	0,00249111	4,85	0,0001
CD	0,00899175	9	0,000999083	1,95	0,0417
CE	0,128322	6	0,021387	41,68	0
DE	0,311276	6	0,0518794	101,1	0
ABC	0,0233386	36	0,000648293	1,26	0,1363
ABD	0,0250034	36	0,000694539	1,35	0,0788
ABE	0,0177064	24	0,000737769	1,44	0,0777
ACD	0,0121253	36	0,000336813	0,66	0,9428
ACE	0,0176899	24	0,000737078	1,44	0,0782
ADE	0,00948186	24	0,000395077	0,77	0,7784
BCD	0,0362965	27	0,00134431	2,62	0
BCE	0,023162	18	0,00128678	2,51	0,0004
BDE	0,0283094	18	0,00157275	3,06	0
CDE	0,0575274	18	0,00319597	6,23	0
ABCD	0,0693892	108	0,000642493	1,25	0,0437
ABCE	0,0422041	72	0,000586168	1,14	0,1966
ABDE	0,0316316	72	0,000439328	0,86	0,7999
ACDE	0,026966	72	0,000374528	0,73	0,957
BCDE	0,0774214	54	0,00143373	2,79	0
RESIDUAL	1,09606	2136	0,000513136		
<hr/>					
TOTAL (CORRECTED)	12,564	2879			

Figura A2.1.1 Análisis de Varianza Experimento 1.

B) Influencia de los parámetros en el tiempo de ejecución de Simulated Annealing

De acuerdo al análisis de varianza, para un nivel de confianza del 95%, todos los factores considerados tienen efecto significativo en el tiempo de ejecución de Simulated Annealing, como se observa gráficamente, en las figuras A2.1.2 a A2.1.6, y en los resultados del análisis de varianza, presentado en la figura A2.1.7. Se tiene que además, existen interacciones significativas entre los factores.

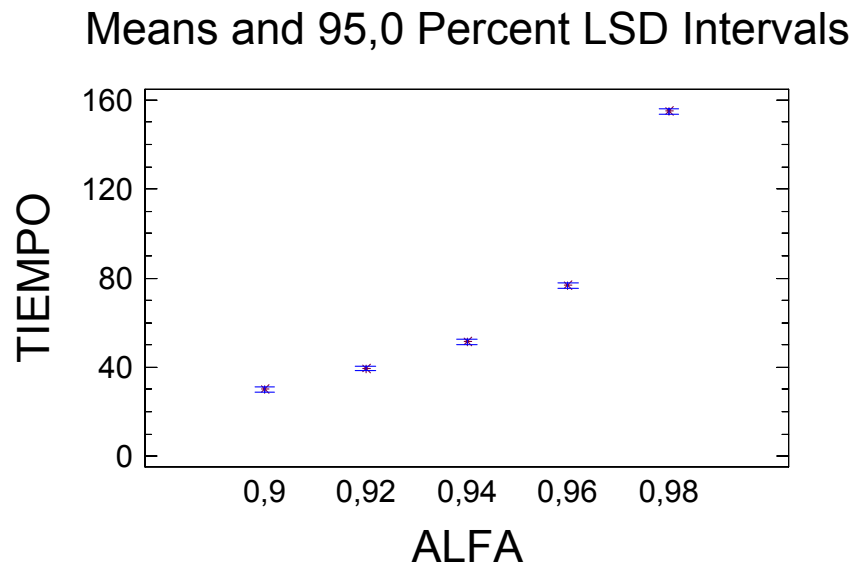


Figura A2.1.2 Gráfico de medias e intervalos de confianza para ALFA.

Means and 95,0 Percent LSD Intervals




Figura A2.1.3 Gráfico de médias e intervalos de confiança para T0.

Means and 95,0 Percent LSD Intervals




Figura A2.1.4 Gráfico de médias e intervalos de confiança para TF.

Means and 95,0 Percent LSD Intervals




Figura A2.1.5 Gráfico de medias e intervalos de confianza para NT.

Means and 95,0 Percent LSD Intervals

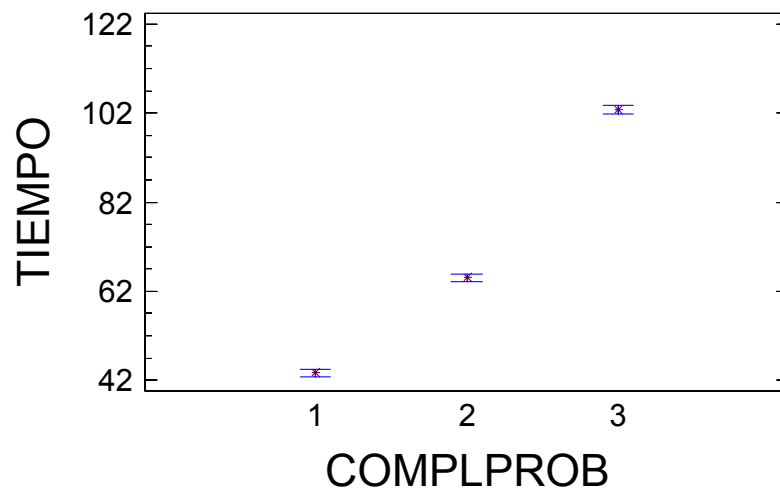


Figura A2.1.6 Gráfico de medias e intervalos de confianza para COMPLPROB.

Analysis of Variance for TIEMPO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:ALFA	5,84E+06	4	1,46E+06	3456	0
B:TO	311823	3	103941	246,23	0
C:TF	1,90E+06	3	633237	1500,1	0
D:NT	6,95E+06	3	2,32E+06	5485,1	0
E:COMPLPROB	1,72E+06	2	861298	2040,4	0
INTERACTIONS					
AB	121931	12	10160,9	24,07	0
AC	769314	12	64109,5	151,87	0
AD	2,87E+06	12	239049	566,29	0
AE	695604	8	86950,5	205,98	0
BC	7122,47	9	791,385	1,87	0,0514
BD	155005	9	17222,8	40,8	0
BE	19035,8	6	3172,63	7,52	0
CD	899923	9	99991,5	236,87	0
CE	373758	6	62292,9	147,57	0
DE	838050	6	139675	330,88	0
ABC	8056,51	36	223,792	0,53	0,9904
ABD	74222,7	36	2061,74	4,88	0
ABE	8635,47	24	359,811	0,85	0,6701
ACD	382836	36	10634,3	25,19	0
ACE	161115	24	6713,13	15,9	0
ADE	349471	24	14561,3	34,49	0
BCD	9757,96	27	361,406	0,86	0,6782
BCE	16427	18	912,614	2,16	0,0031
BDE	14726,5	18	818,14	1,94	0,0102
CDE	180492	18	10027,3	23,75	0
ABCD	32462,8	108	300,582	0,71	0,9885
ABCE	17870,2	72	248,198	0,59	0,9977
ABDE	36473,1	72	506,571	1,2	0,1232
ACDE	97278,2	72	1351,09	3,2	0
BCDE	19603,3	54	363,024	0,86	0,7559
RESIDUAL	901672	2136	422,131		
TOTAL (CORRECTED)	2,58E+07	2879			

Figura A2.1.7 Análisis de varianza experimento con variable respuesta tiempo de ejecución.

A 2.2 Experimento 2

La figura A2.2.1 presenta el análisis de varianza para el experimento 2.

Para un nivel de confianza del 95%, no hay evidencia para afirmar que existan interacciones significativas entre los factores. Sin embargo, los valores-p son relativamente cercanos a 0,05, y gráficamente, se observa que puede existir interacción (figuras A2.2.2 a A2.2.4).

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:T0	0,00173235	1	0,00173235	3,7	0,0624
B:NT	0,00158025	1	0,00158025	3,37	0,0746
C:COMPLPROB	0,169878	2	0,0849391	181,27	0
INTERACTIONS					
AB	0,0016089	1	0,0016089	3,43	0,0721
AC	0,0024809	2	0,00124045	2,65	0,0846
BC	0,00292387	2	0,00146193	3,12	0,0563
ABC	0,00261694	2	0,00130847	2,79	0,0746
RESIDUAL	0,0168685	36	0,000468568		
TOTAL(CORRECTED)	0,19969	47			

Figura A2.2.1 Análisis de varianza para experimento 2.




Figura A2.2.2 Gráfico de interacciones para NT versus T0.




Figura A2.2.3 Gráfico de interacciones para COMPLPROB versus T0.

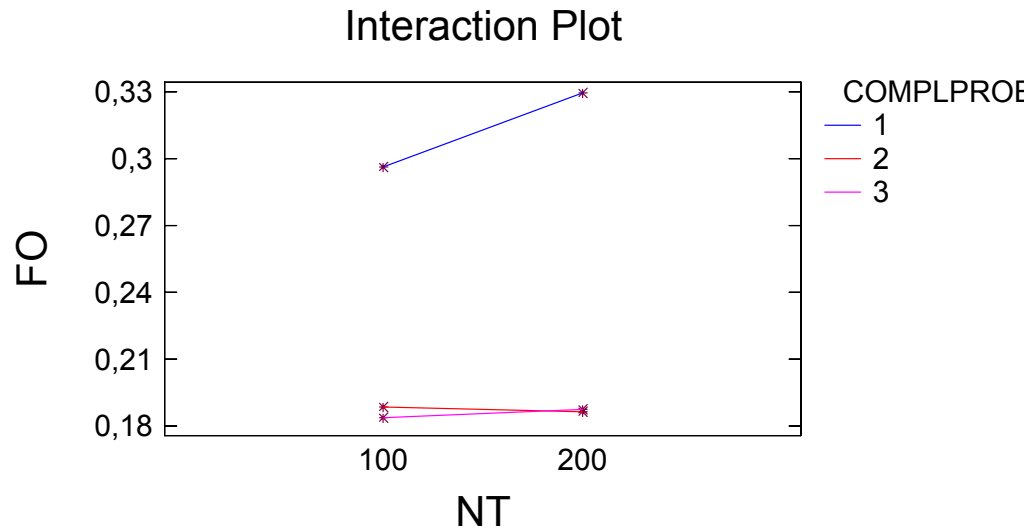


Figura A2.2.4 Gráfico de interacciones para COMPLPROB versus NT.

A 2.3 Experimento 3

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:T0	7,17322E-05	1	7,17322E-05	1,51	0,2245
B:NT	0,0155071	2	0,00775354	163,2	0
C:COMPLROB	0,170743	2	0,0853713	1796,93	0
INTERACTIONS					
AB	0,000229036	2	0,000114518	2,41	0,0994
AC	4,10852E-05	2	2,05426E-05	0,43	0,6512
BC	0,0437294	4	0,0109323	230,11	0
ABC	0,000252769	4	6,31921E-05	1,33	0,2706
RESIDUAL	0,00256552	54	4,75096E-05		
TOTAL(CORRECTED)	0,233139	71			

Figura A2.3.1 Análisis de varianza para experimento 3.

A 2.4 Experimento 4

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:ALFA	0,00394467	2	0,0019723	1,27	0,2882
B:T0	0,000216542	1	0,0002165	0,14	0,7100
C:COMPLPROB	0,0879889	2	0,0439945	28,4	0,0000
INTERACTIONS					
AB	0,00457086	2	0,0022854	1,48	0,2378
AC	0,0138039	4	0,0034510	2,23	0,0781
BC	0,00200668	2	0,0010033	0,65	0,5273
ABC	0,00564007	4	0,0014100	0,91	0,4647
RESIDUAL	0,0836633	54	0,00154932		
TOTAL(CORRECTED)	0,201835	71			

Figura A2.4.1 Análisis de varianza experimento 4.

A 2.5 Experimento 5

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:ALFA	0,0011628	1	0,00116275	2,15	0,1480
B:NT	0,0032804	2	0,00164022	3,04	0,0562
C:COMPLPROB	0,1789070	2	0,08945370	165,69	0,0000
INTERACTIONS					
AB	0,0028430	2	0,00142148	2,63	0,0811
AC	0,0036377	2	0,00181884	3,37	0,0418
BC	0,0440546	4	0,01101360	20,4	0,0000
ABC	0,0049852	4	0,00124629	2,31	0,0697
RESIDUAL	0,0291536	54	0,00053988		
TOTAL(CORRECTED)	0,268024	71			

Figura A2.5.1 Análisis de varianza experimento 5.

A 2.6 Experimento para la determinación de valor para parámetro NT

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:NT	1,133E-09	1	1,13E-09	0	0,9989
B:PROBLEMA	1,905E-01	10	0,0190497	30,77	0
INTERACTIONS					
AB	8,482E-02	10	0,00848199	13,7	0
RESIDUAL	5,449E-02	88	0,000619191		
TOTAL (CORRECTED)	3,298E-01	109			

Figura A2.6.1 Análisis de varianza experimento para determinación de parámetro NT.

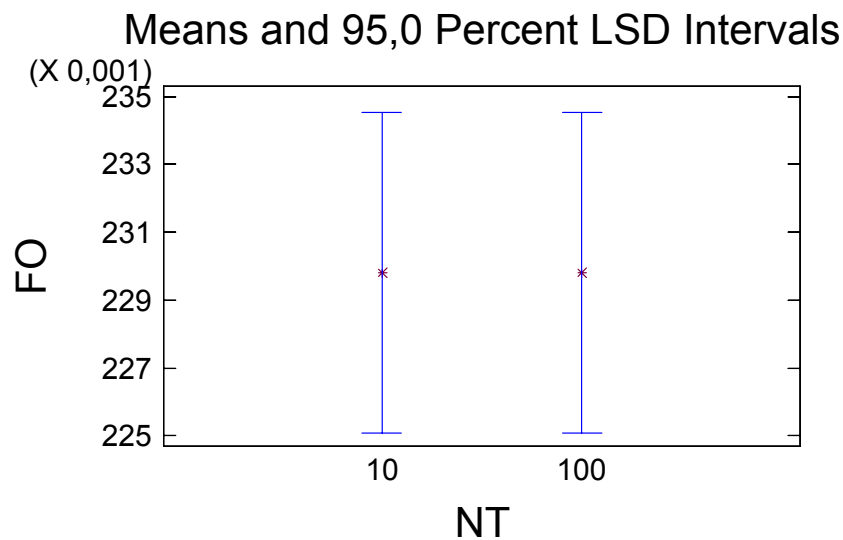


Figura A2.6.2 Gráfico de medias e intervalos de confianza para NT.

Means and 95,0 Percent LSD Intervals

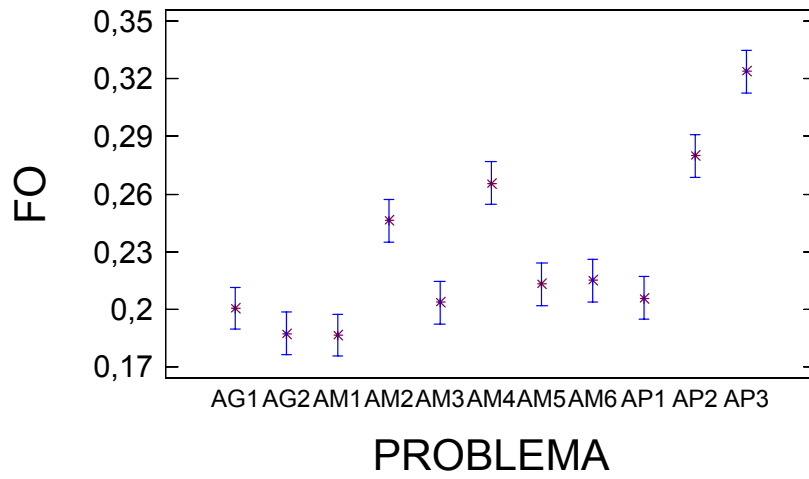


Figura A2.6.3 Gráfico de medias e intervalos de confianza para PROBLEMA.

Interaction Plot




Figura A2.6.4 Gráfico de interacciones para PROBLEMA versus NT.

Anexo 3 Establecimiento parámetros Algoritmo Genético

A 3.1 Experimento 1

A) Variable respuesta: Función Objetivo

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:PMUT	0,0157721	3	0,00525735	141,61	0,0000
B:PCROSS	0,000422124	3	0,000140708	3,79	0,0100
C:POPSIZE	0,014315	3	0,00477167	128,53	0,0000
D:NGENER	0,0158227	3	0,00527423	142,06	0,0000
E:COMPLPROB	0,0156534	2	0,00782671	210,82	0,0000
INTERACTIONS					
AB	0,000463387	9	5,14874E-05	1,39	0,1885
AC	0,00230834	9	0,000256482	6,91	0,0000
AD	0,000747291	9	8,30324E-05	2,24	0,0176
AE	0,00712921	6	0,0011882	32	0,0000
BC	0,000471807	9	0,000052423	1,41	0,1773
BD	0,000205215	9	2,28017E-05	0,61	0,7859
BE	0,000676295	6	0,000112716	3,04	0,0059
CD	0,00307972	9	0,000342191	9,22	0,0000
CE	0,00196515	6	0,000327525	8,82	0,0000
DE	0,00284376	6	0,00047396	12,77	0,0000
ABC	0,00197817	27	7,32656E-05	1,97	0,0021
ABD	0,000734951	27	2,72204E-05	0,73	0,8380
ABE	0,000798429	18	4,43572E-05	1,19	0,2563
ACD	0,00100474	27	3,72126E-05	1	0,4613
ACE	0,00178613	18	9,92293E-05	2,67	0,0002
ADE	0,00132868	18	7,38157E-05	1,99	0,0080
BCD	0,00163354	27	6,05016E-05	1,63	0,0219
BCE	0,00177208	18	0,000098449	2,65	0,0002
BDE	0,000735527	18	4,08626E-05	1,1	0,3448
CDE	0,00143515	18	7,97308E-05	2,15	0,0034
ABCD	0,00286618	81	0,000035385	0,95	0,5977
ABCE	0,00342476	54	6,34215E-05	1,71	0,0012
ABDE	0,00196115	54	3,63177E-05	0,98	0,5203
ACDE	0,00232877	54	4,31254E-05	1,16	0,1991
BCDE	0,00348135	54	6,44695E-05	1,74	0,0008
RESIDUAL	0,0630394	1698	3,71257E-05		
TOTAL (CORRECTED)	0,172185	2303			

Figura A3.1.1 Análisis de varianza, experimento 1.

B) Variable respuesta: Tiempo de ejecución

De acuerdo al análisis de factores principales, presentado en la figura A3.1.2, los únicos factores que influyen de manera estadísticamente significativa en el tiempo de ejecución son, con un nivel de confianza del 95%: POPSIZE, NGENER y COMPLPROB. Esto se puede observar gráficamente en las figuras A3.1.3 a A3.1.5.

Analysis of Variance for TIME - Type III Sums of Squares					
Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:PMUT	87,2969	3	29,099	0,12	0,9457
B:PCROSS	234,911	3	78,3038	0,33	0,8002
C:POPSIZE	4,75E+07	3	1,58E+07	67642,21	0,0000
D:NGENER	4,72E+07	3	1,57E+07	67278,96	0,0000
E:COMPLPROB	2,28E+06	2	1,14E+06	4862,96	0,0000
INTERACTIONS					
AB	206,137	9	22,9041	0,1	0,9997
AC	173,707	9	19,3007	0,08	0,9998
AD	112,575	9	12,5083	0,05	1,0000
AE	248,466	6	41,411	0,18	0,9831
BC	2066,3	9	229,589	0,98	0,4532
BD	741,21	9	82,3567	0,35	0,9571
BE	512,206	6	85,3676	0,36	0,9013
CD	9,42E+06	9	1,05E+06	4474,65	0,0000
CE	446556	6	74426	318,18	0,0000
DE	493532	6	82255,3	351,65	0,0000
ABC	596,47	27	22,0915	0,09	1,0000
ABD	573,894	27	21,2553	0,09	1,0000
ABE	412,86	18	22,9367	0,1	1,0000
ACD	791,436	27	29,3124	0,13	1,0000
ACE	490,885	18	27,2714	0,12	1,0000
ADE	232,579	18	12,9211	0,06	1,0000
BCD	6197,81	27	229,549	0,98	0,4918
BCE	4088,1	18	227,117	0,97	0,4911
BDE	1428,92	18	79,3846	0,34	0,9957
CDE	117747	18	6541,49	27,97	0,0000
ABCD	1816,6	81	22,4271	0,1	1,0000
ABCE	1202,72	54	22,2726	0,1	1,0000
ABDE	1247,48	54	23,1015	0,1	1,0000
ACDE	1561,81	54	28,9223	0,12	1,0000
BCDE	11738,8	54	217,385	0,93	0,6213
RESIDUAL	397185	1698	233,913		
TOTAL (CORRECTED)	1,08E+08	2303			

Figura A3.1.2 Análisis de varianza experimento con variable respuesta tiempo de ejecución.

Means and 95,0 Percent LSD Intervals

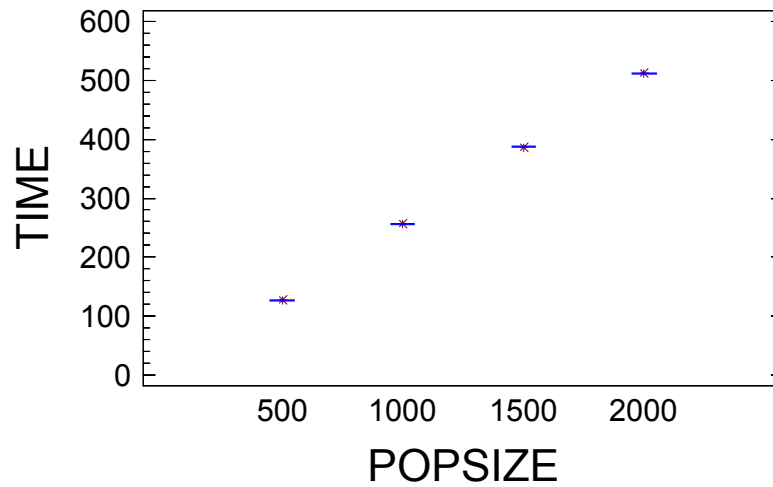


Figura A3.1.3 Gráfico de medias e intervalos de confianza para POPSIZE.

Means and 95,0 Percent LSD Intervals

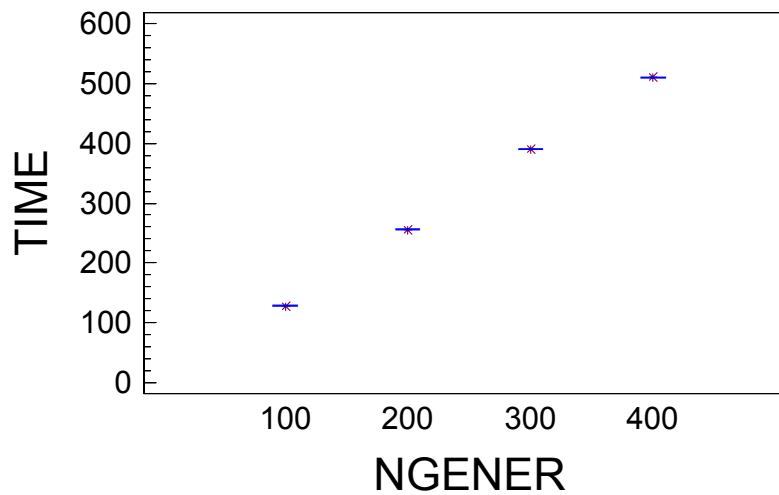


Figura A3.1.4 Gráfico de medias e intervalos de confianza para NGENER.

Means and 95,0 Percent LSD Intervals

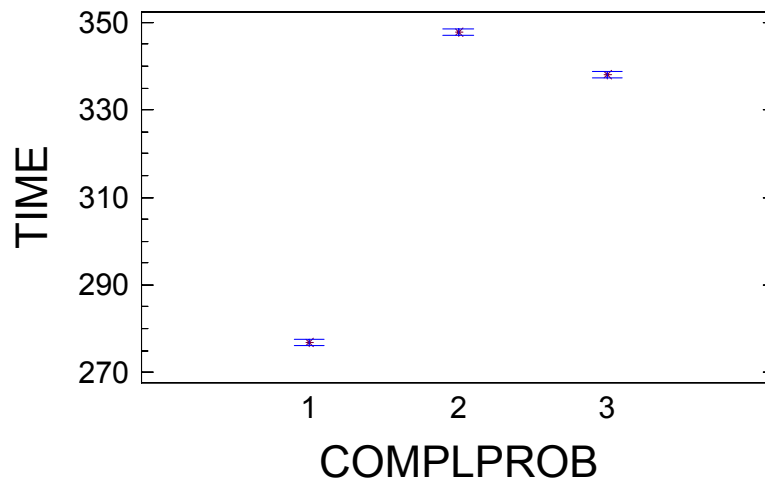


Figura A3.1.5 Gráfico de medias e intervalos de confianza para COMPLPROB.

Además, existe interacción significativa entre los factores: POPSIZE y NGENER, y POPSIZE y COMPLPROB, como se observa gráficamente en las figuras A3.1.6 y A3.1.7. También existe interacción entre los factores POPSIZE, NGENER y COMPLPROB.

Interaction Plot

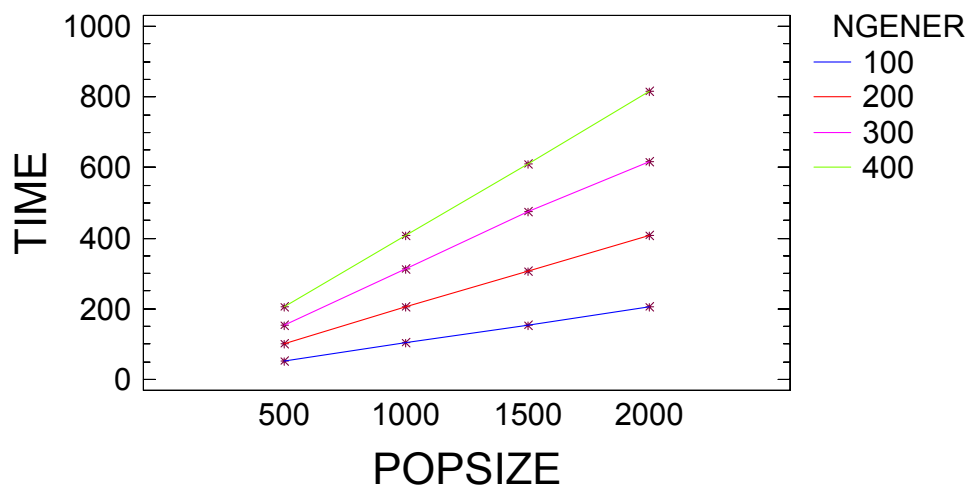


Figura A3.1.6 Gráfico de interacciones entre NGENER y POPSIZE.

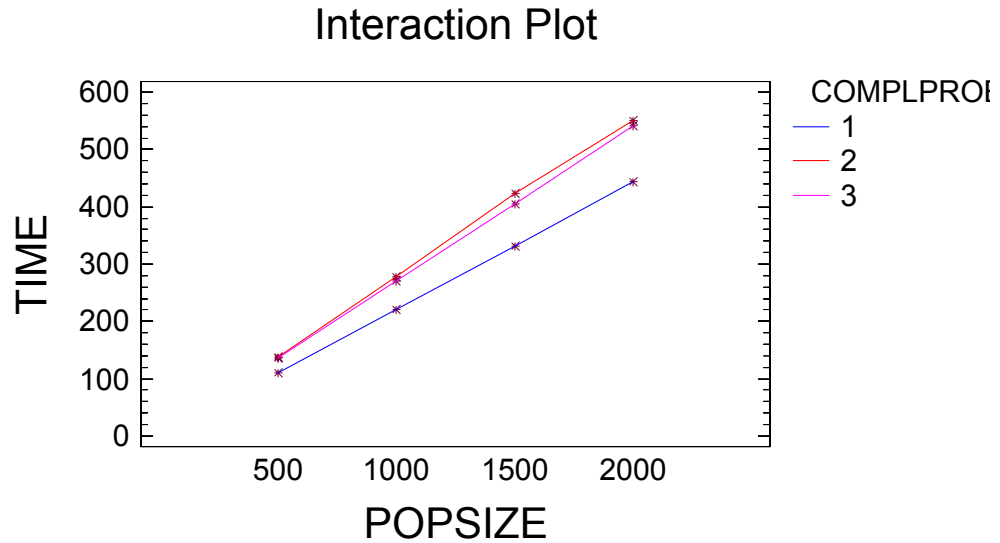


Figura A3.1.7 Gráfico de interacciones entre COMPLPROB y POPSIZE.

A 3.2 Experimento 2

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:PMUT	6,8644E-06	1	6,8644E-06	8,08	0,0090
B:PCROSS	2,4419E-06	1	2,4419E-06	2,87	0,1029
C:COMPLPROB	9,9497E-05	2	4,9749E-05	58,56	0,0000
INTERACTIONS					
AB	1,7983E-06	1	1,7983E-06	2,12	0,1587
AC	4,9008E-06	2	2,4504E-06	2,88	0,0754
BC	7,1997E-07	2	3,60E-07	0,42	0,6594
ABC	6,3225E-07	2	3,16E-07	0,37	0,6932
RESIDUAL	2,0389E-05	24	8,50E-07		
TOTAL (CORRECTED)	0,000137244	35			

Figura A3.2.1 Análisis de varianza experimento 2.

A 3.3 Experimento 3

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:PMUT	0,000216	2	0,000107997	0,53	0,5901
B:PCROSS	0,000144	1	0,000144174	0,71	0,4019
C:POPSIZE	0,000443	1	0,0004427	2,17	0,1428
D:NGENER	0,000656	1	0,000656379	3,22	0,0749
E:COMPLPROB	0,000408	2	0,000204016	1	0,3703
INTERACTIONS					
AB	0,000269	2	0,000134543	0,66	0,5186
AC	0,000303	2	0,0001514	0,74	0,4779
AD	0,000449	2	0,000224266	1,1	0,3358
AE	0,001674	4	0,000418391	2,05	0,0902
BC	0,000193	1	0,000192674	0,94	0,3327
BD	0,000164	1	0,000163964	0,8	0,3714
BE	0,000235	2	0,000117727	0,58	0,5628
CD	0,000441	1	0,000441435	2,16	0,1434
CE	0,000445	2	0,000222339	1,09	0,3389
DE	0,000472	2	0,000236033	1,16	0,3173
ABC	0,000350	2	0,00017483	0,86	0,4265
ABD	0,000425	2	0,000212576	1,04	0,3553
ABE	0,000461	4	0,000115243	0,56	0,6885
ACD	0,000435	2	0,000217424	1,07	0,3471
ACE	0,000775	4	0,000193639	0,95	0,4375
ADE	0,000929	4	0,000232329	1,14	0,3406
BCD	0,000132	1	0,000132387	0,65	0,4218
BCE	0,000426	2	0,000213206	1,05	0,3542
BDE	0,000374	2	0,000187049	0,92	0,4020
CDE	0,000451	2	0,000225667	1,11	0,3335
ABCD	0,000326	2	0,000163057	0,8	0,4516
ABCE	0,000928	4	0,000232025	1,14	0,3413
ABDE	0,000635	4	0,000158848	0,78	0,5407
ACDE	0,001258	4	0,000314399	1,54	0,1932
BCDE	0,000438	2	0,000219244	1,07	0,3441
RESIDUAL	0,030193	148	0,000204007		
TOTAL (CORRECTED)	0,045049	215			

Figura A3.3.1 Análisis de varianza experimento 3.

A 3.4 Experimento 4

Selección de la variable respuesta:

La variable respuesta en este experimento es el valor de la función objetivo (FO) que se obtiene al aplicar el Algoritmo Genético con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se presentan en la figura A3.4.1. En este caso, PMUT, POPSIZE y NGENER tienen valores fijos, por lo que no se los considera como factores en el experimento.

Parámetro	Valores
PMUT	0,05
PCROSS	0,1; 0,2; 0,3; 0,4
POPSIZE	500
NGENER	200
COMPLPROB	1, 2, 3

Figura A3.4.1. Factores y niveles para experimento 4.

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- PCROSS: Una de las conclusiones del experimento 1 fue que se obtendrían buenos resultados con valores bajos de PCROSS, sin embargo, en experimentos posteriores no se encontró evidencia de que PCROSS tuviese un efecto en la calidad de la solución. Por esta razón es que se decide volver experimentar con niveles bajos para PCROSS, y determinar si tiene un efecto significativo, dadas las condiciones del presente experimento.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

El número de réplicas del experimento se fijó en tres.

Principales Resultados:

Para un nivel de confianza del 95%, se tiene que sólo COMPLPROB tiene un efecto significativo en el valor de FO, como se observa en el análisis de varianza presentado en la figura A3.4.2.

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:PCROSS	4,9706E-06	3	1,6569E-06	0,78	0,5188
B:COMPLPROB	0,000147941	2	7,3971E-05	34,65	0,0000
INTERACTIONS					
AB	8,65918E-06	6	1,4432E-06	0,68	0,6702
RESIDUAL	0,000051239	24	2,1350E-06		
TOTAL (CORRECTED)	0,000213	35			

Figura A3.4.2 Análisis de varianza experimento 4.




Figura A3.4.3. Gráfico de medias e intervalos de confianza para COMPLPROB.

En el caso de PCROSS, no tiene un efecto significativo en la función objetivo, como se observa gráficamente en la figura A3.4.4.

Respecto a las interacciones entre los factores, para un nivel de confianza del 95%, no hay interacciones significativas entre los factores considerados.

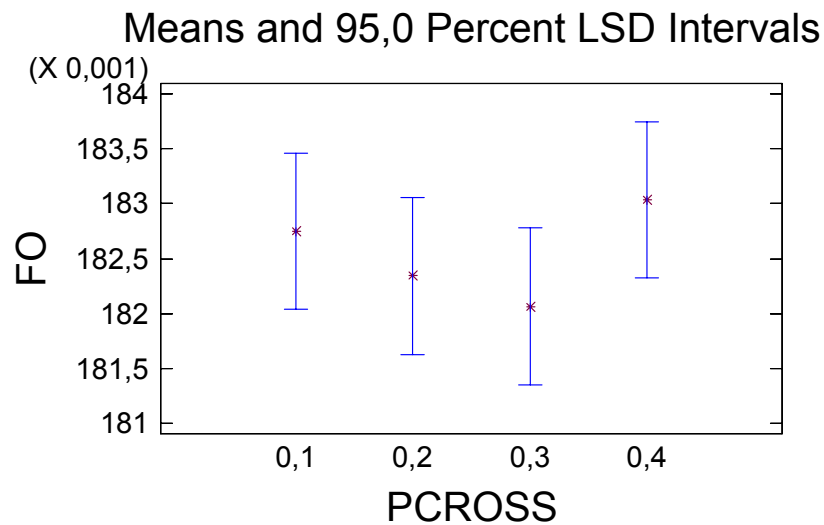


Figura A3.4.4. Gráfico de medias e intervalos de confianza para PCROSS.

A 3.5 Experimento 5

El objetivo de este experimento es determinar si valores altos de PCROSS, dejando fijos los valores para los demás parámetros, tienen un efecto en la calidad de las soluciones.

Selección de la variable respuesta:

Valor de la función objetivo (FO) que se obtiene al aplicar el Algoritmo Genético con los distintos valores seleccionados para los parámetros.

Factores y Niveles:

Los factores y sus niveles considerados en este experimento se presentan en la figura A3.5.1. En este caso, PMUT, POPSIZE y NGENER tienen valores fijos, por lo que no se los considera como factores en el experimento.

Parámetro	Valores
PMUT	0,05
PCROSS	0,5; 0,6; 0,7; 0,8; 0,9
POPSIZE	500
NGENER	200
COMPLPROB	1, 2, 3

Figura A3.5.1. Factores y niveles para experimento 5.

Los niveles para cada uno de los factores fueron seleccionados por las siguientes razones:

- PCROSS: Una de las conclusiones del experimento 1 fue que se obtendrían buenos resultados con valores bajos de PCROSS, sin embargo, en experimentos posteriores no se encontró evidencia de que este factor tuviese un efecto significativo en la calidad de las soluciones. Por esta razón es que se decide experimentar con niveles altos para PCROSS, y determinar si tiene un efecto significativo, dadas las condiciones del presente experimento.
- COMPLPROB: Los niveles considerados para este factor son tres: 1 (problema pequeño), 2 (problema mediano) y 3 (problema grande), que corresponden a los problemas de prueba AP2, AM2 y AG2, respectivamente.

Número de réplicas:

El número de réplicas del experimento se fijó en tres.

Principales Resultados:

El análisis de varianza para este experimento se presenta en la figura A3.5.2.

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:PCROSS	1,20204E-05	4	3,0051E-06	1,08	0,3851
B:COMPLPROB	0,000223802	2	0,000111901	40,12	0,0000
INTERACTIONS					
AB	2,30402E-05	8	2,88002E-06	1,03	0,4342
RESIDUAL	8,36775E-05	30	2,78925E-06		
TOTAL (CORRECTED)		0,00034		44	

Figura A3.5.2 Análisis de varianza experimento 5.

Para un nivel de confianza del 95%, sólo COMPLROB tiene un efecto significativo en el valor obtenido de la función objetivo, lo cual se observa gráficamente en las figuras A3.5.3 y A3.5.4. Por otra parte, no hay interacciones significativas entre estos factores.




Figura A3.5.3 Gráfico de medias e intervalos de confianza para PCROSS.




Figura A3.5.4 Gráfico de medias e intervalos de confianza para COMPLPROB.

A 3.6 Confirmación parámetros Algoritmo Genético

Problema	Solución (Rollizos por tipo)						% Pérdida	Tiempo (s)
	r1	r2	r3	r4	r5	r6		
AP1	5	2	6	5	1	2	18,25%	4385
AP2	18	3	8	5	6	9	18,18%	5427
AP3	31	1	1	10	28	0	18,02%	6106
AM1	7	15	13	15	18	14	17,33%	6459
AM2	27	14	22	13	36	13	17,92%	6414
AM3	43	28	55	34	38	32	17,72%	5977
AM4	101	24	85	47	37	48	18,28%	6609
AM5	53	15	116	82	30	78	17,95%	6398
AM6	110	66	127	94	137	67	17,97%	6736
AG1	89	48	240	77	123	130	17,89%	6659
AG2	177	149	210	117	208	109	17,85%	5005

Figura A3.6.1 Resultados al aplicar una vez el Algoritmo Genético para todos los problemas de prueba.

Anexo 4 Resultados

A 4.1 Resultados Simulated Annealing

Problema	Réplica	Solución (rollizos por tipo)						% Pérdida	Tiempo(s)	% Pérdida promedio	Tiempo promedio (s)
		r1	r2	r3	r4	r5	r6				
AP1	1	5	2	3	3	3	3	19,56%	31	20,01%	29
	2	4	3	3	3	3	3	20,13%	28		
	3	4	3	3	3	3	3	20,13%	29		
	4	4	3	3	3	3	3	20,13%	28		
	5	4	3	3	3	3	3	20,13%	29		
AP2	1	9	9	9	9	9	8	32,93%	31	32,93%	30,6
	2	9	9	9	9	9	8	32,93%	30		
	3	9	9	9	9	9	8	32,93%	31		
	4	9	9	9	9	9	8	32,93%	31		
	5	9	9	9	9	9	8	32,93%	30		
AP3	1	13	15	13	12	12	11	32,55%	35	32,93%	34,6
	2	14	13	13	12	12	12	33,02%	35		
	3	14	13	13	12	12	12	33,02%	34		
	4	14	13	13	12	12	12	33,02%	34		
	5	14	13	13	12	12	12	33,02%	35		
AM1	1	7	7	6	29	4	24	19,76%	57	18,86%	56,6
	2	11	8	5	8	35	10	18,27%	55		
	3	10	8	8	2	39	10	18,89%	60		
	4	13	7	6	2	39	10	18,22%	53		
	5	3	11	10	27	3	23	19,16%	58		
AM2	1	21	15	15	12	43	11	18,20%	47	20,53%	49,4
	2	19	17	14	11	47	9	18,47%	47		
	3	19	18	13	13	42	12	18,52%	48		
	4	24	2	29	27	7	28	18,41%	59		
	5	3	34	34	31	33	4	29,07%	46		
AM3	1	36	15	26	32	80	14	17,95%	61	18,33%	67
	2	31	26	30	16	80	20	18,08%	64		
	3	35	29	25	13	79	24	18,67%	56		
	4	24	4	78	22	38	37	18,47%	90		
	5	53	2	31	21	53	43	18,49%	64		
AM4	1	67	74	64	57	61	57	31,85%	38	32,08%	37,8
	2	69	68	64	61	59	59	32,09%	37		
	3	68	69	64	59	61	59	32,17%	38		
	4	69	64	68	61	59	59	32,19%	38		
	5	69	68	64	61	59	59	32,09%	38		

Figura A4.1.1 Resultados al ejecutar Simulated Annealing con valores definitivos para los parámetros, parte1.

Problema	Réplica	Solución (rollizos por tipo)						% Pérdida	Tiempo(s)	% Pérdida promedio	Tiempo promedio (s)
		r1	r2	r3	r4	r5	r6				
AM5	1	37	23	145	23	20	118	19,83%	74	18,88%	68,8
	2	0	112	51	48	112	43	18,39%	63		
	3	102	1	23	62	117	62	18,87%	73		
	4	87	7	70	3	136	63	18,84%	71		
	5	0	95	74	71	63	63	18,45%	63		
AM6	1	139	18	135	124	55	124	18,54%	62	20,76%	73,2
	2	105	36	159	141	34	120	18,62%	68		
	3	117	86	67	58	218	50	18,87%	55		
	4	71	36	237	60	50	141	20,30%	129		
	5	0	203	202	149	142	1	27,49%	52		
AG1	1	81	45	236	81	43	207	19,29%	81	18,80%	79,4
	2	80	64	231	44	43	231	19,72%	85		
	3	85	57	209	27	196	119	18,60%	70		
	4	103	17	193	151	97	132	17,99%	92		
	5	0	179	139	105	179	91	18,42%	69		
AG2	1	75	61	315	61	183	150	18,80%	91	18,67%	100,8
	2	2	258	118	115	258	94	18,45%	70		
	3	113	1	303	164	101	163	18,26%	153		
	4	82	74	309	76	65	239	19,29%	113		
	5	3	258	120	107	259	98	18,53%	77		

Figura A4.1.2 Resultados al ejecutar Simulated Annealing con valores definitivos para los parámetros, parte 2.

A 4.2 Resultados promedio Algoritmo Genético

Problema	Réplica	Solución (rollizos por tipo)						% Pérdida	Tiempo (s)	% Pérdida promedio
		r1	r2	r3	r4	r5	r6			
AP1	1	4	2	8	3	3	1	18,73%	1426	18,48%
	2	5	2	6	5	1	2	18,25%	1427	
	3	4	2	3	5	5	0	18,31%	1427	
	4	4	2	6	5	1	2	18,25%	1426	
	5	3	2	5	4	5	0	18,84%	1427	
AP2	1	20	4	4	5	9	8	18,27%	1766	18,33%
	2	22	3	4	5	8	9	18,37%	1766	
	3	19	3	3	7	7	9	18,35%	1766	
	4	16	4	3	3	11	8	18,39%	1766	
	5	20	2	7	7	4	10	18,25%	1766	
AP3	1	31	3	3	14	16	6	18,06%	1965	18,06%
	2	27	3	3	13	18	5	18,04%	1963	
	3	27	2	4	18	9	9	18,07%	1964	
	4	25	4	10	8	13	9	18,07%	1964	
	5	31	4	3	8	24	3	18,06%	1966	
AM1	1	13	3	12	23	13	16	17,50%	2065	17,41%
	2	8	9	15	20	11	17	17,39%	2064	
	3	7	12	13	17	16	15	17,38%	2064	
	4	10	16	10	17	19	13	17,32%	2064	
	5	5	12	13	12	21	14	17,45%	2065	
AM2	1	35	12	9	14	51	6	18,00%	2083	17,98%
	2	34	8	8	22	49	4	17,93%	2084	
	3	44	4	4	26	49	4	18,00%	2088	
	4	33	7	22	25	20	20	18,00%	2126	
	5	22	14	12	17	43	9	17,95%	2138	
AM3	1	62	1	52	58	12	45	17,93%	1971	17,87%
	2	28	28	41	32	54	26	17,80%	1982	
	3	55	15	58	29	40	35	17,92%	1977	
	4	14	36	42	33	55	23	17,80%	1960	
	5	47	13	29	47	55	24	17,89%	1944	
AM4	1	108	1	74	80	4	64	18,51%	2152	18,44%
	2	141	19	20	66	88	23	18,47%	2150	
	3	118	33	40	63	66	32	18,44%	2150	
	4	126	25	73	55	38	47	18,31%	2150	
	5	96	16	107	19	37	58	18,47%	2150	

Figura A4.2.1 Resultados promedio obtenidos por el Algoritmo Genético para todos los problemas de prueba, parte 1.

Problema	Réplica	Solución (rollizos por tipo)						% Pérdida	Tiempo (s)	% Pérdida promedio
		r1	r2	r3	r4	r5	r6			
AM5	1	32	80	58	65	105	39	17,90%	2081	17,95%
	2	85	42	99	75	54	65	17,97%	2081	
	3	85	31	111	49	66	68	18,01%	2081	
	4	55	26	105	68	52	71	17,98%	2082	
	5	67	60	57	57	122	34	17,89%	2081	
AM6	1	159	86	102	88	176	47	18,10%	2190	18,07%
	2	215	62	98	103	155	60	18,07%	2190	
	3	188	69	124	88	146	64	17,97%	2189	
	4	152	40	152	105	92	92	18,07%	2191	
	5	233	36	89	138	122	74	18,11%	2191	
AG1	1	171	34	211	132	97	132	17,87%	2167	17,88%
	2	164	77	155	112	174	96	17,84%	2167	
	3	118	60	156	108	176	100	17,91%	2167	
	4	126	63	179	110	153	107	17,90%	2167	
	5	127	48	220	88	132	124	17,88%	2167	
AG2	1	130	108	219	158	154	132	17,88%	2114	17,85%
	2	102	124	231	153	149	131	17,83%	2115	
	3	109	130	200	162	170	120	17,84%	2115	
	4	125	166	183	138	210	102	17,81%	2116	
	5	185	116	204	156	171	124	17,88%	2114	

Figura A4.2.2 Resultados promedio obtenidos por el Algoritmo Genético para todos los problemas de prueba, parte 2.

A 4.3 Comparación entre ambos algoritmos

Analysis of Variance for FO - Type III Sums of Squares

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
MAIN EFFECTS					
A:HEURISTICA	0,05270	1	0,0527	293,34	0,0000
B:PROBLEMA	0,10746	10	0,0107	59,82	0,0000
INTERACTIONS					
AB	0,09008	10	0,0090	50,14	0,0000
RESIDUAL	0,01581	88	0,0002		
TOTAL (CORRECTED)	0,26604	109			

Figura A4.3.1 Análisis de varianza experimento comparación entre ambos algoritmos.

Problema	Pérdida Promedio (%)	
	S. Annealing	Algoritmo Genético
AP1	20,01%	19,76%
AP2	32,93%	19,17%
AP3	32,93%	18,80%
AM1	18,86%	17,77%
AM2	20,53%	18,69%
AM3	18,33%	18,25%
AM4	32,08%	18,99%
AM5	18,88%	18,42%
AM6	20,76%	18,47%
AG1	18,80%	18,17%
AG2	18,67%	18,16%

Figura A4.3.2 Resultados promedio comparación entre ambos algoritmos.