

Planificación del aprovechamiento forestal utilizando algoritmos genéticos

Forest harvest planning using genetic algorithms

MARÍA ALEJANDRA QUINTERO M.¹,
MAGDIEL ABLAN²
y MAURICIO JEREZ³

1 Universidad de Los Andes, Facultad de Ciencias Forestales y Ambientales, Departamento de Botánica y Ciencias Básicas, Mérida, Venezuela, Correo electrónico: mariaq@ula.ve

2 Universidad de Los Andes, Facultad de Ingeniería, Centro de Simulación y Modelos (Cesimo), Mérida, Venezuela, Correo electrónico: mablan@ula.ve

3 Universidad de Los Andes, Facultad de Ciencias Forestales y Ambientales, Centro de Estudios Forestales y Ambientales de Postgrado, Mérida, Venezuela, Correo electrónico: jerez@ula.ve

Recibido: 15-03-10 / Aceptado: 08-09-10

Resumen

En este artículo se presenta una introducción a los algoritmos genéticos, técnica heurística que puede ser utilizada para resolver diversos problemas de planificación forestal. Al igual que otras heurísticas los algoritmos genéticos pueden encontrar, en un tiempo de computación aceptable, una buena solución a problemas de optimización que en muchos casos no pueden resolverse con técnicas clásicas de programación matemática, tales como la programación lineal y sus extensiones. Para ilustrar el potencial que tienen los algoritmos genéticos en el campo de la planificación forestal, se utiliza un ejemplo de planificación del aprovechamiento en una plantación, en el que se desea obtener una secuencia de cortas que minimice los costos y satisfaga los requerimientos de madera de una planta de producción de pulpa. Primero, el problema se resolvió utilizando una técnica de programación matemática (programación entera binaria), mediante la cual se obtuvo la solución óptima. Luego, se diseñó un algoritmo genético y se evaluó su eficiencia en términos del valor objetivo (costo total de aprovechamiento), error relativo con respecto a la solución óptima, eficacia y tiempo de ejecución. El algoritmo genético tuvo un excelente desempeño, presentó un error relativo promedio de 0,24%, una eficacia del 99,76% y un tiempo de ejecución 58,8% menor que el tiempo requerido para resolver el modelo mediante programación entera binaria.

Palabras clave: heurísticas, programación matemática, programación entera binaria, algoritmos evolutivos, planificación forestal.

Abstract

In this paper, an introduction to genetic algorithms is presented. This is an heuristic technique that can be suited for solving several problems in forest planning. As other heuristics, the genetic algorithms can find, in an acceptable computing time, a good solution to optimization problems that, in many cases, can not be solved with classic techniques of mathematical programming, such as lineal programming and its variants. For illustrating the potential of the Genetic Algorithm (GA) in the field of Forest Planning, an example of harvest planning for a plantation is shown in which the goal is to obtain the harvest sequence that minimize the operation costs and satisfy the wood requirements of a pulp mill. First, the problem was solved by using a mathematical programming technique (binary integer programming), in order to obtain the optimal solution. Thereafter, a GA was designed and its efficiency was assessed in terms of the objective value (total harvest cost), relative error in relation to the optimal solution, efficiency, and execution time. The GA had an excellent performance, showing a relative error of 0,24%, an efficiency of 99,76%, and an execution time 58,8 % lower than that needed for solving the model with integer binary programming.

Key words: heuristics, mathematical programming, binary integer programming, evolutionary algorithms, forest planning.

1. Introducción

En las últimas décadas la planificación forestal ha venido apoyándose en modelos cuantitativos para facilitar los procesos de toma de decisiones, estos modelos proporcionan información pertinente para seleccionar las alternativas de manejo más adecuadas y permiten lograr una mejor comprensión de los efectos que puede generar cualquier

decisión. Se han utilizado diferentes enfoques de modelado, destacándose entre ellos la programación matemática cuyo principio es la optimización (maximización o minimización) de una función (llamada función objetivo) que puede estar sujeta a un conjunto de restricciones. La programación matemática comprende un conjunto de técnicas tales como la programación lineal y sus derivadas (programación por metas, programación entera,

programación lineal probabilística), programación cuadrática, programación dinámica y programación no lineal. Un problema de planificación forestal que puede abordarse con técnicas de programación matemática es la planificación del aprovechamiento que consiste en decidir cuándo, dónde y cuánta madera cortar para alcanzar ciertos objetivos como por ejemplo la maximización de beneficios, maximización del volumen de madera aprovechado, minimización de costos, tomando en consideración un conjunto de restricciones operativas, ambientales, legales, entre otras.

Los algoritmos existentes para resolver modelos de programación matemática encuentran el valor de las variables que minimizan o maximizan la función objetivo y que a su vez cumplen con todas las restricciones impuestas, es decir, consiguen la solución óptima de un problema. Estos algoritmos fallan cuando los modelos de planificación forestal son complejos, como por ejemplo: modelos de grandes dimensiones con muchas variables y/o restricciones; problemas en los que se desea optimizar simultáneamente múltiples objetivos (económicos, ambientales, sociales); modelos que utilizan relaciones funcionales complejas; y problemas que incluyen aspectos espaciales. En estos casos, un conjunto de técnicas denominadas heurísticas constituyen una buena alternativa de solución. Las heurísticas son procedimientos simples que obtienen una buena solución, no necesariamente óptima, a un problema difícil en un tiempo de computación razonable.

Entre las heurísticas con mayor potencial para resolver problemas de planificación forestal se encuentran los algoritmos genéticos, una técnica de búsqueda desarrollada por Holland (1975) e inspirada en la teoría de evolución de Darwin. En el campo de la optimización los algoritmos genéticos han sido utilizados con bastante éxito en una gran cantidad de problemas en diferentes áreas del conocimiento, ya que pueden alcanzar soluciones óptimas o cercanas al óptimo cuando los métodos exactos presentan dificultades. Dentro de las heurísticas, los algoritmos genéticos se han destacado como una técnica de optimización robusta y eficiente, y se consideran promisorios para solucionar problemas de optimización difíciles de resolver como los que se presentan en planificación forestal (Rodrigues *et al.*, 2004).

En la literatura se encuentran algunas aplicaciones de los algoritmos genéticos para resolver problemas de planificación forestal. Uno de los primeros trabajos es el modelo de programación de cosechas desarrollado por Falcão y Borges (2001), el cual utiliza variables binarias para representar las alternativas de manejo de un conjunto de rodales con restricciones de volumen. Ducheyne *et al.* (2004) utilizan algoritmos genéticos para resolver un problema de planificación del aprovechamiento con variables enteras en el que se busca maximizar el valor presente neto y minimizar las desviaciones entre períodos de corta sucesivos. Rodrigues *et al.* (2004) desarrollaron un algoritmo genético para resolver cuatro problemas de planificación forestal de diferentes dimensiones, en todos se desea maximizar el valor presente neto con restricciones de singularidad, producción máxima y mínima. Hay investigaciones en las que se utilizan algoritmos genéticos para elaborar planes forestales que incluyen restricciones espaciales relacionadas al tamaño, forma y disposición de las unidades de manejo, puede citarse el trabajo de Lu y Eriksson (2000) quienes desarrollaron un algoritmo genético para delimitar unidades de manejo forestal en el marco de la planificación operacional. También los modelos de Ducheyne *et al.* (2006) y Thompson *et al.* (2009) implementan diferentes estrategias en los algoritmos genéticos para resolver problemas con restricciones espaciales. En otras investigaciones se hacen comparaciones en el marco de la planificación forestal, entre los algoritmos genéticos y otras técnicas heurísticas como recocido simulado, búsqueda tabú, métodos de búsqueda escaladores (*hill-climbing*). En este grupo se encuentran los trabajos de Falcão y Borges (2002), Palahí *et al.* (2004), Pukkala y Kurttila (2005), Liu *et al.* (2006). Cabe señalar que en Venezuela a pesar que se han utilizado los algoritmos genéticos en diversas áreas de la ciencia, no existen publicaciones que refieran aplicaciones en el campo forestal.

En este artículo se describen los fundamentos básicos de los algoritmos genéticos y se ilustra su aplicación al resolver un problema de planificación de cortas en una plantación forestal que busca minimizar los costos de aprovechamiento considerando un conjunto de restricciones operativas. Los objetivos del trabajo son: 1) mostrar el potencial de los algoritmos genéticos mediante la resolución de

un problema ilustrativo de planificación del aprovechamiento forestal; y 2) evaluar la eficiencia del algoritmo genético desarrollado en comparación a una técnica clásica de programación matemática como lo es la programación entera binaria.

2. Materiales y métodos

2.1 Algoritmos genéticos

Son métodos de búsqueda que recorren el espacio de soluciones de un problema en forma aleatoria, utilizando una analogía con la evolución de las especies. Los algoritmos genéticos evalúan simultáneamente un conjunto de soluciones del problema al que se le denomina población. A una solución se le denomina individuo y es representada mediante una cadena de caracteres, siendo la representación binaria la más común; en terminología de los algoritmos genéticos la estructura de datos que representa una de las posibles soluciones del problema corresponde a un cromosoma y cada uno de los elementos que conforman un cromosoma se denomina gen. La figura 1 ilustra estos conceptos.

Las soluciones se evalúan de acuerdo una función de adaptación (*fitness*) que mide su calidad y les asocia un valor único que corresponde a un número real no negativo, que es más grande cuanto mejor sea la solución; en la naturaleza esto equivaldría al grado de efectividad de un organismo para competir por unos determinados recursos, poder sobrevivir y reproducirse (Kuri, 2000). La función de adaptación está relacionada con la función objetivo que se desea optimizar; si el problema es de

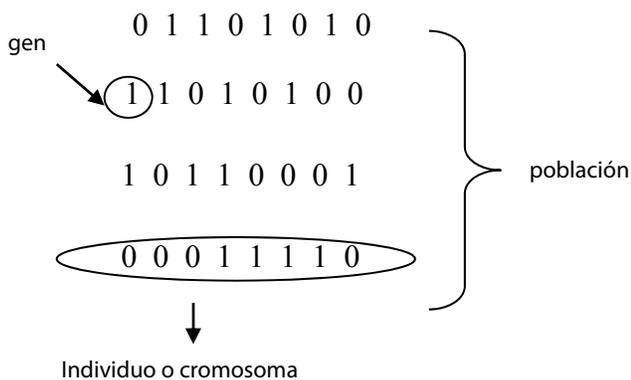


Figura 1. Conceptos básicos de los algoritmos genéticos.

maximización, la adaptación debe indicar qué tan alto es el valor de la función objetivo para un individuo particular. Cuando se trata de un problema de minimización, la adaptación para un individuo debe ser tanto más alta cuanto más pequeño sea su valor objetivo. En algunos casos pueden coincidir la función objetivo y la función de adaptación, pero esto no es lo más común, en la mayoría de los problemas es necesario establecer una equivalencia entre la función de adaptación y la función objetivo. La función de adaptación se debe construir cuidadosamente, ya que su calidad puede influir de manera considerable en la eficiencia de un algoritmo genético (Dréo *et al.*, 2006).

El procedimiento que utilizan los algoritmos genéticos para resolver un problema de optimización es evaluar una población de soluciones, y a partir ésta crear una nueva población utilizando operadores genéticos diseñados para tal fin. La nueva población reemplaza a la anterior y verifica la interesante propiedad de que contiene una mayor proporción de buenas características en comparación con la población anterior (Cabezas, 2002). Este proceso se repite un determinado número de iteraciones (generaciones), después de varios ciclos de evolución la población deberá contener individuos más aptos y al final, si el algoritmo genético ha sido bien diseñado, la población convergerá hacia una solución óptima del problema. Al finalizar una corrida de un algoritmo genético hay uno o más individuos con una alta adaptación, aquel que tenga la mayor adaptación se considera la solución del problema.

Los operadores genéticos son los mecanismos que garantizan la evolución de los individuos, creando a partir de una población inicial nuevas poblaciones o generaciones de individuos mejorados. Los tres operadores básicos que operan en los algoritmos genéticos son selección, mutación y cruzamiento.

El operador de selección elige individuos en una población para su reproducción o supervivencia en el algoritmo genético, su objetivo es resaltar las mejores soluciones dentro de una población. Este operador no genera soluciones nuevas en el espacio de búsqueda, sino que determina qué individuos dejarán descendencia y en qué cantidad en la próxima generación (Deb, 2000). La idea básica es que las soluciones que tienen mayor adaptación

tienen mayor probabilidad de selección. Así, la selección permite orientar la búsqueda hacia aquellos puntos más promisorios, es decir, con la mayor adaptación observada hasta el momento (Estévez, 1997). Hay diferentes maneras de implementar el operador de selección, cada una de las cuales define en forma diferente una distribución de probabilidad basada en la adaptación.

El cruzamiento es una de las operaciones fundamentales que intervienen en todo algoritmo genético. Se aplica a dos individuos (padres) y consiste en una combinación de los mismos para obtener como resultado otros dos nuevos individuos (hijos). En el cruzamiento se reemplazan algunos genes de un padre por los genes correspondientes del otro padre. El cruzamiento puede implementarse de varias formas, una manera sencilla es definir un punto de cruzamiento e intercambiar los genes de los padres siguientes a esta posición para dar origen a un hijo, luego intercambiar los genes anteriores (incluyendo el punto de cruzamiento) para crear otro hijo. Por ejemplo, supóngase que se tienen dos individuos 10011100 y 00010111 los cuales se cruzan utilizando como punto de cruzamiento el gen 4, los hijos resultantes son 10010111 y 00011100. En otras palabras, durante el cruzamiento se combinan dos soluciones del problema para dar origen a dos nuevas soluciones.

El tercer operador genético básico es la mutación, que consiste en cambiar alguna(s) de las características de un individuo para crear un nuevo individuo. La mutación escoge aleatoriamente un subconjunto de genes de un individuo y cambia su valor, el tamaño del subconjunto de genes puede ser un número predeterminado. Cuando se cambia sólo un gen se le denomina al proceso mutación simple, por ejemplo, si se tiene el individuo 10011100 y se muta el gen 2, el individuo resultante sería 11011100. Otra manera de implementar la mutación es examinar cada gen de un individuo y de acuerdo a una cierta probabilidad (usualmente muy pequeña) cambiar su valor, en este caso no se sabe de antemano cuántos genes serán cambiados en la mutación (Reeves, 1996). La mutación permite generar nuevas soluciones que exploren regiones del dominio del problema que probablemente no se han visitado aún, favoreciendo la diversidad en la población de soluciones.

En la figura 2 se presenta un diagrama de flujo con los pasos de un algoritmo genético simple en el

que se utiliza una población de tamaño N , se realiza una selección proporcional a la adaptación, y se aplican los operadores de cruzamiento y mutación con probabilidad P_c y P_m , respectivamente. El procedimiento descrito en la figura 2 es la base para diversas aplicaciones de algoritmos genéticos, hay también versiones mucho más complicadas que utilizan formas diferentes de los operadores genéticos básicos de selección, cruzamiento y mutación, incluso pueden incluir otros operadores.

2.2 El problema

Se requiere planificar un sistema de cortas para una unidad de producción forestal hipotética que permita abastecer de madera en forma continua a una planta de producción de pulpa para cartón, de manera que el costo total de aprovechamiento sea mínimo. La unidad de producción forestal está conformada por seis rodales de una misma especie (eucalipto) y los requerimientos de la planta son de 20000 toneladas anuales. El plan de cortas debe establecerse para un período de cinco años y el aprovechamiento anual de madera puede realizarse en uno o más rodales, pero un mismo rodal sólo puede aprovecharse una vez durante el período de planificación.

El costo total de aprovechamiento incluye costo de cosecha, costo de transportar la madera a la planta y costo de oportunidad, referido al gasto que se incurre al cortar un determinado rodal en un año diferente al considerado como turno óptimo. El costo de cosecha se consideró constante para todos los rodales, los costos de transporte dependen de la distancia de cada rodal a la planta, y los costos de oportunidad fueron calculados de acuerdo al enfoque de alternativas financieras utilizado por Chiari *et al.* (2008). En los cálculos se utilizó una edad mínima de corta de 6 años y el turno óptimo se fijó en 7 años. Los datos necesarios para formular el modelo se muestran en los cuadros 1, 2 y 3. Los costos se expresan en unidades monetarias (u.m.) sin especificación de alguna moneda particular.

2.3 Modelo matemático

La función objetivo del modelo consiste en minimizar el costo total de aprovechamiento (Ecuación 1).

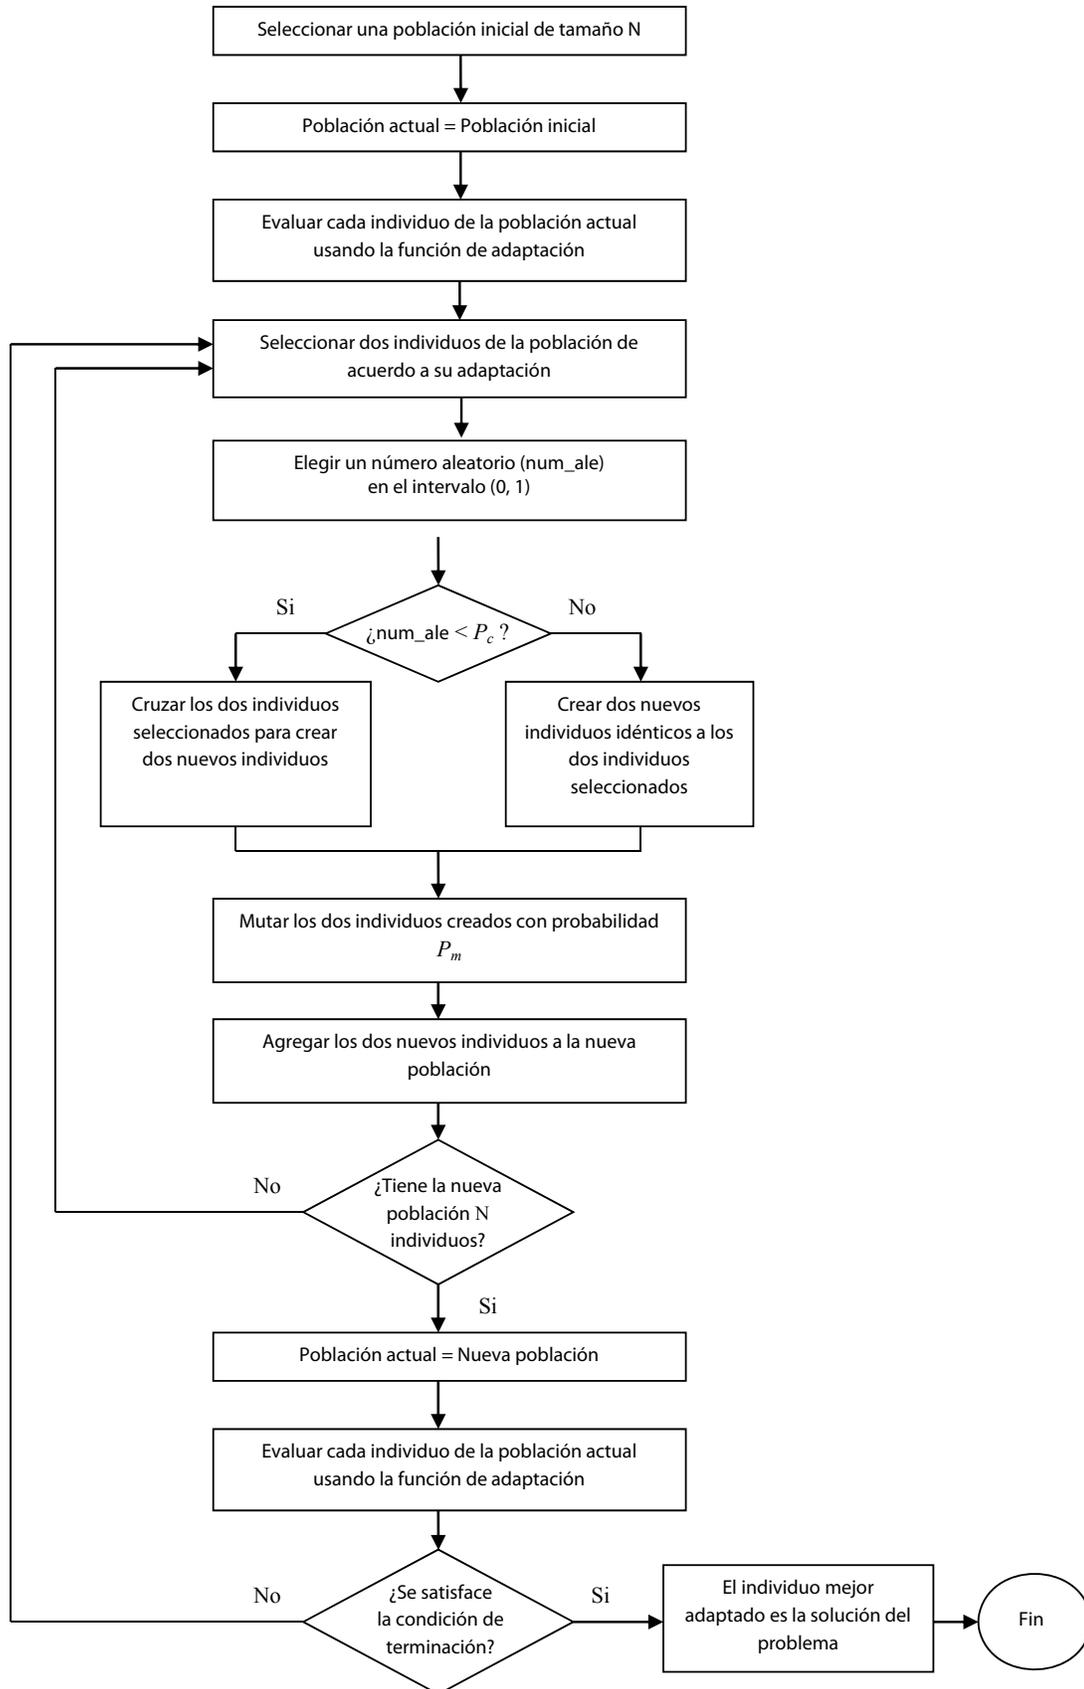


Figura 2. Diagrama de flujo del algoritmo genético simple.

$$\text{Minimizar } Z = \sum_{i=1}^6 \sum_{j=1}^5 C_{ij} * X_{ij} \quad (\text{Ec.1})$$

Donde:

C_{ij} = costo total de aprovechamiento (costo de cosecha + costo de transporte + costo de oportunidad) si se corta el rodal i en el año j

X_{ij} = variable de decisión binaria cuyo valor es igual a 1 si se corta el rodal i en el año j , y vale 0 en caso contrario

La función objetivo está sujeta al siguiente conjunto de restricciones:

$$\sum_{i=1}^6 V_{ij} * X_{ij} \geq 20000 \quad j = 1, 2, \dots, 5 \quad (\text{Ec.2})$$

$$\sum_{j=1}^5 X_{ij} = 1 \quad i = 1, 2, \dots, 6 \quad (\text{Ec.3})$$

$$X_{ij} = (0, 1) \quad i = 1, 2, \dots, 6; \quad j = 1, 2, \dots, 5 \quad (\text{Ec.4})$$

Para estas restricciones, V_{ij} es el volumen total (toneladas) presente en el rodal i el año j .

El primer grupo de restricciones (Ecuación 2) indica que la sumatoria del volumen extraído en todos los rodales a aprovechar en un año debe ser igual o mayor a la cuota anual establecida para cumplir con la demanda de la planta; el segundo grupo (Ecuación 3) son las restricciones de singularidad, que se refieren al hecho que un rodal sólo puede ser cortado en un año del período de planificación, la igualdad de estas restricciones indica que al final del período de planificación todos los rodales deben haber sido aprovechados; y el tercer grupo (Ecuación 4) indica que las variables de decisión del modelo son binarias.

2.4 Solución mediante programación entera binaria

Para tener una referencia acerca de cuál es la solución óptima del problema y poder evaluar la eficiencia del algoritmo genético diseñado, se resolvió el modelo utilizando una técnica de programación matemática, en este caso la apropiada es la programación entera binaria, porque permite plantear modelos de optimización en los que las variables de decisión son binarias y tanto la función objetivo como las restricciones son lineales.

La solución óptima se obtuvo con el software de optimización SAS OR, específicamente este pro-

grama utilizó el algoritmo de ramificación y acotamiento, el cual puede resolver modelos de programación entera y sus variantes: programación entera pura, mixta o binaria (SAS, 2004).

2.5 Solución mediante algoritmos genéticos

Se diseñó un algoritmo genético para resolver el problema planteado y se implementó utilizando el lenguaje de programación Visual Basic 6.0. Para el desarrollo del algoritmo genético fue necesario definir un conjunto de estrategias de solución las cuales se describen a continuación.

Cuadro 1. Datos de los rodales

Rodal	Edad (años)	Area (ha)	IMA (m ³ /ha/año)
1	7	245	29
2	4	78	26
3	6	305	18
4	8	154	27
5	5	208	27
6	2	310	26

Cuadro 2. Volumen disponible en cada rodal

Rodal	Volumen (t)				
	año 1	año 2	año 3	año 4	año 5
1	39788	43198	46168	48733	50926
2	0*	0	9734	11356	12330
3	26352	30744	33379	35674	37656
4	25281	27019	28520	29803	30887
5	0	26957	31450	34145	36493
6	0	0	0	0	12896

*Las celdas con volumen igual a 0, se refieren a rodales que no pueden ser cortados en un año determinado debido a que no han alcanzado la edad mínima de corta.

Cuadro 3. Costo total de aprovechamiento

Rodal	Costo total (u.m.*)				
	año 1	año 2	año 3	año 4	año 5
1	1273216	1388498,3	1501958,8	1610544,7	1712374,5
2	0	0	314574	363417,6	396119,9
3	857294	983808	1075210,4	1169903,1	1263884,6
4	973304,6	1052724,1	1128516,7	1199410,1	1264696,5
5	0	1172496	1263375,4	1354704,4	1767886,3
6	0	0	0	0	1048314,8

* Unidades monetarias

2.5.1 Representación de los individuos

Se utilizó una representación binaria para codificar una solución del problema, la implementación se hizo mediante un vector de 0's y 1's en el que cada uno de sus elementos almacena una variable binaria X_{ij} que indica si un determinado rodal i se cortará o no en el año j . El tamaño del vector es igual al número de rodales multiplicado por el período de planificación ($6 \times 5 = 30$). En la figura 3 se muestra una representación de un individuo o solución, en terminología de algoritmos genéticos esta representación corresponde a un cromosoma. Se observa en esta figura que los primeros cinco genes corresponden a las variables relacionadas con la corta del rodal 1, los siguientes cinco están relacionados al rodal 2, y así sucesivamente. De esta manera, cada rodal tiene asociados cinco genes (elementos del vector), correspondientes a los cinco años del período de planificación. La solución que está representada en la figura 2 indica que el rodal 1 se corta en el año 2, el rodal 2 en el año 3, los rodales 4 y 6 en el año 5, y el rodal 5 en el año 4. Las celdas marcadas con x se refieren a períodos de tiempo en los que no se puede aprovechar un rodal debido que no ha alcanzado la edad mínima de corta, esas variables no se toman en cuenta, se incluyen en el vector para mayor facilidad en la programación y se les asigna un valor constante igual a cero que no cambia durante la ejecución del programa.

2.5.2 Generación de la población inicial

Se seleccionaron N individuos para conformar la población a partir de la cual se inicia el algoritmo genético. Cada individuo de la población se seleccionó en forma aleatoria de acuerdo al siguiente procedimiento: para cada rodal se elige al azar un año en el que será cortado y se les asigna el valor 1 a los elementos del vector correspondientes, a los elementos restantes se les asigna 0.

2.5.3 Función de adaptación

Se utilizó una transformación de la función objetivo para medir la calidad de una solución (Ecuación 5).

$$FIT(X) = cota - f^p(X) \tag{Ec. 5}$$

Donde:

$FIT(X)$ = función de adaptación

$f^p(X)$ = función que consta de la función objetivo original (ecuación 1) y una penalización por la violación total (medida en toneladas) de las restricciones de demanda, esta función está dada por la ecuación 6.

$$f^p(X) = f(X) + P \cdot VT(X) \tag{Ec. 6}$$

Donde:

$f(X)$ = función objetivo del problema original, P corresponde a la penalización (u.m./t) que se impone a la violación de las restricciones de demanda

$VT(X)$ = violación total (t) de las restricciones de demanda para una solución X , la cual se calcula según la ecuación 7.

$$VT(X) = \sum_{k=1}^5 (20000 - g_k) \cdot I_k \tag{Ec.7}$$

Donde:

g_k = valor de la restricción de demanda para el año k evaluada en X , o lo que es igual, el volumen aprovechado en el año k si se aplica el plan de cortas (solución) X

I_k = variable indicadora que vale 1 si en el año k se viola la restricción de demanda, es decir, el volumen que se corta en ese año es menor a la cuota anual ($g_k < 20000$), y en otro caso vale 0. La cota que se utiliza en la función de adaptación (ecuación 5) es una cantidad igual o mayor que el máximo valor que puede tomar $f^p(X)$.

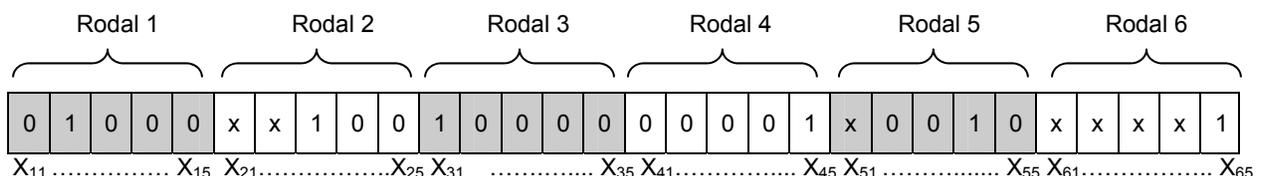


Figura 3. Presentación de una solución del problema.

2.5.4 Selección

Se utilizó el procedimiento de selección proporcional propuesto por Holland (1975), que se basa en la idea de que la probabilidad de selección P_i del i -ésimo individuo en la población depende de la adaptación relativa de éste con respecto a la población:

$$P_i = \frac{FIT_i}{\sum_{j=1}^N FIT_j} \quad (\text{Ec.8})$$

Donde:

N = cantidad de individuos de la población

FIT_j = es la adaptación del j -ésimo individuo

Una vez calculada la probabilidad de selección de cada individuo de una población de acuerdo a la ecuación 8, se utilizó el método de la ruleta para llevar a cabo la selección. La descripción de este método se encuentra en cualquier texto o tutorial sobre algoritmos genéticos, se recomiendan Estévez (1997), Reeves (2003), Dréo *et al.* (2006).

2.5.5 Cruzamiento

Se aplicó cruzamiento de un punto con una probabilidad P_c . Con la finalidad de preservar la estructura original de una solución así como las restricciones de singularidad, o en otras palabras, para garantizar que de los cinco elementos del vector que corresponden a un rodal solamente uno de ellos tenga el valor 1, los puntos de cruzamiento que pueden utilizarse están restringidos a aquellas posiciones del vector donde finaliza un rodal (5, 10, 15, 20, 25), entre estos valores se selecciona aleatoriamente el punto de cruzamiento. En la figura 4 se muestra la codificación de una solución con los puntos de cruzamiento.

2.5.6 Mutación

Se utilizó mutación simple, eligiendo aleatoriamente un rodal y dentro de éste el gen que mutará. Si el gen a mutar tiene un valor 0 se le asigna 1 y al

resto de los genes de ese rodal se le asigna 0. Si el gen a mutar tiene un valor de 1 se le asigna 0 y se elige al azar entre los genes restantes uno al cual se le asignará el valor 1. Un individuo tiene una probabilidad P_m de mutar.

2.5.7 Parámetros del algoritmo genético

Los parámetros necesarios para correr el algoritmo genético son: tamaño de la población (N), probabilidad de cruzamiento (P_c), probabilidad de mutación (P_m) y número máximo de iteraciones del algoritmo (K_{max}), este último es el criterio de parada utilizado. Los valores de los parámetros se determinaron mediante experimentación.

2.6 Evaluación del desempeño del algoritmo genético

Para examinar el desempeño del algoritmo genético diseñado se realizaron 100 corridas y en todas se registró el valor objetivo obtenido (costo total de aprovechamiento), el tiempo de ejecución, iteración en la que se encuentra la solución y se calculó el error relativo del valor objetivo con respecto al valor óptimo obtenido mediante programación entera (Ecuación 9).

$$\text{Error relativo} = \frac{V_{ag} - V_{opt}}{V_{opt}} \times 100\% \quad (\text{Ec. 9})$$

Donde:

V_{opt} = valor objetivo óptimo obtenido mediante programación entera binaria

V_{ag} = es el valor objetivo obtenido en una corrida del algoritmo genético.

Se calcularon las estadísticas básicas para las variables de desempeño registradas en las corridas. La eficacia del algoritmo genético se determinó como la diferencia entre el 100% y el error relativo medio. Además, se contabilizó el número de corridas en las que el algoritmo genético obtuvo la solución óptima.

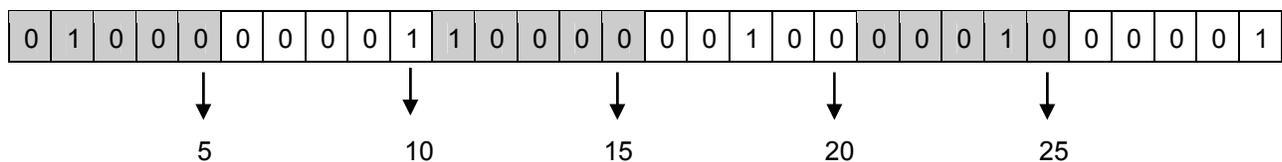


Figura 4. Posibles puntos de cruzamiento.

3. Resultados y discusión

La secuencia óptima de cortas obtenida mediante programación entera binaria se muestra en el cuadro 4, así como también el tiempo de ejecución en milisegundos (ms) empleado por el programa SAS OR para resolver el modelo. Los valores de los parámetros del algoritmo genético definidos mediante experimentación se presentan en el cuadro 5 y las estadísticas básicas para las variables de desempeño evaluadas en el cuadro 6.

Cuadro 4. Secuencia óptima de corta

Año	Rodales a cortar	Volumen aprovechado (t)
1	1	39788
2	5	26957
3	3	33379
4	4	29803
5	2 y 6	25226
Volumen total		155153
Valor objetivo (costo mínimo en u.m.*)		5457192,8
Tiempo de ejecución (ms**)		710

* Unidades monetarias; ** Milisegundos

Cuadro 5. Parámetros del algoritmo genético

Parámetro	Valor
Tamaño de la población	100
Probabilidad de cruzamiento	1
Probabilidad de mutación	0,05
Número máximo de iteraciones	50

Cuadro 6. Estadísticas básicas para las variables de desempeño del algoritmo genético

Variable	Media	Desviación estándar	Mínimo	Máximo
Valor objetivo (u.m.*)	5470376,4	17480,7	5457192,8	5545256,5
Error relativo (%)	0,04	0,32	0	1,61
Tiempo de ejecución (ms**)	292,6	4,0	285,0	303,0
Iteración en la que obtiene la solución	7	7	1	37

* Unidades monetarias; ** Milisegundos

Se observa que el costo de aprovechamiento óptimo obtenido a través de programación entera es de 5457192,8 u.m., mientras que el costo de aprovechamiento medio (valor objetivo medio) calculado a partir de los resultados obtenidos en las 100 co-

rridas del algoritmo genético es de 5470376,4 u.m., apenas 0,24% mayor que el valor óptimo. Al calcular la eficacia del algoritmo genético como la diferencia entre el 100% y el error relativo medio, se tiene que ésta es igual al 99,76% siendo una aproximación excelente para esta técnica heurística.

El algoritmo genético encontró la solución óptima en el 47% de las corridas, y en el 53% restante consiguió soluciones sub-óptimas, el mayor error relativo registrado en estas soluciones fue de 1,61%, lo que indica que éstas son muy cercanas a la solución óptima. De esta manera, el algoritmo genético además de la solución óptima, encontró otras soluciones que representan secuencias de corta alternativas entre las cuales el planificador puede elegir, lo que constituye una ventaja en relación a las técnicas de programación matemática en las que se obtiene una única solución, que a pesar de ser la óptima, en algunos casos debido a consideraciones prácticas puede no ser fácil de implementar, resultando útil tener otras opciones para seleccionar la más apropiada. A manera de ejemplo, en el cuadro 7 se presentan las dos secuencias de corta sub-óptimas que tienen el costo total de aprovechamiento más bajo.

Cuadro 7. Secuencias sub-óptimas de corta obtenidas por el algoritmo genético

Año	Secuencia de corta 1		Secuencia de corta 2	
	Rodales a cortar	Volumen aprovechado (t)	Rodales a cortar	Volumen aprovechado (t)
1	3	26352	1	39788
2	5	26957	5	26957
3	1	46168	4	28520
4	4	29803	3	35674
5	2 y 6	25226	2 y 6	25226
Volumen total		154506		156165
Valor objetivo (costo total de aprovechamiento en u.m.*)		5468019,2		5480992,
Error relativo (%)		0,20		0,44

* Unidades monetarias

El tiempo de ejecución medio del algoritmo genético fue de 292,6 ms con una desviación estándar de 4 ms, un 58,8% menos en relación al tiempo utilizado por el algoritmo exacto de ramificación y acotamiento para programación entera en SAS OR, el cual fue de 710 ms. Esta es una de las razones por

las cuales en muchos casos se prefiere el uso de una técnica heurística a un método de programación matemática, las heurísticas pueden hallar soluciones de un problema en un tiempo de computación menor, lo cual es muy importante en problemas de gran tamaño, en los que debido al elevado número de posibles soluciones del problema, los algoritmos exactos de programación matemática pueden llevar muchas horas de tiempo de cálculo y no encontrar una solución. También se puede observar en los resultados que en promedio el algoritmo genético encuentra la solución del problema en la iteración 7, con una desviación estándar igual a 7 y valores máximo y mínimo iguales a 1 y 37. Así, el algoritmo genético diseñado consigue una buena solución al problema en forma rápida, en la mayoría de los casos durante las primeras iteraciones.

Las estadísticas de las variables de desempeño evaluadas en este trabajo indican que el problema de planificación del aprovechamiento forestal planteado fue resuelto exitosamente mediante el algoritmo genético desarrollado, el cual mostró ser bastante eficiente en este caso particular.

4. Conclusiones

Los algoritmos genéticos constituyen un método de solución para problemas de planificación forestal que comprenden la optimización de una función objetivo sujeta a un conjunto de restricciones y que son difíciles de resolver mediante técnicas de programación matemática convencionales debido a sus dimensiones o complejidad. Este método heurístico basado en los mecanismos de la evolución natural de las especies, puede encontrar buenas soluciones cercanas al óptimo y en muchos casos puede obtener la solución óptima, por tal razón constituye una alternativa que vale la pena explorar al plantear modelos de planificación forestal.

En este artículo se presentaron las ideas principales en las que se fundamentan los algoritmos genéticos y que se considera pueden orientar a aquellos investigadores y planificadores forestales que desean comenzar a utilizar esta técnica. El ejemplo de planificación del aprovechamiento forestal utilizado aunque es sencillo, permite comprender el diseño y funcionamiento de un algoritmo genético.

El algoritmo genético diseñado en este trabajo mostró ser eficiente para resolver el problema planteado, ya que tuvo una eficacia del 99,76% y un tiempo de ejecución mucho menor que el requerido por el algoritmo de ramificación y acotamiento para programación entera utilizado por el software de optimización SAS OR. El desempeño de los algoritmos genéticos puede ser diferente en otras situaciones, pues depende de las características de cada problema y de la manera de implementarlos.

Es importante mencionar que existen muchas variaciones de los algoritmos genéticos, tal como lo señala Reeves (2003) probablemente cada algoritmo genético es único, ya que es posible definir diferentes estrategias en el tamaño de la población, en los métodos de inicialización, en la representación de los individuos, en la definición de la función de adaptación y en la aplicación de los operadores genéticos. En cualquier caso, para obtener buenos resultados, es necesario diseñar cuidadosamente el algoritmo genético para el problema particular que se desea resolver y elegir los parámetros más favorecedores de acuerdo a una experimentación previa.

5. Referencias bibliográficas

- CABEZAS, C. A. 2002. Algoritmos genéticos, una opción para la optimización de funciones. *Tecnología química* 23(2): 65-69.
- CHIARI, R., O. CARRERO, M. JEREZ, M.A. QUINTERO y J. STOCK. 2008. Modelo preliminar para la planificación del aprovechamiento en plantaciones forestales industriales en Venezuela. *Interciencia* 33 (11): 802-809.
- DEB, K. 2000. Introduction to selection. In: *Evolutionary Computation I - Basic Algorithms and Operators*. T. Bäck, D. B. Fogel y Z. Michalewicz (eds.). Institute of Physics Publishing. Bristol, Reino Unido. 166-171 pp.
- DRÉO, J., A. PÉTROWSKI, P. SIARRY y E. TAILLARD. 2006. *Metaheuristics for hard Optimization*. Springer-Verlag. Berlín, Alemania. 369 p.
- DUCHEYNE, E.I., R.R. DE WULF y B. DE BAETS. 2004. Single versus multiple objective genetic algorithms for solving the even-flow forest management problem. *Forest Ecology and Management* 201(2-3): 259-273.
- DUCHEYNE, E.I., R.R. DE WULF y B. DE BAETS. 2006. A spatial approach to forest-management optimi-

- zation-linking GIS and multiple objective genetic algorithms. *International Journal of Geographical Information Science* 20(8): 917-928.
- ESTÉVEZ, P. 1997. Optimización mediante algoritmos genéticos. *Anales del Instituto de Ingenieros de Chile* Agosto 97: 83-92.
- FALCÃO, A. O. y J. G. BORGES. 2001. Designing an evolution program for solving integer forest management scheduling models: an application in Portugal. *Forest Science* 47(2): 158-168.
- FALCÃO, A. O. y J. G. BORGES. 2002. Combining random and systematic search heuristic procedures for solving spatially constrained forest management scheduling models. *Forest Science* 48(3): 608-621.
- HOLLAND, J. H. 1975. *Adaptation in natural and artificial systems*. University of Michigan Press. Ann Harbor, USA. 334 p.
- KURI, A. 2000. Algoritmos Genéticos. Centro de Investigación en Computación. Instituto Tecnológico Autónomo de México. En línea: <http://cursos.itam.mx/akuri/PUBLICA.CNS/2000/AGS.pdf> [Consultado: 10/12/09].
- LIU, G., S. HAN, X. ZHAO, J. D. NELSON, H. WANG y W. WANG. 2006. Optimisation algorithms for spatially constrained forest planning. *Ecological Modelling* 194(4): 421-428.
- LU, F. y L. O. ERIKSSON. 2000. Formation of harvest units with genetic algorithms. *Ecology and Management* 130(1-3): 57-67.
- PALAHÍ, M., T. PUKKALA, L. PASCUAL y A. TRASOBARES. 2004. Examining alternative landscape metrics in ecological forest planning: a case for capercaillie in Catalonia. *Investigación Agraria: Sistemas y Recursos Forestales* 13(3): 527-538.
- PUKKALA, T. y M. KURTILA. 2005. Examining the performance of six heuristic search techniques in different forest planning problems. *Silva Fennica* 39(1): 67-80.
- REEVES, C. R. 1996. Modern Heuristic Techniques. In: *Modern Heuristic Search Methods*. V.J. Rayward-Smith, I. H. Osman, C.R. Reeves y G.D. Smith (eds.). Jon Wiley & Sons. Chichester, Inglaterra. 1-25 pp.
- REEVES, C. R. 2003. Genetic Algorithms. In: *Handbook of metaheuristics*. F. Glover y G.A. Kochenberger (eds.). Kluwer Academic Publishers, Boston, USA. 37-54 pp.
- RODRIGUES, F. L., H.G. LEITE, H.N. SANTOS, A.L DE SOUZA y G.F. SILVA. 2004. Metaheurística algoritmo genético para solução de problemas de planejamento florestal com restrições de integridade. *Árvore* 28(2): 233-245.
- SAS. 2004. SAS/OR 9.1 User's Guide. SAS Institute Inc. Cary, NC, USA. 168 p.
- THOMPSON, M. P, J. D. HAMANN y J. SESSIONS. 2009. Selection and penalty strategies for genetic algorithms designed to solve spatial forest planning problems. *International Journal of Forestry Research* 2009: 1-14.