

## OPTIMIZACIÓN DEL TRANSPORTE DE CAÑA DE AZÚCAR UTILIZANDO SISTEMAS MULTIAGENTES Y ALGORITMOS GENÉTICOS GROUPING

Agustín Décima<sup>a</sup>, Nicolás Majorel Padilla<sup>a,b</sup>, Adrián Will<sup>a,c</sup>, Sebastián Rodríguez<sup>a</sup> y  
Oscar Diez<sup>d</sup>

<sup>a</sup>*Centro de Investigación en Tecnologías Avanzadas de Tucumán, Universidad Tecnológica Nacional  
– Facultad Regional Tucumán, Tucumán, Argentina, nicolas.majorel@citad.org.ar,  
<http://www.citad.org.ar/>*

<sup>b</sup>*Departamento de Electricidad, Electrónica y Computación, Facultad de Ciencias Exactas y  
Tecnología, Universidad Nacional de Tucumán, Tucumán, Argentina.*

<sup>c</sup>*Departamento de Matemática, Facultad de Ciencias Exactas y Tecnología, Universidad Nacional de  
Tucumán, Tucumán, Argentina.*

<sup>d</sup>*Estación Experimental Agroindustrial Obispo Colombres, Tucumán, Argentina.*

**Palabras clave:** optimización, logística, industria azucarera, Sistemas Multiagentes,  
algoritmos genéticos grouping.

**Resumen.** El problema de logística de productos agroindustriales es un problema de larga data, con numerosos e importantes impactos en diversos aspectos de la realidad de la provincia de Tucumán y el país. Existen numerosos casos de industrias cuya materia prima proviene del campo y se transporta hacia los centros de producción con todo tipo de vehículos, usando la red vial existente. Esta situación ocasiona múltiples problemas, como accidentes de tránsito, gastos excesivos de combustible por falta de planificación y optimización global, etc. Se presenta en este trabajo una propuesta para la optimización del tránsito de caña de azúcar desde los productores hasta los ingenios, utilizando Sistemas Multiagentes por un lado y Algoritmos Genéticos tipo Grouping por otro. Se verificarán los sistemas desarrollados sobre datos artificiales, y se compararán ventajas y desventajas de cada uno sobre los casos estudiados.

## 1 INTRODUCCIÓN

La provincia de Tucumán es la principal productora argentina de caña de azúcar, con el 66% de la producción nacional. Es una de las principales actividades de la provincia, estimándose en un 10.5% del Producto Bruto Geográfico (PBG) provincial, lo que representa aproximadamente unos 1500 millones de pesos (Lannes y Pucci 2007). Además, la agroindustria azucarera representa un 42% del sector de la industria manufacturera de la provincia (Pérez et. al. 2007).

El transporte de caña de azúcar desde los productores en el campo hasta los ingenios para su procesamiento es un problema complejo, de gran tamaño, donde intervienen gran cantidad de variables. A pesar de la importancia económica de esta actividad para la provincia, en la actualidad la plantación, cosecha y transporte no presenta una planificación optimizada. Esta situación, agravada por otros elementos socio-económicos, como el mal mantenimiento de los vehículos, entregas a ingenios situados a gran distancia, etc., reduce la rentabilidad de la actividad tanto para los productores como para los ingenios.

El aspecto negativo de esta situación no se reduce únicamente al aspecto económico, ya que también impacta en el medio ambiente (recorridos extensos con vehículos mal mantenidos, excesivamente cargados, etc.), y en la seguridad vial (aumento del tráfico pesado a baja velocidad en rutas altamente transitadas). Un sistema unificado permitiría ordenar el movimiento de la producción dando como resultado un cronograma de cosechas y entregas, respetando todas las restricciones planteadas, y sugiriendo puntos de la red vial que deberían ser especialmente monitoreados y mantenidos.

Adicionalmente, se debe tener en cuenta la iniciativa actual del Gobierno Nacional de incentivar la producción de biocombustibles, mediante la sustitución por ley de hasta un 5% de alcohol en las naftas. Siendo el Bioetanol uno de los derivados de la caña de azúcar, es importante maximizar su eficiencia de producción y minimizar los consumos de combustibles fósiles en la industria.

Es importante destacar que, dado el gran volumen de caña de azúcar transportada por año dentro de la provincia de Tucumán (aproximadamente 1400 millones de toneladas), cualquier optimización que se consiga, por más pequeña que sea, puede resultar en grandes impactos económicos, en el medio ambiente, y en los diversos aspectos logísticos y de producción relacionados a esta industria.

Problemas similares han sido atacados con relativo éxito en otros países del mundo, utilizando diversas herramientas, como por ejemplo en Sudáfrica (Giles et al. 2009; Giles et al. 2006; Jorio et al. 2006; Le Gal et al. 2009), Australia (Higgins & Muchow 2003; Higgins 2002; Higgins 1999) y Tailandia (Yosnuat & Supsomboon 2004). Sin embargo este problema es muy dependiente de características específicas de cada región, por lo que las herramientas desarrolladas no son directamente aplicables a nuestro país.

Este trabajo constituye una primera aproximación de un proyecto a largo plazo cuyo objetivo es desarrollar una herramienta de software destinada a mejorar la situación mencionada, mediante una planificación integral del transporte cañero durante los 180 días que dura la cosecha de caña de azúcar en la provincia de Tucumán. Se tomó la decisión de abordar en esta primera etapa el problema de entrega de la cosecha para un solo día. Esta decisión fue tomada en conjunto con productores e industriales, ya que es usual que condiciones imprevistas como heladas, cortes de ruta o lluvias excesivas, modifiquen el escenario y obliguen a conseguir una solución al problema de manera inmediata, para las nuevas condiciones. Adicionalmente permite ajustar el modelo matemático utilizado y estudiar la performance de los diferentes algoritmos en un modelo simple.

Con esta decisión, la situación se reduce a un problema de entregas en un grafo bipartito

completo, con los productores de caña de azúcar por un lado, y los consumidores (ingenios) por el otro. Dado que lo que puede entregar un productor en un día es varios órdenes de magnitud menor que lo que necesita en ese día un ingenio en promedio, el problema se encuadra como un problema de entrega simple y no como un Travelling Salesman Problem (TSP), ya que se recoge la carga de un solo productor y se la entrega a un solo ingenio. Este escenario puede modelarse como un problema de optimización binaria sobre un grafo bipartito completo, con dos restricciones: que cada productor entregue la producción de su parcela sólo a un ingenio, y los ingenios deben cumplir una cuota de producción mínima y, de ser posible, una cuota de producción óptima. A fin de simplificar el problema, se consideró además que la cantidad total de caña a entregar coincide exactamente con la demanda total de los ingenios.

Para seleccionar la variable de optimización a utilizar, un análisis de la situación actual en la industria mostró que cada participante de la misma busca maximizar su ganancia económica individual, lo que en la mayoría de los casos no se traduce en una ganancia global para toda la industria. Por otro lado, existen variables económicas externas, como subsidios, convenios, impuestos, etc., que distorsionan cualquier perspectiva económica. Por estos motivos, se decidió utilizar como variable de optimización un concepto basado en energía, que permita transformar múltiples variables en una única variable escalar.

En un trabajo previo ([Majorel Padilla et. al. 2011](#)) se desarrolló una solución al problema propuesto usando Sistemas Multiagentes (SMA) y comparando los resultados obtenidos con los de una solución desarrollada mediante programación lineal. En este trabajo se utilizó el SMA mencionado, comparándolo con un desarrollo basado en Algoritmos Genéticos Grouping (AGG), ya que ambas técnicas presentan características apropiadas para el tipo de problema descrito, como ser la paralelización y la escalabilidad en tamaño y en cantidad de variables.

Este trabajo está organizado como se indica a continuación: en la sección siguiente se presenta la propuesta de trabajo y el modelo matemático asociado, en la sección 3 se detallan la metodología y las herramientas utilizadas, luego se presentan los resultados obtenidos y finalmente en la sección 5 se realizan las conclusiones de la investigación.

## 2 DEFINICIÓN DEL MODELO UTILIZADO

Como se dijo anteriormente, el modelo utilizado tiene como objetivo maximizar el balance energético total del sistema. Se presentan a continuación la definición formal de los conceptos mencionados.

Se divide la zona productora de caña de azúcar en unidades productivas de la misma superficie, denominadas **parcelas**, tal como se utiliza en la industria azucarera. Cada parcela produce una cantidad de caña que puede variar en cantidad y calidad, dependiendo de diversos factores (cantidad de agua, edad de la caña, calidad y tipo de fertilizantes, condiciones climáticas, etc.). Con esta división, se estima que en toda la provincia se cuenta con una cantidad total aproximada de 300.000 parcelas.

Por otra parte, cada **ingenio** demanda un cierto número diario de toneladas de caña para ser procesadas y tiene cierta eficiencia en este procesamiento de acuerdo a la tecnología con la que cuenta. En la actualidad, en la provincia de Tucumán existen 15 ingenios activos.

El **balance energético** (BE) se define como el cociente entre la energía total obtenida como producto final, sea en forma de azúcar o de alcohol, y la energía total insumida a lo largo del proceso productivo, sea en forma de fertilizantes, combustible utilizado, pérdidas de materia prima por estacionamiento, etc.. Particularizando este concepto para las parcelas, el BE es el cociente entre la energía obtenida en toneladas de caña y la energía insumida en la siembra, crecimiento y cosecha de la misma. Este concepto permite comparar distintas

parcelas entre sí, resultando más eficiente aquella parcela que presenta un mayor BE. En el caso de los ingenios, cuanto mayor sea su BE, más eficiente será, ya que extrae mayor cantidad de energía para igual energía invertida, u obtiene la misma energía final con menor inversión. Incluso, el mismo concepto es aplicado al definir los costos de transportar la caña desde las parcelas hacia los ingenios. Para este caso, el BE es el cociente entre la energía obtenida en toneladas de caña por la parcela y la energía que llega al ingenio para su procesamiento, y cuanto mayor sea este valor, mayor será el costo del transporte.

El problema puede ser descripto mediante las siguientes variables:

- Un conjunto  $P$  de  $m$  parcelas, cada una con su valor de producción, medido en toneladas de caña, y su eficiencia, indicada por su balance energético. Este último valor es siempre mayor que 1, ya que se obtiene más energía de la que se invierte (no se considera la energía del sol en el cálculo).
- Un conjunto  $I$  de  $n$  ingenios, cada uno de ellos con su demanda máxima diaria, medida en toneladas de caña, y su eficiencia, indicada por su balance energético. Este valor es siempre menor que 1, ya que se obtiene menos energía de la que ingresa.
- Una matriz de costos  $C$ , de tamaño  $m \times n$ , en la cual cada valor  $c_{ij}$  expresa el costo, medido como balance energético, de transportar la producción desde la parcela  $i$  hasta el ingenio  $j$ . Este costo incluye todos los costos traducidos a energía, desde combustible necesario para el transporte, pérdidas estimadas por mal estado del camino, pérdidas por estacionamiento, mantenimiento de los vehículos, etc.

El Balance Energético ( $BE_{ij}$ ) total para transportar la producción de una parcela  $i$  hacia el ingenio  $j$  puede expresarse como:

$$BE_{i,j} = \frac{BEP_i \cdot BEI_j}{C_{i,j}} \quad \forall i = 1, \dots, m, j = 1, \dots, n \quad (1)$$

donde  $BEP_i$  es el balance energético de la parcela  $i$ ,  $BEI_j$  es el balance energético del ingenio  $j$  y  $C_{i,j}$  es el costo (medido como balance energético) de transportar la producción desde la parcela  $i$  hasta el ingenio  $j$ . Luego, el Balance Energético Total ( $BE_T$ ) del sistema puede expresarse como:

$$BE_T = \sum_{i=1}^m \sum_{j=1}^n BE_{ij} \cdot sol(i, j) \quad (2)$$

donde  $sol$  es un estado del sistema en una iteración, y consiste en una matriz de  $m$  filas y  $n$  columnas, en la que cada elemento  $sol(i, j)$  de la matriz es igual a 1 si la parcela  $i$  selecciona al ingenio  $j$ , y cero en cualquier otro caso.

Entonces, el objetivo del presente trabajo es encontrar una distribución de las  $m$  parcelas en los  $n$  ingenios tal que maximice  $BE_T$ , cumpliendo con la siguiente restricción:

$$Pmin_j \leq \sum_{i=1}^m P_i \cdot sol(i, j) \leq Pmax_j \quad \forall j = 1, \dots, n \quad (3)$$

donde  $Pmin_j$  es la producción mínima que necesita el ingenio  $j$  para funcionar,  $Pmax_j$  es la producción máxima de la que es capaz el ingenio  $j$ ,  $P_i$  es la producción de la parcela  $i$  y  $sol(i, j)$  es la solución del sistema como fue definida anteriormente.

Para cumplir este objetivo se utilizaron dos enfoques: uno basado en SMA, y otro basado en AGG, los cuales se describen en la siguiente sección.

### 3 METODOLOGÍA Y HERRAMIENTAS

Como ya se mencionó, las técnicas utilizadas como herramientas para implementar la propuesta realizada fueron algoritmos genéticos y Sistemas Multiagentes.

Los Sistemas Multiagentes (SMA) consideran a los sistemas como sociedades compuestas por entidades autónomas e independientes llamadas agentes, que interactúan entre sí para conseguir resolver un problema o realizar una tarea común (Ferber 1999). Para este problema se utilizó el concepto de Fuerzas de Atracción (Zhao & Yi 2006; Chen & Cheng 2010) donde cada parcela es representada por un agente, que es atraído por otro agente que representa a un ingenio con una fuerza que varía de acuerdo a la demanda del ingenio en el momento. Esto debe ser hecho de manera que se respeten las restricciones, se optimice el  $BE_T$ , y los agentes alcancen un estado de equilibrio alrededor del óptimo.

Los Algoritmos Genéticos Grouping son un tipo de algoritmos genéticos específicamente adaptados a problemas de partición, donde el problema consiste en partir un conjunto dado de elementos en subconjuntos, de manera tal que todos los elementos queden en uno y sólo uno de estos subconjuntos y minimizando o maximizando una función objetivo (Falkenauer & Delchambre 1992; Ülker et al. 2008). Es posible encarar el problema planteado como un problema de partición, donde el total de las parcelas debe ser dividido en subconjuntos (uno por cada ingenio), de manera tal que se maximice el  $BE_T$ . Desde este punto de vista, el problema es complejo porque requiere de operadores y algoritmos de reparación especiales diseñados para el mismo.

#### 3.1 Solución con SMA

Dentro del modelo adoptado, cada parcela está representada por un *agente parcela* y similarmente los ingenios por un *agente ingenio*. De esta manera, un *agente ingenio* genera una determinada atracción sobre todos los *agentes parcela*. Luego, cada *agente parcela* se encarga de evaluar cuál de todos los *agentes ingenio* resulta más atractivo, y comunica su decisión al *agente ingenio* seleccionado, informándole además su producción. A continuación, cada *agente ingenio* recibe los datos de todos los *agentes parcela* que lo seleccionaron, evalúa si cumple con sus requerimientos de demanda y en función de ello, genera una nueva atracción. Esta nueva atracción es enviada a todos los *agentes parcela* y el ciclo se repite hasta encontrar una situación de equilibrio, en donde los *agentes parcela* no modifiquen su decisión del *agente ingenio* seleccionado, y los *agentes ingenio* no modifiquen su atracción sobre los *agentes parcela*. Para una explicación detallada del funcionamiento del SMA ver Majorel Padilla et. al. 2011.

#### 3.2 Solución con Algoritmos Genéticos Grouping

Para el desarrollo de la solución usando AGG, se puede entender la situación como un problema de llenado de contenedores, similar al Bin Packing Problem (Falkenauer & Delchambre 1992; Lodi et al. 2002) pero con dos diferencias principales: los ingenios son contenedores de diferente capacidad que deben ser llenados con el contenido de las parcelas, y el objetivo es maximizar el  $BE_T$  del sistema completo manteniéndose siempre dentro de las restricciones definidas previamente, y no minimizar la cantidad de contenedores.

En este escenario, las soluciones son representadas por un vector de  $m$  elementos, en el cual el índice  $i$  representa una parcela y el  $i$ -ésimo elemento indica a cuál ingenio es asignada esa parcela, por lo tanto, los valores posibles para cada elemento del vector son de 1 a  $n$ . En la Figura 1 puede observarse un ejemplo de una solución, en la cual se observa que la parcela 1 es asignada al ingenio 3, la parcela 5 al ingenio  $k$  ( $1 \leq k \leq n$ ) y la parcela  $m$  al ingenio 14.




Figura 1. Ejemplo de codificación utilizada

El AGG se inicia construyendo una población inicial de soluciones, que se genera de la siguiente manera: se realiza una permutación aleatoria del total de parcelas y se las asigna secuencialmente al primer ingenio hasta cubrir la capacidad del mismo, para luego continuar con el siguiente y así sucesivamente. Se introdujo una corrección aleatoria para evitar la tendencia a que los primeros ingenios estén más llenos que los últimos. Al cabo de este proceso, se obtiene un conjunto de soluciones estocásticas dentro del espacio de soluciones permitidas por las restricciones impuestas.

A continuación comienza un proceso iterativo cuyo primer paso es el proceso de selección de soluciones, utilizando como función de fitness la fórmula de  $BE_T$  especificada en la ecuación (2), más el agregado de una función que penaliza las soluciones que no cumplan las restricciones (posible a causa de las mutaciones). Esta función de penalización posee la forma mostrada en la Figura 2, y es modificada por un parámetro dependiente del tamaño del problema cuyo objetivo es mantener la penalización balanceada con el valor de  $BE_T$ .

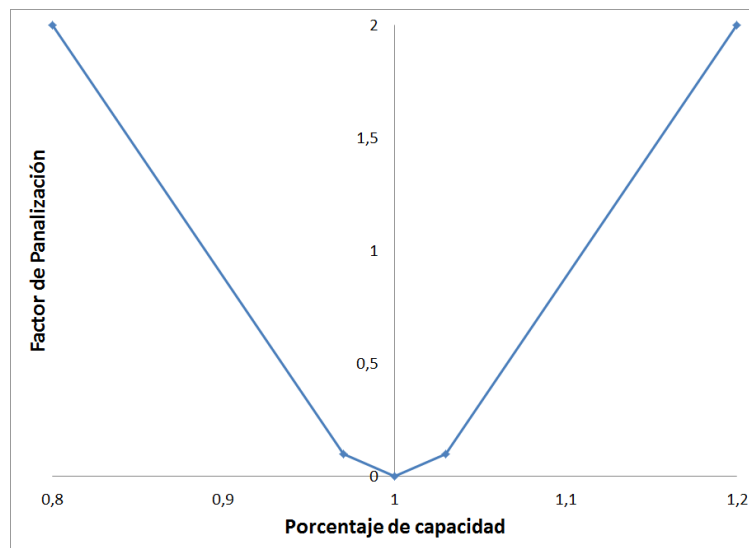


Figura 2: Factor de penalización - Función de Fitness

Completado el proceso de selección, se aplican sobre las soluciones obtenidas cuatro operadores, un cruzamiento y tres mutaciones, cada uno de ellos con un porcentaje de incidencia independiente. Es necesario considerar que los AGG necesitan utilizar técnicas de reparación de soluciones al realizar el cruzamiento, ya que no hay manera de asegurar que las soluciones producidas sean consistentes. Por lo tanto, se utilizó una heurística de reparación estándar. A continuación se describirá brevemente cada uno de estos operadores:

- Cruzamiento: Se utiliza el operador Partial Map Crossover (Ahmed 2010), reparando inconsistencias mediante First Fit Decreasing (FFD) (Falkenauer & Delchambre 1992; Ülker et al. 2008; Salcedo-Sanz 2009)
- Mutación Energética 1: toma un porcentaje A de parcelas al azar de una solución y las reasigna al ingenio que maximice el BE para cada una de ellas. Este operador puede producir soluciones que no cumplan con las restricciones impuestas.
- Mutación Energética 2: toma un porcentaje B de las parcelas peor asignadas (es

decir, aquellas con menor BE) de una solución y las reasigna a otros ingenios al azar mediante FFD.

- **Mutación de Reubicación:** para aquellos ingenios que superaron su capacidad máxima, se calcula cuan excedidos se encuentran en relación a ésta, y se obtiene el ingenio cuyo porcentaje sea mayor. Se toma dicho porcentaje de las peores parcelas asignadas a ese ingenio (es decir, aquellas con menor BE), y a tales parcelas se las reasigna a otros ingenios al azar mediante FFD.

Una vez aplicados los operadores, el proceso se repite según la cantidad de generaciones que se desee.

### 3.3 Ejemplos utilizados y parámetros definidos

Para evaluar ambos enfoques se elaboraron varios problemas de ejemplo diferentes. Dos de ellos fueron creados sintéticamente sobre la base de la situación real proporcionada por la industria. El primer caso fue el utilizado en [Diez et. al. 2010](#) y [Majorel Padilla et. al. 2011](#) es un modelo simple que cuenta con 6 ingenios y 245 parcelas (denominado ejemplo 245-6) modificado para poder estimar a priori los resultados correctos, y el segundo se construyó de manera similar pero con 10 ingenios y 500 parcelas (denominado ejemplo 500-10).

En los ejemplos sintéticos, se dividió la cantidad total de parcelas en partes iguales, sin tener en cuenta su producción en toneladas, y se ajustaron los costos de manera que el primer grupo de parcelas sea asignado preferentemente al primer ingenio, el segundo grupo al segundo ingenio y así sucesivamente. De esta manera, se espera que los resultados de las pruebas arrojen una distribución similar a esta, con una mayor dispersión en aquellos ingenios con menor *BEI*, pero respetando siempre las restricciones impuestas en la ecuación (3).

Se utilizaron adicionalmente ocho ejemplos de tamaño creciente generados en forma aleatoria, de 1.000, 2.000, 3.000, 5.000, 10.000, 15.000, 20.000 y 30.000 parcelas respectivamente, todos con 15 ingenios. No se utilizaron ejemplos de mayor orden de magnitud de parcelas porque la codificación actual del SMA no permite manejar matrices mayores a 65.536 parcelas, y el AGG no permite procesar ejemplos con más de 30.000 parcelas de manera eficiente.

Todos los ejemplos están hechos con la suposición de que la demanda de caña por parte de todos los ingenios es igual a la oferta total de las parcelas para mantener compatibilidad con los trabajos anteriores, y se considera las restricciones de capacidad satisfechas cuando los ingenios alcanzan el 100% de su capacidad máxima, con una tolerancia de  $\pm 3\%$ . Ambos sistemas permiten la modificación estos porcentajes, así como también manejar situaciones en las que la producción total de caña es distinta a la demanda colectiva de los ingenios (a pesar que esta situación no fue analizada en profundidad en este trabajo).

Parámetro del AGG	Valor
Porcentaje de Aplicación de Crossover	10%
Porcentaje de Aplicación de Mutación Energética 1	20%
Porcentaje A	0% a 20%, variable al azar
Porcentaje de Aplicación de Mutación Energética 2	20%
Porcentaje B	0% a 20%, variable al azar
Porcentaje de Aplicación de Mutación de Reubicación	5%
Tamaño de la Población Inicial	400 individuos
Cantidad de Generaciones	600

Tabla 1. Valores de los parámetros del AGG.

Para los parámetros específicos del AGG, se utilizaron los valores mostrados en la [Tabla 1](#), que fueron obtenidos de manera experimental. Es importante mencionar que las 600 generaciones fueron distribuidas en 6 iteraciones de 100 generaciones cada una (paralelización sucesiva), con inundaciones (eliminación de la mitad con menos fitness de la población) y relleno con inmigración (población nueva generada al azar pero cumpliendo las restricciones).

#### 4 RESULTADOS OBTENIDOS

A continuación, se presentan los resultados obtenidos para todos los ejemplos descriptos, tanto por el Sistema Multiagentes como por el Algoritmo Genético Grouping, sobre la base del modelo descrito en la sección 2.

En la [Figura 3](#) se observa la distribución final de las parcelas encontrada por el AGG (Figura 3a) y por el SMA (Figura 3b) para el ejemplo sintético 500-10.

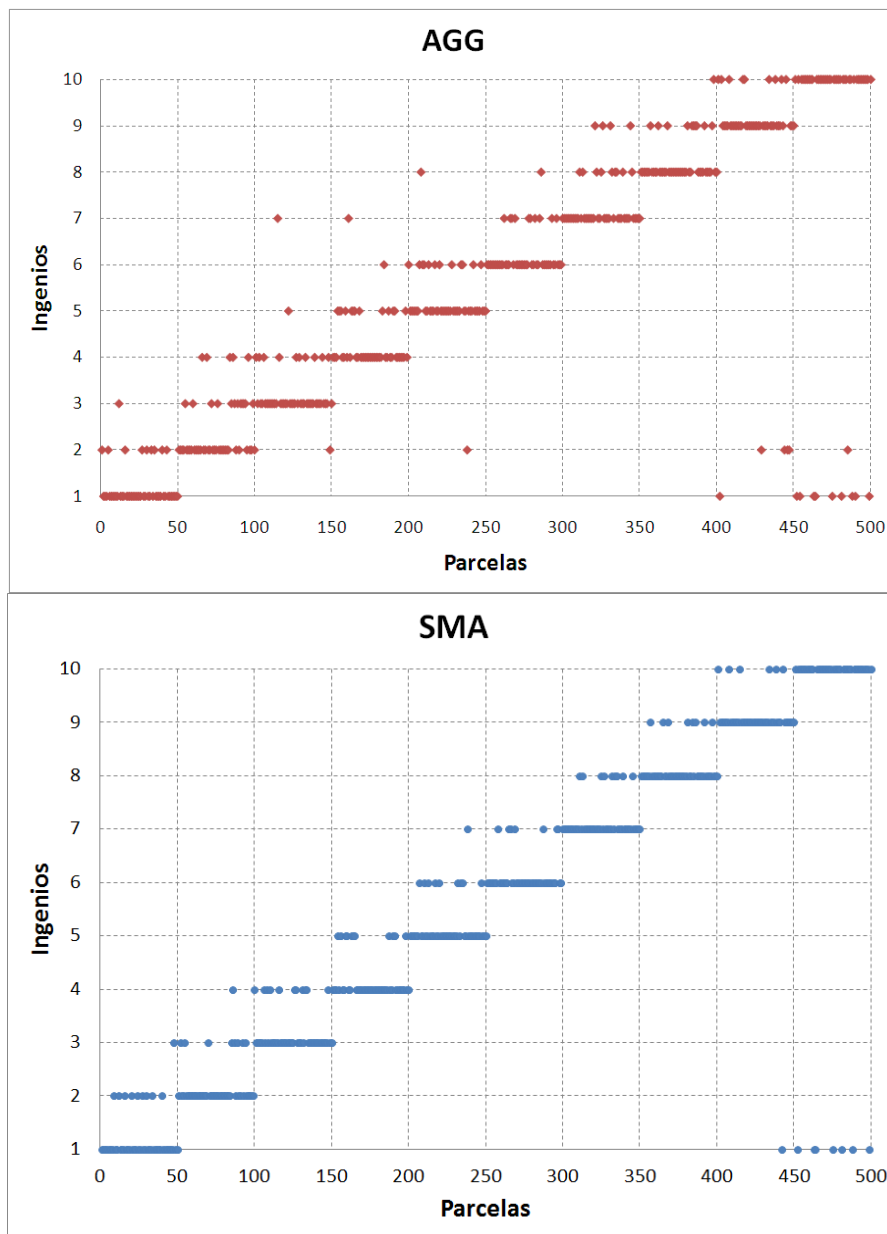


Figura 3: Distribución de las parcelas en los ingenios, en el AGG (a) y en SMA (b).



De esta manera, se comprobó que las soluciones obtenidas por ambos sistemas cumplen las restricciones y coinciden con la distribución esperada. Además, se comprobó en [Majorel Padilla et. al. 2011](#) que la solución obtenida por el SMA es idéntica en términos de  $BE_T$  a la óptima obtenida por un método de programación lineal. Aun así, las soluciones obtenidas por ambas herramientas son muy similares, aunque no idénticas: la diferencia es debido a que el AGG tiene problemas en reubicar algunas parcelas (menos del 1%) para alcanzar el  $BE_T$  óptimo global, ya que no dispone de una optimización local.

En la [Figura 4](#) se presentan los valores de BET en función de las iteraciones/generaciones para el ejemplo 245-6, utilizando SMA en la Figura 4a y AGG en la Figura 4b.

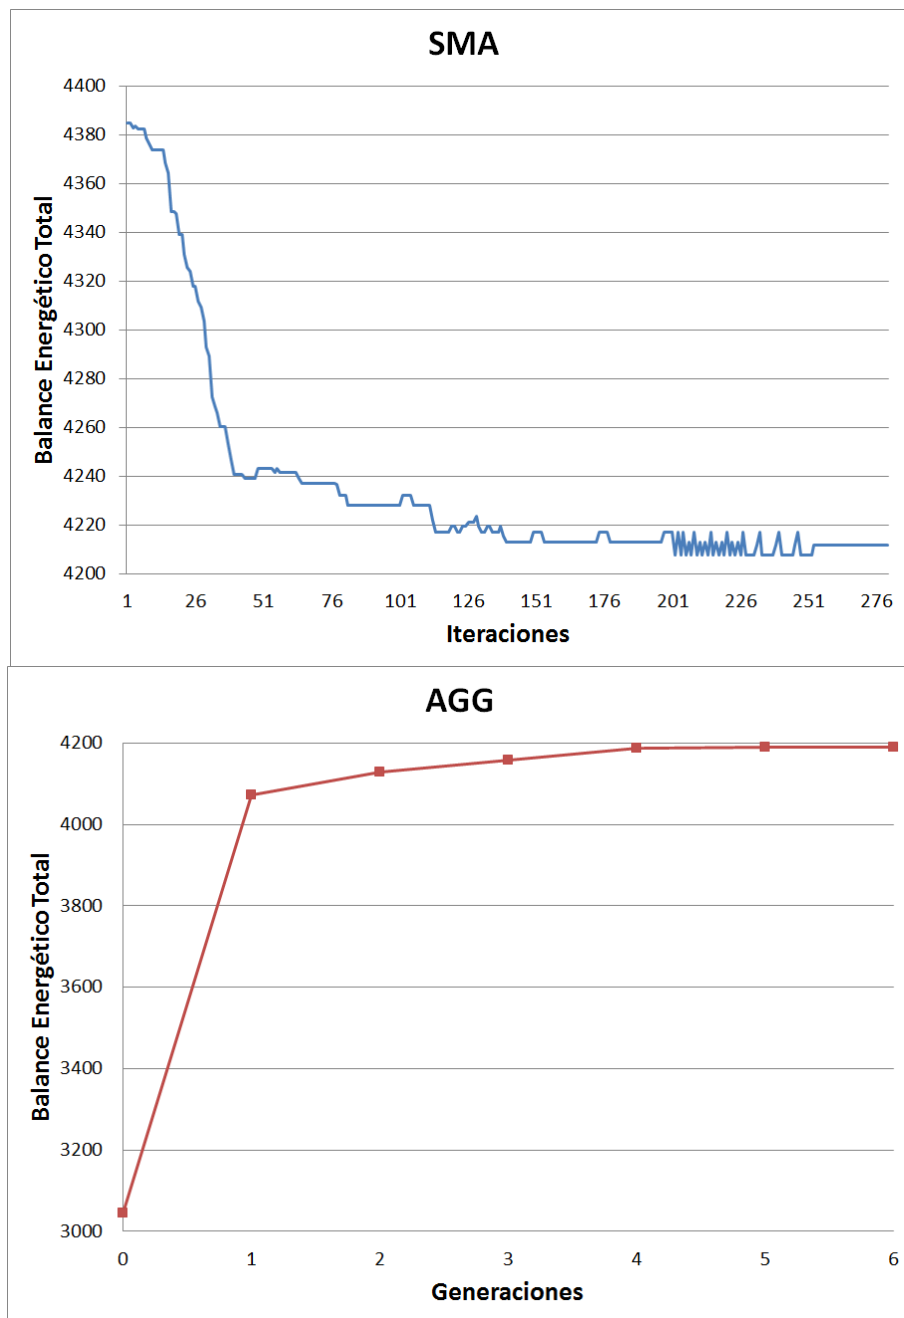


Figura 4. Balance Energético Total para SMA (a) y para AGG (b).

En la Figura 4a puede observarse como el SMA parte de una solución inicial quasi-óptima por construcción, en la que cada parcela entrega su producción al ingenio que le resulta más conveniente, sin importar si cumple con las restricciones. A partir de este punto, el sistema optimiza buscando una solución similar que respete las restricciones impuestas, a costa de disminuir su BET. Por este motivo, el sistema comienza con un BET máximo que va disminuyendo a medida que el sistema intenta cumplir las restricciones. Esta heurística proporciona un buen punto de partida cercano al óptimo teórico, entregando buenos resultados con muy pocas iteraciones en todos los ejemplos estudiados.

En la Figura 4b, por el contrario, puede observarse como el AGG parte de un conjunto de soluciones aleatorias y lejanas al óptimo las cuales van siendo optimizadas progresivamente conforme pasan las generaciones. Vale aclarar que en este caso, el conjunto inicial de soluciones cumple con las restricciones, y si bien pueden generarse eventualmente soluciones que no las cumplan (producto del operador de mutación energética 1), éstas son penalizadas y tienden a desaparecer.

En la [Tabla 2](#) se muestran los valores de  $BE_T$  obtenidos por ambos sistemas para todos los ejemplos, y puede observarse que el valor final obtenido por el AGG es entre el 94% y el 99% del valor obtenido por el SMA.

Parcelas	$BE_T$ SMA	$BE_T$ AGG	AGG / SMA
254	4211,85	4189	99,45%
500	5094,72	4998	98,10%
1000	13004,39	12370	95,12%
2000	25255,68	24135	95,56%
3000	38972,98	36750	94,29%
5000	64289,86	60240	93,70%
10000	128462,55	120658	93,92%
15000	192839,67	181103	93,91%
20000	257178,88	241524	93,91%
30000	385651,12	362165	93,91%

Tabla 2. Comparación entre los valores de BET obtenidos por el SMA y el AGG.

En la [Figura 5](#) puede observarse como cambia el tiempo de ejecución en función de la cantidad de parcelas para el SMA (Figura 5a) y para el AGG (Figura 5b).




Figura 5. Tiempos de ejecución en milisegundos para (a) SMA y (b) AGG.

Si bien el tiempo de ejecución incrementa linealmente con la cantidad de parcelas en ambos casos, es notable la diferencia en tiempo de ejecución de tres órdenes de magnitud entre ambos paradigmas, en favor de SMA. Esto puede observarse también en la [Figura 6](#), en la cual se muestran las mismas gráficas anteriores, pero en una única escala logarítmica.

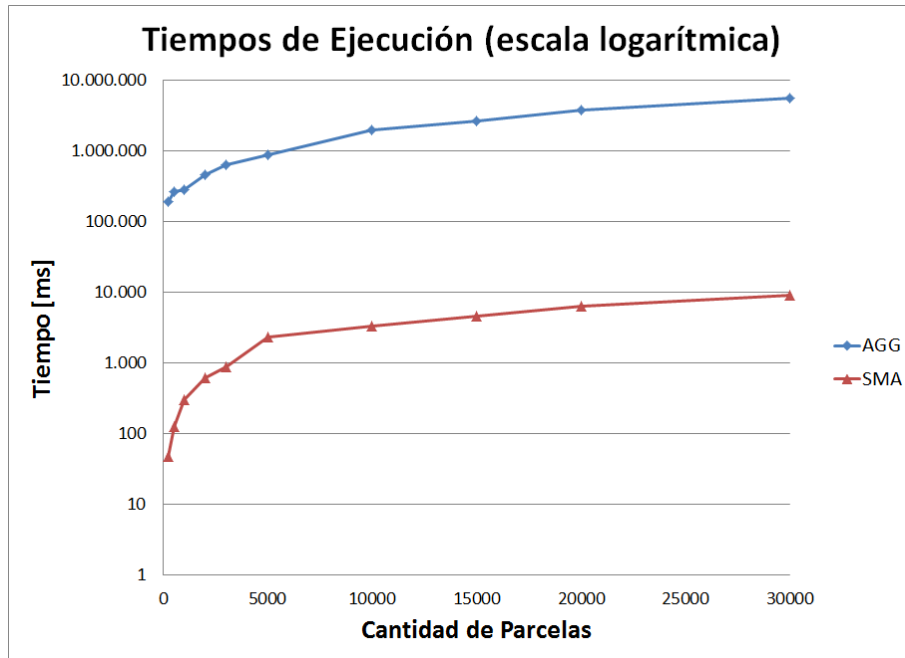


Figura 6. Tiempos de ejecución de ambos sistemas, en escala logarítmica.

Es importante destacar que el AGG está programado íntegramente en MATLAB<sup>®</sup> (sin uso de toolboxes adicionales), mientras que el SMA está programado en Java SE, por lo que la diferencia de performance podría ser menor que la obtenida, aunque según nuestras estimaciones, no lo suficiente para disminuir los 3 órdenes de magnitud que las separan.

Con todos los experimentos realizados, se pudo comprobar que el modelo se ajusta de manera adecuada a lo esperado.

## 5 CONCLUSIONES Y LÍNEAS FUTURAS DE INVESTIGACIÓN

Se desarrolló y probó en este trabajo un sistema basado en Algoritmos Genéticos tipo Grouping para resolver el problema de optimización del transporte de caña de azúcar y se comparó el mismo con un sistema desarrollado previamente con la misma finalidad basado en Sistemas Multiagentes. Los resultados obtenidos muestran que el sistema resuelve satisfactoriamente el problema en los casos probados, proporcionando resultados similares en ambas herramientas, pero siendo los tiempos de procesamiento del Sistema Multiagentes mucho menores.

Estos resultados pueden resumirse de la siguiente manera:

- Las soluciones encontradas por el Algoritmo Genético Grouping alcanzan en todos los casos un BET entre 1% y 7% menor al hallado por SMA.
- Ambos sistemas encuentran la solución en un tiempo linealmente proporcional al tamaño del problema, obteniéndose resultados completamente viables aún para los ejemplos más grandes utilizados.
- El sistema con SMA obtiene la solución en un tiempo que es tres órdenes de magnitud menor al del AGG. Para un caso típico de procesamiento diario de 3000 parcelas, el SMA obtiene una solución en aproximadamente un segundo.

- El desarrollo de ambos sistemas permitió comprobar que los mismos son fácilmente paralelizables y escalables en cantidad de variables. Estas características permiten complejizar el modelo propuesto sin demasiados inconvenientes. Además, su comportamiento mostró ser escalable con respecto al tamaño del problema.
- La influencia del operador de cruzamiento fue mucho menor que la de los operadores de mutación, indicando que se debería implementar otro operador de cruzamiento más adecuado.
- El modelo en su forma presente puede aplicarse a muchas agroindustrias en diversas zonas del país, ya que las características planteadas hasta el momento son generales.

En cuanto a líneas futuras de investigación, se pueden mencionar:

- Verificar con datos industriales el correcto comportamiento de los sistemas ante situaciones en las que la oferta de caña sea distinta de la demanda total de los ingenios
- Debe desarrollarse un sistema de llenado de la matriz de costos que tenga en cuenta las diversas variables del problema, incluyendo estado de los caminos y costo en combustible.
- El sistema debe complejizarse para incluir otras características de la caña de azúcar que resultan importantes para el problema (como variedad de la caña, porcentaje estimado de fibra, etc.).
- Se deben incorporar al sistema las características y demandas propias de la industria de azúcar de caña de la provincia de Tucumán (forma de trabajo, características de la producción, vehículos existentes, etc.).

Agradecimientos

Los autores agradecen el apoyo del proyecto PID 1318 y PID 1341 de la UTN y del proyecto CIUNT 26/E457, y a la EEAOC el apoyo, contacto con la industria, y uso de los datos.

## REFERENCIAS

- Ahmed, Z.H., 2010. Genetic Algorithm for the Traveling Salesman Problem using Sequential Constructive Crossover Operator. *International Journal of Biometrics and Bioinformatics (IJBB)*, 3(6), p.96.
- Chen, B. & Cheng, H.H., 2010. A review of the applications of agent technology in traffic and transportation systems. *Intelligent Transportation Systems, IEEE Transactions on*, 11(2), pp.485-497.
- Diez, O, Will, A., Rodriguez, S., et.al., Optimización del Transporte de Caña de Azúcar desde el productor al ingenio en la provincia de Tucumán, *Actas del primer Taller de Matemática Industrial, TAMI 2010, fascículo 6, serie B, Cursos y Seminarios en Matemática*, FCEyN-UBA. 2010.
- Falkenauer, E. & Delchambre, A., 1992. A genetic algorithm for bin packing and line balancing. In *Robotics and Automation, 1992. Proceedings., 1992 IEEE International Conference on*. IEEE, pp. 1186-1192 vol. 2.
- Ferber, J., 1999. Multi-agent systems: an introduction to distributed artificial intelligence, Addison-Wesley London.
- Le Gal, P.Y. et al., 2009. Coupled modelling of sugarcane supply planning and logistics as a management tool. *Computers and Electronics in Agriculture*, 68(2), pp.168-177.
- Giles, R.C. et al., 2006. The complexities of introducing the FREDD vehicle scheduling system into the Darnall mill area. In *Proceedings of the 80th Annual Congress of the South African Sugar Technologists' Association*, Durban, South Africa, 18-20 July 2006. South

- African Sugar Technologists' Association, pp. 66-70.
- Giles, R.C. et al., 2009. Vehicle scheduling project success at South African and Swaziland sugar mills. In Proceedings of the 82nd Annual Congress of the South African Sugar Technologists' Association, Durban, South Africa, 26-28 August 2009. South African Sugar Technologists' Association, pp. 151-163.
- Higgins, A.J., 2002. Australian sugar mills optimize harvester rosters to improve production. *Interfaces*, pp.15-25.
- Higgins, A.J. & Muchow, R.C., 2003. Assessing the potential benefits of alternative cane supply arrangements in the Australian sugar industry. *Agricultural Systems*, 76(2), pp.623-638.
- Higgins, A.J., 1999. Optimizing cane supply decisions within a sugar mill region. *Journal of Scheduling*, 2(5), pp.229-244.
- Jorio, R. et al., 2006. Simulation model to reduce the impact of rain stops and breakdowns on sugarcane harvesting, transport, and crushing system performances. In *Proc S Afr Sug Technol Ass.* p. 112.
- Lannes, A, Pucci, C. 2007. La agroindustria azucarera y su influencia en el PBI de Tucumán, *Banco Santiago del Estero*.
- Lodi, A., Martello, S. & Monaci, M., 2002. Two-dimensional packing problems: A survey. *European Journal of Operational Research*, 141(2), pp.241-252.
- Majorel Padilla, N., Décima, A., Will, A., Rodriguez, S., Diez, O., 2011. Optimización del Transporte de Caña de Azúcar en Tucumán utilizando Sistemas Multiagentes. *8va Jornadas de Informatica Industrial, 28 de agosto al 2 de septiembre, Cordoba, Argentina*.
- Pérez, D., Fandos, C., Scandaliaris, J., Mazzone, L., Soria, F., Scandaliaris, P., Estado actual y evolución de la productividad del cultivo de caña de azúcar en Tucumán y el noroeste argentino en el período 1990-2007. *EEAOC Publicación Especial 34*.
- Salcedo-Sanz, S., 2009. A survey of repair methods used as constraint handling techniques in evolutionary algorithms. *Computer science review*, 3(3), pp.175-192.
- Ülker, Ö., Korkmaz, E. & Özcan, E., 2008. A grouping genetic algorithm using linear linkage encoding for bin packing. *Parallel Problem Solving from Nature-PPSN X*, pp.1140-1149.
- Yosnual, J. & Supsomboon, S., 2004. An integer programming for sugarcane factory supply allocation. In Proceedings of the Fifth Asia Pacific Industrial Engineering and Management Systems Conference, 12-15 December, Gold Coast, Australia.
- Zhao, D. & Yi, J., 2006. Robot Planning with Artificial Potential Field Guided Ant Colony Optimization Algorithm. *Advances in Natural Computation*, pp.222-231.