

# Modelo de optimización en la gestión de inventarios mediante algoritmos genéticos

**César Hernando Valencia Niño**

D.Sc.(c) da Engenharia Elétrica  
Pontifícia Universidade Católica do Rio de Janeiro  
Investigador Grupo GRAM  
Universidade Santo Tomás USTA  
Bucaramanga, Colombia  
chvn@ele.puc-rio.br

**Silvia Nathalia Cáceres Quijano**

M.Sc.(c) da Engenharia de Produção  
Universidade Federal do Rio de Janeiro  
Pesquisadora Programa de Engenharia de Produção Instituto  
Alberto Luiz Coimbra - COPPE  
Rio de Janeiro, Brasil  
natacace@ufrj.br

**Resumen—** Este artículo presenta el diseño de un Algoritmo Genético (AG) que permita optimizar la gestión de inventarios en las cadenas de suministros y minimizar el Efecto Bullwhip, para esto, fueron considerados los costos de depósito, distribución y fabricación del producto además del costo individual de los elementos que serán pedidos. La cadena utilizada en la simulación contiene 5 niveles: cliente, minorista, depósito, distribuidor y fábrica, así las cantidades para cada par fueron consideradas para ser evaluadas por el AG en el mejor cromosoma. Adicionalmente, fue utilizado el modelo de coeficientes BMN para generar la función de evaluación de los cromosomas escogidos por el AG y así satisfacer las restricciones consideradas en el modelo.

**Palabras clave—** Algoritmos Genéticos, Efecto Bullwhip, Optimización de Inventarios y Coeficientes Bmn.

**Abstract—** This paper presents the design of a genetic algorithm (GA) that optimizes inventory management in supply chains. They were considered warehousing, distribution, and manufacturing product costs, plus the cost of individual items to be ordered. The string used in the simulation contains 5 levels, being: customer, retail, warehouse, distributor and factory. The amounts of each pair were considered to be evaluated by the GA in the best chromosome. Additionally the BMN coefficients model was used to generate the evaluation function of chromosomes selected by the GA and satisfies the constraints considered in the model.

**Keywords—** Genetic Algorithms, Bullwhip Effect, Supply Chain Optimization and BMN Coefficients.

## I. INTRODUCCIÓN

En búsqueda de la maximización del lucro en las empresas y la minimización del tiempo necesario para realizar los procesos en las cadenas de suministros, la gestión de inventarios es determinante; así, las cantidades de elementos que serán pedidas dependen de los tiempos y los cambios en los estándares de consumo de los clientes para generar fluctuaciones que consiguieran producir distorsiones como exceso de inven-

tarios o desabastecimiento (BullwhipEffect). De esta forma, diferentes organizaciones compiten hoy para mejorar tiempos, administrar eficientemente cantidades y desarrollar soluciones mediante diversos modelos con resultados que reducen entre otros el BullwhipEffect; en este artículo el modelo seleccionado para ser aplicado mezcla dos propiedades, los coeficientes BMN utilizados en los sistemas de generación de potencia y la posibilidad de incluir respuestas que sean resultado de procesos evolutivos.

De este modo, el algoritmo de selección de la mejor respuesta está inspirado en el principio de la evolución de las especies, o programación conocida como Algoritmos Genéticos, que permite evaluar un extenso espacio de búsqueda y encontrar respuestas viables u óptimas según el tipo de restricciones que sean utilizadas; en la literatura fueron encontrados modelos desarrollados con la misma inspiración [1] y con resultados evaluados por los autores como satisfactorios. No obstante, la mezcla con coeficientes BMN para ser adaptados en cantidades de inventarios no presentó ningún resultado.

En la segunda parte será presentada la formulación del problema, en la tercera parte el modelo del algoritmo genético, en la cuarta parte los experimentos realizados y, finalmente, los resultados obtenidos.

## II. FORMULACIÓN DEL PROBLEMA

El efecto látigo (también conocido como *Bullwhip Effect* o *Efecto Forrester*). Es un fenómeno importante en el estudio de las cadenas de distribución porque tiene consecuencias sobre la eficiencia del flujo de materiales en las cadenas de suministros. En [2] se marca el inicio del con-

cepto de compartir informaciones en la gestión de la cadena de suministros. Las informaciones así como los pedidos, se propagan con mayor volatilidad cuando se asciende en el nivel de la cadena de distribución (y/o suministros). En [3] llamaron este fenómeno de efecto “Bullwhip” o Efecto látigo.

Según [4], el Efecto látigo es el producto de la falta de coordinación en el desempeño en la cadena de suministros y una inadecuada gestión de inventarios, que ocurre cuando en cada nivel de la cadena optimiza apenas su propio objetivo sin considerar su impacto en la cadena entera.

La reducción del efecto látigo puede ser clasificada en 3 tipos de iniciativas:

- Alterar el proceso físico de producción, almacenamiento y transporte de los materiales.
- Compartir informaciones para el planeamiento en cada etapa de la cadena logística.
- Control de los efectos de las políticas comerciales para que no conlleven el flujo de la cadena al efecto látigo.

Tabla I.  
Estrategias de reducción do Efecto Látigo [5]

	<b>Forrester (1958)</b>	<b>Lee et al. (1997)</b>	<b>Simchi-Levi et al. (2000)</b>
Mejora del proceso logístico	Agilización del tratamiento de los pedidos	Formación de lotes de compra y de producción	Reducción del tiempo de reabastecimiento
Compartir Informaciones	Mejora en la calidad de los datos Ajuste de los inventarios	Procesamiento de las variaciones en la demanda	Formación de acuerdos estratégicos. Reducción de la incertidumbre
Reducción del efecto de políticas comerciales		Variaciones de precio Racionamiento	Reducción de la variabilidad

Según la Tabla 1, como una posible alternativa será utilizado el enfoque de Lee, formar lotes de compra y de producción y procesar las variaciones en la demanda.

En la propuesta de este artículo se busca desarrollar los siguientes objetivos:

- Generar un Modelo de Optimización de Inventarios para organizar los pedidos consi-

derados los tiempos y las variaciones en la demanda.

- Utilizar un Algoritmo Genético para encontrar la mejor configuración de respuesta.
- Realizar pruebas del modelo con demanda fija y variable.

### III. MODELO MEDIANTE AG

Para ser realizado el modelado del problema se estableció como objetivo disminuir el costo total de los inventarios a ser pedidos, para evitar tener costos altos por exceso de inventarios o desabastecimiento, para ello fueron utilizadas las ecuaciones de [6].

#### A. Costos considerados en el modelo

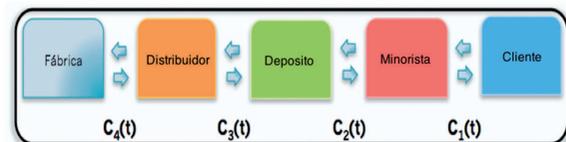
En la Tabla II, son presentados los costos y cantidades que serán considerados para obtener el mínimo costo posible, donde el índice *i* representa el nivel de origen y *j* el nivel de destino.

Tabla II  
Costos y Cantidades. Adaptado de [6]

<b>Costos y Cantidades</b>	<b>Símbolo</b>
• Costo de depósito de la mercancía Cantidad de elementos. Costo individual de cada unidad	CEM(t) QEE <sub>i</sub> (t) CIE <sub>i</sub> (t)
• Costo de unidades anteriores Cantidad de órdenes anteriores Costo de la orden de unidad anterior	CUA <sub>i</sub> (t) QOA <sub>i</sub> (t) COA <sub>i</sub> (t)
• Costo de elementos a ser pedidos Cantidad de elementos Costo individual de cada unidad	CEP <sub>i</sub> (t) QEP <sub>i</sub> (t) CIP <sub>i</sub> (t)
• Costo de distribución Costo de envío de <i>i</i> para <i>j</i> Costo por unidad Cantidad de unidades distribuidas de <i>i</i> para <i>j</i> Capacidad de carga Costo por la distribución de la carga de <i>i</i> para <i>j</i>	CD <sub>ij</sub> (t) CE <sub>ij</sub> (t) CUD <sub>ij</sub> (t) QUD <sub>ij</sub> (t) CC <sub>ij</sub> (t) CPD <sub>ij</sub> (t)
• Costo de fabricación Cantidad de demanda de <i>i</i> para <i>j</i> Costo de producción por unidad.	CF <sub>ij</sub> (t) QD <sub>ij</sub> (t) CPU <sub>ij</sub> (t)

En la Figura 1 es presentada la configuración con los 5 niveles utilizada en el modelado, también son presentados los 4 costos que generan el costo total que se ha de minimizar.

FIG. 1. 5 NIVELES DEL MODELO UTILIZADO.



En la Ecuación 1 es presentado el costo de depósito de la mercancía.

$$CEM_i(t) = OEE_i(t) * CIE_i(t) \quad (1)$$

En la Ecuación 2 es presentado el costo de las órdenes anteriores.

$$CUA_i(t) = QOA_i(t) * COA_i(t) \quad (2)$$

En la ecuación 3 es presentado el costo de los elementos que van a ser pedidos.

$$CEP_i(t) = QEP_i(t) * CIP_i(t) \quad (3)$$

En la ecuación 4 es presentado el costo de distribución para etapa de la cadena.

$$CD_i(t) = [(CE_{ij}(t) + CUD_i(t)) * QUD_{ij}(t)] + [(QUD_i(t) / CC_i(t)) * CPD_i(t)] \quad (4)$$

En la ecuación 5 es presentado el costo de fabricación.

$$CF_i(t) = QD_{ij}(t) * CPU_i(t) \quad (5)$$

En las ecuaciones 6, 7, 8 y 9 son presentados los costos individuales de cada punto de la cadena siendo ellos minorista, depósito, distribuidor y fábrica respectivamente.

$$C_1(t) = CEM_1(t) + CUA_1(t) + CEP_1(t) \quad (6)$$

$$C_2(t) = CEM_2(t) + CUA_2(t) + CEP_2(t) + CD_2(t) \quad (7)$$

$$C_3(t) = CEM_3(t) + CUA_3(t) + CEP_3(t) + CD_3(t) \quad (8)$$

$$C_4(t) = CEM_4(t) + CUA_4(t) + CEP_4(t) + CD_4(t) + CF_4(t) \quad (9)$$

**B. Coeficientes Bmn**

Los coeficientes [7] BMN inicialmente utilizados para relacionar pérdidas con penalidades dentro de los modelos matemáticos de sistemas de transmisión de energía[8,9], son empleados en este trabajo para proporcionar una herramienta que permita obtener las “pérdidas” del sistema en la función de salida del modelo.

Estos son un conjunto de coeficientes, en forma matricial, cada línea y columna de la matriz corresponde a un punto de origen-destino así todas las etapas de la cadena son agrupadas.

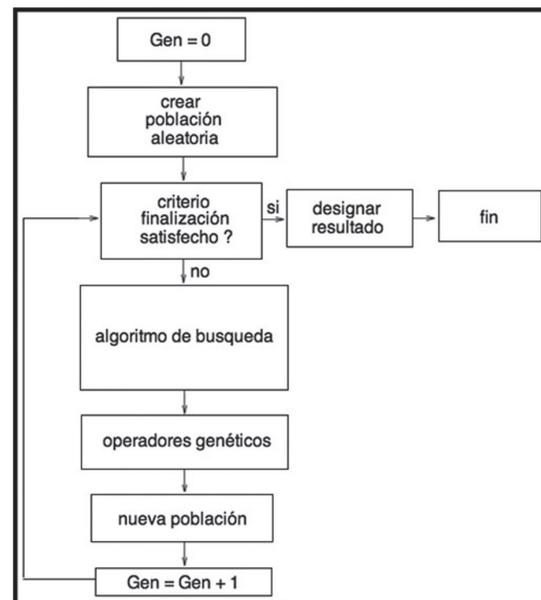
$$\begin{bmatrix} 0 & \dots & * \\ \vdots & \ddots & \vdots \\ * & \dots & 0 \end{bmatrix} \quad (10)$$

La matriz de la ecuación 11 representa el conjunto de coeficiente BMN, que en las columnas y filas tiene las mismas variables que generan una diagonal de ceros, en los otros valores son incluidos los coeficientes de pérdidas entre cada par de niveles del modelo, dichos coeficientes son obtenidos del histórico del comportamiento del sistema, en tiempo anteriores a la utilización de este modelo.

**C. Diseño del algoritmo genético**

Los algoritmos genéticos son una técnica de búsqueda local que también es utilizada en optimización, con inspiración en el principio de la evolución de las especies y la supervivencia del más apto, para este trabajo fue ejecutado el diagrama de flujo de la Figura 2, considerados operadores genéticos como cruzamiento y mutación.

FIG. 2. DIAGRAMA DE FLUJO UTILIZADO



La representación utilizada genera un cromosoma con las siguientes características:

Tabla III  
Representación utilizada

$QEE_i(t)$	$QEP_{ij}(t)$	$QUD_{ij}(t)$	$QD_{ij}(t)$
------------	---------------	---------------	--------------

Donde el primer Gen del cromosoma está compuesto por la cantidad de elementos en el depósi-

to, el segundo Gen tendrá 3 elementos que son la cantidad de elementos a ser pedidos de una etapa para otra, el tercer Gen contendrá 3 elementos que son las cantidades distribuidas de una etapa para otra y finalmente el cuarto Gen tendrá la cantidad de elementos a ser fabricados.

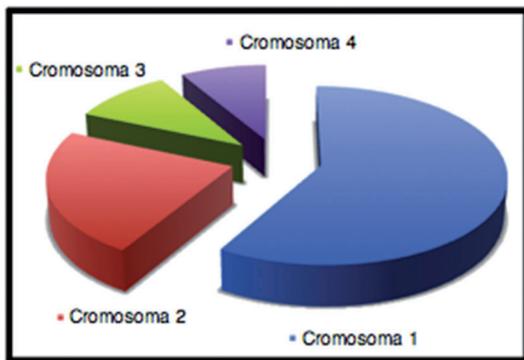
En la decodificación para obtener la solución real, fue implementada una función en Matlab® que considera los coeficientes utilizados y la mejor respuesta encontrada por el algoritmo genético [11, 12].

Como función de evaluación fue utilizada la ecuación 11, que genera el costo total  $C(t)$  en un tiempo  $t$ .

$$C(t) = C_1(t) + C_2(t) + C_3(t) + C_4(t) \quad (11)$$

El proceso de selección que es determinante en el algoritmo genético fue realizado mediante la ruleta, donde las porciones son proporcionales a la aptitud de los cromosomas según como es presentado en la Figura 3.

FIG. 3. RULETA DE SELECCIÓN DE LA POBLACIÓN INICIAL



Como operadores genéticos fueron utilizados los dos principales, cruzamiento que fue realizado en diferentes tasas y tipos y la mutación también fue realizada en diferentes tasas y de tipo uniforme.

La inicialización de la población fue aleatoria para mantener la diversidad de cromosomas en el universo de respuestas [13], para dicha inicialización no se utilizó ningún tipo de semilla que seleccionara una región búsqueda especial.

Los parámetros y criterios de parada, cambiaron para los diferentes experimentos realizados [14, 15], en los resultados obtenidos son presentados los diversos valores y tipos de configuración utilizados.

#### IV. EXPERIMENTOS REALIZADOS

Los experimentos realizados pretenden obtener la mejor configuración del AG para alcanzar la mejor respuesta con el menor esfuerzo computacional, se estableció una configuración básica que consiguió cumplir el objetivo y sobre esta fueron realizados los cambios para determinar la influencia de cada parámetro, las configuraciones fueron las indicadas en la Tabla IV.

Tabla IV  
Configuraciones utilizadas

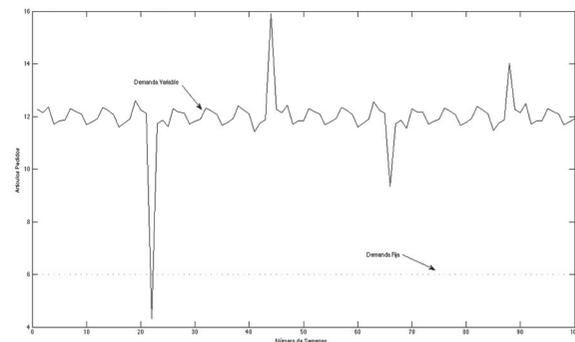
Parámetros	C1	C2	C3	C4	C5
Tamaño de la población	10	50	50	50	50
Tipo de cruzamiento	SP	SP	SP	TP	H
Tasa de cruzamiento	0.8	0.8	0.4	0.8	0.8
Tipo de mutación	U	U	U	U	U
Tasa de mutación	0,05	0.05	0.05	0.05	0.2
Número de generaciones	100	40	100	60	60
Total de individuos	1x103	2x103	5x103	3x103	3x103

Donde **SP** significa fue que utilizado cruzamiento de un solo punto, **TP** de dos puntos y **H** que fue utilizado cruzamiento Heurístico, **U** significa que el tipo de mutación fue uniforme.

#### V. RESULTADOS OBTENIDOS

Para la evaluación del algoritmo propuesto fueron seleccionados valores para la demanda fija y demanda variable basados en los históricos de 100 semanas atrás, la Figura 4 presenta el comportamiento de los valores escogidos.

FIG. 4. RULETA DE SELECCIÓN DE LA POBLACIÓN INICIAL



**A. Tasa de demanda fija**

A continuación son presentados los resultados para las 5 configuraciones establecidas para una demanda fija, en ellas está incluido el comportamiento de las respuestas en las generaciones y la media de dichas respuestas.

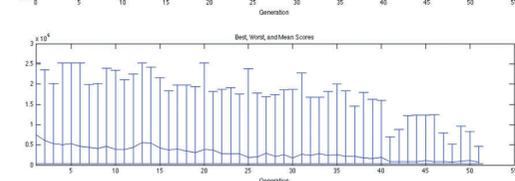
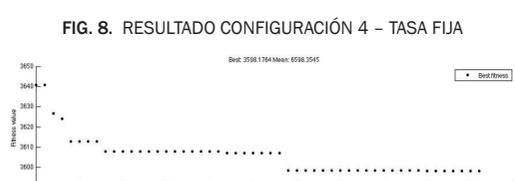
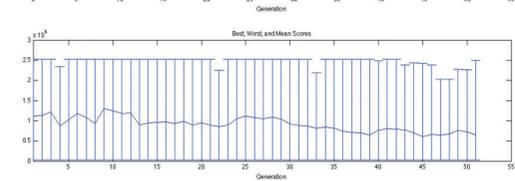
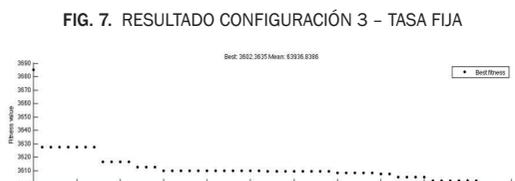
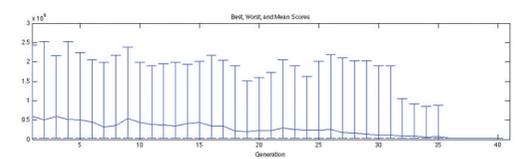
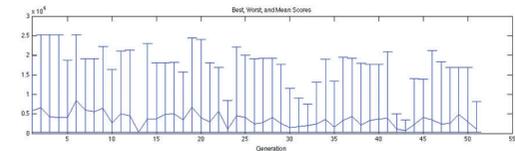
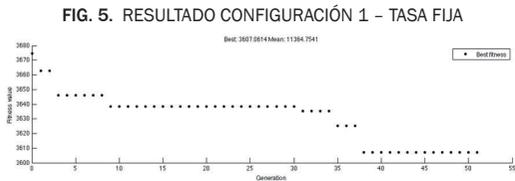


FIG. 9. RESULTADO CONFIGURACIÓN 5 – TASA FIJA

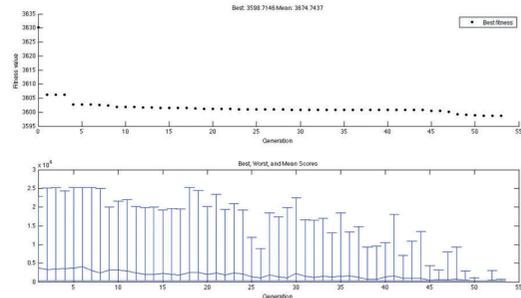


Tabla V  
Resultados de costos para Tasa Fija

Configuración	Mejor	Media
1	3607.06	11364.75
2	3596.09	3603.90
3	3602.36	63936.83
4	3598.17	6598.35
5	3598.71	3674.74

Los resultados presentados en el comportamiento del algoritmo obedecen a un problema de minimización de costos totales mediante la configuración adecuada de los elementos almacenados y elementos pedidos, para cada configuración se presentan en la parte superior el comportamiento para cada generación se resalta que con la evolución de los individuos generados los costos son menores.

**B. Tasa de demanda variable**

A continuación son presentados los resultados para las 5 configuraciones establecidas para una tasa de demanda variable, en ellas son presentadas el comportamiento de las respuestas en las generaciones y la media de dichas respuestas.

FIG. 10. RESULTADO CONFIGURACIÓN 1 – TASA VARIABLE

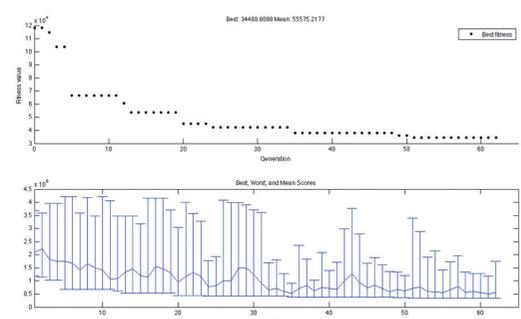


FIG. 11. RESULTADO CONFIGURACIÓN 2 – TASA VARIABLE

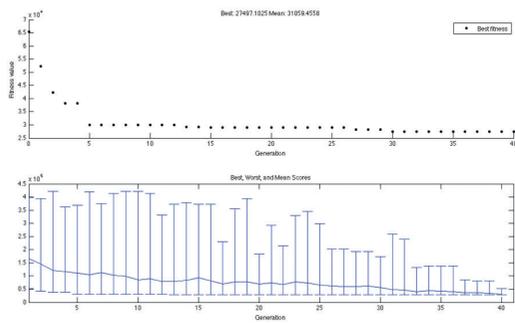


FIG. 12. RESULTADO CONFIGURACIÓN 3 – TASA VARIABLE

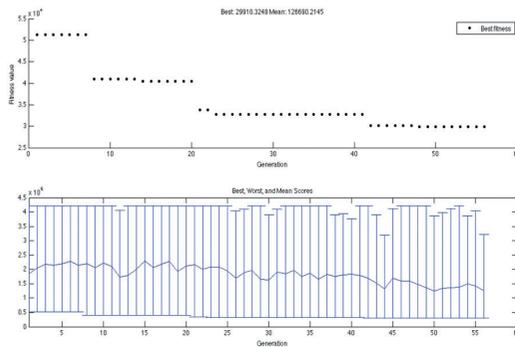


FIG. 13. RESULTADO CONFIGURACIÓN 4 – TASA VARIABLE

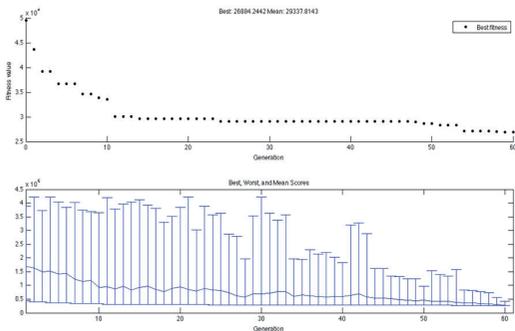


FIG. 14. RESULTADO CONFIGURACIÓN 5 – TASA VARIABLE

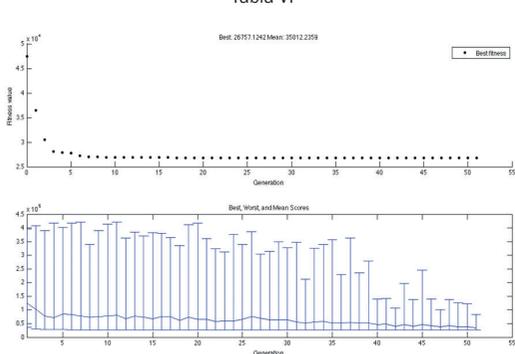


Tabla VI

Resultado de costos para Tasa Variable

Configuración	Mejor	Media
1	34488.80	55575.21
2	27497.10	31059.45
3	29910.32	126690.21
4	26884.24	29337.81
5	26757.12	35012.23

## VI. CONCLUSIONES

La utilización de los algoritmos genéticos en la optimización de la gestión de inventarios generó una disminución de los costos de operación, así como la regularización de las órdenes cuando la demanda fue variable, en las simulaciones realizadas se obtuvo el mejor resultado mediante el cruzamiento heurístico, un número mayor en la población inicial fue más determinante que un número mayor de generaciones para encontrar la mejor respuesta, mediante la utilización de los coeficientes Bmn se generó una penalización en los tiempos de atraso “lead time” en la entrega de pedidos lo que podría entenderse como una penalización “Soft” para el AG.

El modelo que se tomó como referencia presentaba costos totales antes de ser utilizado el AG de USD 4567 para la tasa de demanda fija y de USD 33245 para la tasa de demanda variable, es posible comparar estos resultados con los mejores obtenidos y apreciar la optimización realizada por el AG reflejada en la disminución de costos totales, todo esto considerando las restricciones impuestas al modelo para que no existan desabastecimiento o exceso de inventarios para cada nivel de la cadena utilizada, además de las penalidades establecidas por los coeficientes Bmn.

El tiempo total de simulación fue de 100 semanas, así es posible considerar las fluctuaciones para la tasa variable y la estanqueidad para la tasa fija.

Como trabajo futuro se espera configurar el modelo propuesto como un Algoritmo Genético Paralelo, para mejorar los resultados ya obtenidos, así que la utilización de nuevos operadores genéticos que mantienen la integridad de la información genética en el cruzamiento como el “Ring Crossover” así como el “Arithmetic Crossover”.

## REFERENCIAS

- [1] J. VonNeuman, «The Theory of Self-Reproducing Automata», University of Illinois Press, Urbana, 1996.
- [2] J. Forrester, «Industrial Dynamics», Harvard Business Review. Boston, n. 36, Julio-Agosto 1958.
- [3] L. H. Lee, V. Padmanabhan y S. Whang, «Information Distortion in a Supply Chain: The Bullwhip Effect», *Management Science*, Vol. 50, No. 12, Diciembre 2004.
- [4] S. Chopra y P. Meindl, «Gerenciamento da Cadeia de Suprimentos – Estratégica, Planejamento e Operação», São Paulo: Prentice Hall, 2003.
- [5] J. P. P. Dias, 2003, «Gestão dos estoques numa cadeia de distribuição com sistema de reposição automática e ambiente colaborativo», *Disertación de Maestría – Programa de Post-graduación en Ingeniería de Producción* Escuela Politécnica de la Universidad de San Pablo.
- [6] J. Lu, P. Humphreys, R. McIvor, y L. Maguire, «Employing Genetic Algorithms to minimise the Bullwhip Effect in an online efficient-responsive supply chain», en 2009 IEEE/INFORMS International Conference on Service Operations, Logistics and Informatics, Chicago, IL, USA, 2009, pp. 117-122.
- [7] E. Hill y W. Stevenson, «A New Method of Determining Loss Coefficients», *IEEE Transactions on Power Apparatus and Systems*, vol. 87, no. 7, pp. 1548-1553, Jul. 1968.
- [8] G. Kumaran y V. S. R. K. Mouly, «Using evolutionary computation to solve the economic load dispatch problem», en *Proceedings of the 2001 Congress on Evolutionary Computation (IEEE Cat. No.01TH8546)*, Seoul, South Korea, pp. 296-301.
- [9] H. Happ, «Optimal Power Dispatch», *IEEE Transactions on Power Apparatus and Systems*, vol. 93, no. 3, pp. 820-830, May. 1974.
- [10] LanshunNie, XiaofeiXu, y Dechen Zhan, «Collaborative Planning in Supply Chains by Lagrangian Relaxation and Genetic Algorithms», en 2006 6th World Congress on Intelligent Control and Automation, Dalian, China, 2006, pp. 7258-7262.
- [11] P. Radhakrishnan, V. M. Prasad, y M. R. Gopalan, «Genetic Algorithm Based Inventory Optimization Analysis in Supply Chain Management», en 2009 IEEE International Advance Computing Conference, Patiala, India, 2009, pp. 418-422.
- [12] J. Lu, P. Humphreys, R. McIvor, y L. Maguire, «Employing genetic algorithms to minimise the bullwhip effect in a supply chain», en 2007 IEEE International Conference on Industrial Engineering and Engineering Management, Singapore, 2007, pp. 1527-1531.
- [13] R. Perumalsamy y J. Natarajan, «Predictive analytics using Genetic Algorithm for efficient supply chain inventory optimization», in 2010 Second International conference on Computing, Communication and Networking Technologies, Karur, India, 2010, pp. 1-8.
- [14] W. Jianhua y H. Xianfeng, «A hybrid genetic algorithm for agile supply chain scheduling optimization», en 2010 2nd International Conference on Future Computer and Communication, Wuhan, China, 2010, pp. V1-396-V1-400.
- [15] N. P. Joseph y G. Radhamani, «Determining Robust Solutions in Supply Chain Using Genetic Algorithm», en 2010 International Conference on Data Storage and Data Engineering, Bangalore, India, 2010, pp. 275-277.