

Modelo de simulación para la optimización del inventario de una distribuidora, basado en Simulación Monte Carlo y Algoritmo Metaheurístico Genético

Simulation model for inventory optimization of a distributor, based on Monte Carlo Simulation and Genetic Metaheuristic Algorithm

Katherine R. Chicaiza¹, Alex L. Gómez², Peter A. Ruiz³, y Lorenzo Cevallos-Torres⁴

RESUMEN

La presente investigación tiene como objetivo minimizar los costos de ventas de una distribuidora, debido a que, al no llevar un correcto control de inventario, al final de cada periodo mensual quedan demasiados productos en stock almacenados en bodega que se convierten en grandes pérdidas de dinero. Para la realización de este estudio, se tiene un histórico de datos reales que va desde todo el año 2017 hasta junio del 2019, posteriormente desde el mes de julio hasta diciembre del 2019 se simuló las compras y ventas diarias de los productos mediante un Modelo de Simulación Monte Carlo, completando así la muestra necesaria para la generación de los resultados estimados en el año 2020 utilizando el modelo basado en el Algoritmo Metaheurístico Genético. Los resultados obtenidos mediante el Algoritmo Metaheurístico, Modelo de Simulación Monte Carlo, y Función Objetivo de minimización de costos que representan aproximadamente un 10% en comparación a los costos de periodos anteriores.

Palabras clave: Minimizar costos, Algoritmo Metaheurístico Genético, Simulación Monte Carlo, Gestión de inventarios.

ABSTRACT

The purpose of this investigation is to minimize the costs of sales of a distributor, since, not having adequate inventory control, at the end of each monthly period there are too many products stored in the warehouse that become large losses of money. For the realization of this study, there is a history of real data that goes from the whole year 2017 to June 2019, then, from July to December 2019, the daily purchases and sales of the products were simulated through a simulation of the Monte Carlo model, therefore completing the sample necessary for the generation of the results estimated in the year 2020 using the model based on the Genetic Metaheuristic Algorithm. The results obtained through the Metaheuristic Algorithm, the Monte Carlo Simulation Model and the Objective Cost Minimization Function that represent approximately 10% compared to the costs of previous periods.

Keywords: Minimize costs, Genetic Metaheuristic Algorithm, Monte Carlo Simulation, Inventory Management.

Fecha de recepción: Mayo 20, 2019.

Fecha de aceptación: Septiembre 5, 2019.

Introducción

La ejecución de un correcto control de inventario es de vital importancia para maximizar el lucro de las empresas al menor costo. Puesto que una mala gestión de este puede ser la culpable de generar inventarios excesivos al final del periodo, o por el contrario sufrir de desabastecimiento lo que, en cualquiera de los dos casos, tendrá como consecuencia pérdidas de dinero en cualquier negocio, como se lo puede apreciar en el local de distribución del presente estudio. Por tanto, el objetivo de este proyecto es hacer uso de algoritmos de simulación, como el del método Monte Carlo y Algoritmo Metaheurístico, para la generación de estimaciones

puntuales cercanas a los datos reales que permitirán la optimización del manejo del inventario equilibrando la inversión del capital hacia los productos y la utilidad que generan los mismos.

Arias y Londoño en [1], desarrollan un algoritmo de Optimización basado en Algoritmos Genéticos con el fin de optimizar el problema asociado al sistema de inventario (Q; r) Multi-Artículos, con aleatoriedad tanto en la demanda como en el tiempo de reposición, cuya política de decisión es minimizar la inversión total de inventario anual, sujeta a un número máximo esperado de pedidos por año y a un nivel mínimo esperado de satisfacción. Como resultados ofrecieron una solución aceptable en un tiempo de

¹ Estudiante de Ingeniería en Sistemas Computacionales. Universidad de Guayaquil, Ecuador. E-mail: katherine.chicaizam@ug.edu.ec

² Estudiante de Ingeniería en Sistemas Computacionales. Universidad de Guayaquil, Ecuador. E-mail: alex.gomez@ug.edu.ec

³ Estudiante de Ingeniería en Sistemas Computacionales. Universidad de Guayaquil, Ecuador. E-mail: peter.ruiza@ug.edu.ec

⁴ Ing. en Estadística Informática, MSc. en Modelado Computacional en Ingeniería. Universidad de Guayaquil, Ecuador. E-mail: lorenzo.cevallost@ug.edu.ec

Como citar: Chicaiza Moncayo, K., Gomez Sanchez, A., Ruiz Anton, P., & Cevallos-Torres, L. (2019). Modelo de simulación para la optimización del inventario de una distribuidora, basado en Simulación Monte Carlo y Algoritmo Metaheurístico Genético. *Ecuadorian Science*, 3(2), 33-38.
DOI: <https://doi.org/10.26911/issn.2602-8077vol3iss2.2019pp33-38p>.

cómputo razonable e incluso, presentan una solución alternativa para el caso en que haya pedidos pendientes ante la carencia de una metodología con herramientas analíticas para una solución con más precisión, cualesquiera sean las condiciones sobre Q y r , en dicho caso. Sin embargo, los autores hacen uso del paquete de optimización OptQuest que conlleva al manejo de múltiples variables para su funcionamiento, lo cual lo vuelve extenso y complicado de realizar en comparación con los algoritmos desarrollados en VBA sobre la hoja de cálculo de Microsoft Excel implementados sin mucha complejidad en el presente proyecto.

La simulación mediante métodos heurísticos es de gran ayuda cuando se quiere reproducir los rasgos de un sistema real, tal y como lo describe Montenegro en [2], quien realiza un sistema de inventarios mediante simulación Monte Carlo con el fin de mejorar el manejo del mismo, mediante el uso de herramientas o técnicas estadísticas que permitan pronosticar el producto terminado, cálculo de los tiempos de llegada de materias primas y stock de seguridad, para mejorar la administración de inventarios en la empresa. Sin embargo, el autor recalca que los resultados obtenidos no son muy precisos debido al modelo implementado en su proyecto y por lo tanto recomienda utilizar métodos más sofisticados, como el que se realiza en el presente estudio el cual se basa en Algoritmos Metaheurísticos que guían una heurística subordinada combinando distintos conceptos para explorar y explotar el espacio de búsqueda para determinar la mejor solución.

Izar e Ynzunza en [3] analizan un método Híbrido que combina dos modelos de inventarios: cantidad económica de pedido (EOQ) y punto de reorden, incluyendo el tiempo de entrega de forma aleatoria para que los datos se asemejen más a la realidad y sea aplicable a cualquier distribución de probabilidad haciendo uso de registros históricos de la demanda del artículo y los tiempos de entrega del proveedor. Con los resultados que obtuvieron determinaron la cantidad de pedido y el punto de reorden óptimos para la minimización de costos dentro del inventario en los meses posteriores. Pero, los mismos autores concluyen que el método no es práctico si la cantidad de datos a utilizar es demasiado grande debido al número elevado de cálculos que se necesitarían para llegar a una solución, lo que en comparación con el presente trabajo no sería un problema ya que se hace uso de sistemas de simulación que implementan algoritmos apropiados tanto para el manejo de volúmenes de datos y generación de estimaciones, como lo son el método Monte Carlo y el Algoritmo Metaheurístico Genético.

Azofeifa, Carlos E. en [4] utiliza simulación de Monte Carlo para estimar el riesgo de fracaso de un proyecto de inversión en una compañía que comercializa equipos informáticos, utilizando para este propósito la hoja electrónica Excel y haciendo uso de varias funciones preestablecidas dentro de la herramienta informática, demostrando lo importante que pueden llegar a ser estos sistemas para la toma de decisiones de una empresa. Los resultados obtenidos le permitieron tener un juicio sobre la probabilidad de los posibles valores de utilidad o de pérdida del proyecto. Por igual, en el presente estudio se hará el uso de simulación Monte Carlo en el programa informático Excel, con la diferencia de que aparte de utilizar las funciones de la herramienta se crearán nuevos sistemas con algoritmos específicos para el análisis y generación de resultados óptimos esperados.

Materiales y métodos

Para realizar el análisis y la simulación se tiene como material los datos históricos del inventario desde el año 2017 hasta el mes de junio del 2019, sin embargo, se hace uso del modelo de Simulación Monte Carlo, junto con su distribución de probabilidad, para la

generación de los datos faltantes que van desde julio a diciembre del 2019.

En el estudio [16] se indica que la simulación es importante realizar debido a que reproduce objetos reales cuando por diversos problemas que se pueden presentar tales como los recursos, tiempo y seguridad no es posible llevar a cabo la actividad en su entorno natural con sus verdaderos componentes.

Cevallos y Botto en [6] indican que, el método Monte Carlo es una técnica de análisis numérico que se basa en el uso de una secuencia de números aleatorios, con el propósito de muestrear los valores correspondientes a las variables probabilísticas de un determinado problema. Debido al alto número de estados posibles del sistema, se hace imposible calcular el valor promedio de todos estos estados, por lo que se decide tomar una muestra y estimar esos valores promedio, de distribuciones de probabilidad.

El método de Monte Carlo es una técnica de análisis numérico para realizar simulación, basada en el uso de una secuencia de números aleatorios, con el propósito de muestrear los valores correspondientes a las variables probabilísticas de un determinado problema [17]. Además, en el trabajo [7] añade que la Simulación de Monte Carlo proporciona, con la creación de un modelo, la respuesta de posibles resultados mediante la sustitución de un rango de valores (representados por una distribución de probabilidad) para cualquier factor con incertidumbre. Luego calcula los resultados una y otra vez, cada vez usando un grupo diferente de valores aleatorios de las funciones de probabilidad. Para completar una Simulación de Monte Carlo puede ser necesario realizar miles o decenas de miles de cálculos, dependiendo de la cantidad de incertidumbre y de los rangos especificados.

Algoritmo 1 AlgoritmoSimulacionModeloMonteCarlo()

```
Sub randomValues()
  Read numProducts, numRowsT, numPeriods, a, b
  As Integer
  Dim ramValue As Long
  numRows = 7
  numColumn = 3
  For p = 1 To numPeriods
    For i = 1 To numProducts
      For j = 1 To numRowsT
        Cells(numRow, numColumn) = Round((a +
          (Rnd() *
            (b - a))), 0)
        numRow = numRow + 1
      Next j
      numRow = 7
      numColumn = numColumn + 1
    Next i
    numRow = 7
    numColumn = numColumn + 1
  Next p
End Sub
```

La fórmula acorde a la distribución de probabilidad presente y que se utilizó para la simulación en el algoritmo 1 es:

$$a + rand() * (b - a)$$

Donde:

a : representa el valor mínimo dentro del rango de simulación.

b : representa el valor máximo dentro del rango de simulación.

$rand()$: son números aleatorios.

Distribución de probabilidad

La distribución de probabilidad que siguen los datos de la muestra se logró determinar mediante el uso de la herramienta Stat::Fit del software de modelado de sistemas de simulación optimizados ProModel 2016. Cevallos y Botto en [15] indican que esta herramienta se utiliza para determinar el tipo de distribución de un conjunto de datos. Es por ello que en primer lugar se recolectan los datos que posteriormente se proceden a insertar en la herramienta Stat::Fit una muestra de 30 datos reales, la cual permite analizar el tipo de distribución de probabilidad [18] y sobre la cual se utilizará para la simulación de compras y ventas de los productos. lo que da como resultado una variada información estadística como se muestra en la Fig. 1.

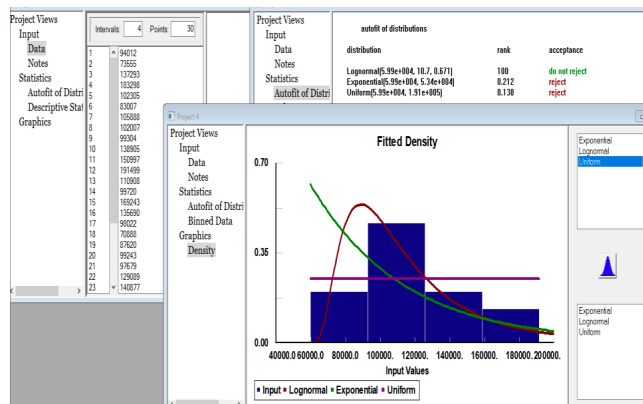


Figura 1. Datos estadísticos obtenidos mediante la herramienta Stat::Fit del software ProModel en base a la muestra de 30 datos reales de ventas mensuales.

Tal como se lo aprecia en la Fig. 1, los datos reales siguen una distribución de tipo LogNormal tanto para ventas como compras de los productos, lo que para los autores del [8], esta distribución es una probabilidad utilizada para expresar el comportamiento de observaciones con asimetría positiva, en donde la mayoría de los valores ocurren en las proximidades de un valor mínimo. En el estudio [6] se indica que la distribución de probabilidad logNormal se obtiene cuando la distribución normal describe los logaritmos de una variable. Esta distribución es característica en conjunto de datos donde existe mayor frecuencia de valores pequeños por lo cual la media se desplaza hacia la derecha y esto hace que el mejor estadígrafo de posición sea la moda y no la media aritmética.

La función de densidad de probabilidad “PDF” es la siguiente:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{[\ln(x-\lambda)-\mu]^2}{2\sigma^2}\right], x > \lambda, \sigma > 0$$

La función de distribución acumulada “CDF” es la siguiente:

$$F(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{[\ln(t-\lambda)-\mu]^2}{2\sigma^2}\right] dt, x > \lambda, \sigma > 0$$

$$\text{media} = \exp(\mu + 0.5\sigma^2) + \lambda$$

$$\text{varianza} = \exp(2\mu + 2\sigma^2)(\exp(\sigma^2) - 1)$$

Donde:

- μ = parámetro de ubicación
- σ = parámetro de escala
- λ = parámetro de valor umbral
- $\pi = 3.1416....$

Herramienta Solver en hoja Excel

Cuesta en [11] indica que, Solver es un programa de complemento de Microsoft Excel, muy aplicado sobre todo en el mundo empresarial, permite calcular el valor de una celda que depende de diversos factores o variables donde a la vez existen una serie de restricciones que han de cumplirse, es decir la herramienta Solver de Excel realiza cálculos para la resolución de problemas de programación lineal, en donde a partir de una función lineal a optimizar (máximo o mínimo) y cuyas variables están sujetas a unas restricciones expresadas como inecuaciones lineales, el fin es obtener valores óptimos bien sean máximos o mínimos.

Solver ajusta los valores de las celdas de variables de decisión para que cumplan con los límites de las celdas de restricción y den el resultado deseado en la celda objetivo. En resumidas cuentas, se puede usar Solver para determinar el valor máximo o mínimo de una celda cambiando otras celdas.

Modelo de inventario

El modelo AHP está definido de la siguiente forma:

Guamantica en [5] considera que, el inventario es la cantidad almacenada de materiales que se utiliza para la producción o satisfacción de la demanda del consumidor. La finalidad en el manejo de los inventarios es tratar de minimizar costos y tener un mejor control de estos. Es muy importante que las empresas tengan su inventario atentamente controlado, vigilado y ordenado, dado a que de éste depende el proveer y distribuir adecuadamente lo que se tiene, colocándolo a disposición en el momento indicado.

De acuerdo con como se maneja actualmente el inventario dentro de la distribuidora de tarjetas, se utilizará el modelo EOQ sin faltantes ya que se toma en cuenta varios supuestos:

- La demanda es constante, es decir que se conoce la tasa de demanda aproximada.
- No se admiten faltantes.
- Se le atribuye un costo por mantener guardado, es decir un costo por inventario.
- Tiene un costo de pedido.
- Todos los costos se mantienen constantes.
- La reposición es instantánea, esto es que NO existe un tiempo en el que el pedido se demora, es decir se reabastece inmediatamente cuando este llega a cero o a una cantidad determinada.




Figura 2. Gráfica representativa del modelo de inventario EOQ.

Por tanto, para calcular la cantidad óptima de inventario se hará uso de la siguiente fórmula:

$$Q^* = \sqrt{\frac{2C_p D}{C_{MI}}}$$

Donde:

Q^* : Representa la cantidad óptima, y depende principalmente de CP y CMI .

CP : Los costos por hacer un pedido.

CMI : Los costos de inventario.

D : Demanda del producto.

Además, con respecto a esto se deben hacer las siguientes consideraciones:

1. Cuando la cantidad que se elige es menor que la óptima, se puede apreciar que los costos de mantener en inventarios son menores que los generados por los costos por pedido. Esto es: $CP > CMI$.
2. Si se elige la cantidad óptima se igualan los costos de inventario y de pedido. $CP = CMI$
3. Si se elige una cantidad mayor los costos por pedido tienden a ser menores que los generados por los inventarios. $CP < CMI$

Algoritmo Genético

Los Algoritmos Genéticos (AGs) son métodos adaptativos que pueden usarse para resolver problemas de búsqueda y optimización. Si bien no se garantiza que el Algoritmo Genético encuentre la solución óptima del problema, existe evidencia empírica de que se encuentran soluciones de un nivel aceptable, en un tiempo competitivo con el resto de los algoritmos de optimización combinatorios tal como lo describen en [10].

Algoritmo 2 AlgoritmoSimulaciónModeloAlgoritmo-Genetico()

```
Sub GenethicAlgorithm()
  Declare maxValue, minValue, fixedValue,
  numGenerations
  as Double
  Declare numGenes, pcSelection, lvlMutation
  as Integer
  Initialize numRows = 3
  Initialize = 3
  Call clear(numGenes)
  Assign in Cell(numRow, numColumn) = "Nº Gen"
  For i = 1 To numGenes
    Assign in numRow = numRow + 1
    Assign in Cells(numRow, numColumn) = i
  Next i
  Declare functionObjetive, costTotal, earnings As Double
  Initialize numColumnX = 14
  Initialize numRows = 5
  For m = 1 To 12
    For b = 1 To numGenerations
      If b = 1 Then
        Assign in Cells(numRow, numColumn + 1) =
        "GENES"
        Assign in Cells(numRow, numColumn + 2) =
        "COST"
        Assign in Cells(numRow, numColumn + 3) =
        "EARNINGS"
        Declare arrayGen(4) As Double
        For c = 1 To numGenes
          numRow = numRow + 1
          For i = 1 To 4
            If (i Mod 2) = 1 Then
              arrayGen(i - 1) = Round((minValue +
```

```
(Rnd() * (maxValue - (maxValue * 0.42))),
0)
Else
  arrayGen(i - 1) = Round((minValue +
  (Rnd() * ((maxValue * 0.12) -
  minValue))), 0)
End If
gen = arrayGen(0) & "/" & arrayGen(1) &
"/" & arrayGen(2) & "/" & arrayGen(3)
Assign in Cells(numRow, numColumn + 1) =
gen
Next i
Next c
End If
Call calCost(numGenes, fixedValue)
Call SelectionProcess(numGenes, pcSelection)
Call MCPProcess(numGenes, pcSelection, lvlMutation)
For i = 1 To numGenes
  numRow = numRow + 1
  With Sheets("GENERATIONS")
    Assign in .Cells(3, b + 1) = b & "a" & " " &
    "GENERATION"
    Assign in .Cells(numRow, b + 1) =
    Worksheets(1).Cells(numRow, numColumn + 6)
  End With
  If b unequal numGenerations Then
    Assign in Cells(numRow, numColumn + 1) =
    Cells(numRow, numColumn + 6)
  End If
Next i
Next b
Call dataPass
Next m
End Sub
```

Este tipo de algoritmo Metaheurístico utiliza varios elementos denominados operadores genéticos, los cuales se describen como:

- **Selección:** Michalewicz en [12] indica que, la selección hace una analogía entre la Evolución Biológica y los Algoritmos Genéticos, en él, cada solución representa un individuo con características propias y que es posible de evaluar, en donde sobreviven aquellos individuos mejor evaluados y pasarán a las siguientes generaciones creando una nueva descendencia más facultada.
- **Mutación:** Michalewicz en [12] indica que, la mutación es una operación cuyo objetivo es generar nueva información dentro de la población de soluciones para obtener una mejor exploración del espacio de búsqueda.
- **Mutación estándar:** en este caso Back en [13] considera que, dado un cromosoma, se altera el valor de cada gen con una probabilidad p_m , se denomina probabilidad de mutación
- **Cruce:** durante esta fase se cruzan o mezclan los individuos seleccionados en la fase anterior. Entre sus tipos se utilizará el cruce en un punto, donde se selecciona el punto de cruce aleatoriamente.
- **Aceptación:** Eiben en [13] indica que, después de realizar el cruce y la mutación de los individuos de la población llega el momento de decidir si aceptamos los hijos generados. La técnica más utilizada es la aceptación total de todos los hijos de la última generación.

La función objetivo evalúa el dominio de la solución cuando se utilizan Algoritmos Genéticos, en esta técnica existen algunos problemas comunes cuando se pretende minimizarla o maximizarla, y cómo un proceso basado en una mejora repetitiva puede ayudar

a acercarnos al objetivo o por lo menos a estar muy cerca. Dicha función de evaluación (fitness):

- Representa la función objetivo de nuestro problema de optimización.
- Asigna valores reales a cada genotipo.
- Se utiliza de base para realizar la selección
- Cuanto más discrimine, mejor (valores diferentes).
- Normalmente, pretenderemos maximizar el valor de fitness (aunque algunos problemas se plantean mejor como problemas de minimización y la conversión resulta trivial).

Caso de Estudio

Se tiene como objeto de estudio cuatro de las tarjetas prepagos que comercializa una distribuidora al por mayor y que, de acuerdo con su histórico de inventario desde el 2017 hasta junio del 2019 se evidencia que, al finalizar cada periodo mensual, en sus bodegas quedan una inmensa cantidad de productos en stock. Además, para el inicio del siguiente periodo recurren a comprar mucho más de los mismos productos, por lo que se asume que no existe ningún tipo de control sobre ese inventario.

Estos datos históricos serán la base para el proceso de simulación de las compras y ventas proyectadas para el 2020, es por ello por lo que se utiliza el modelo de Monte Carlo para la obtención de los datos que completarían el último año del histórico, correspondiente desde julio a diciembre del 2019. Este modelo se lo desarrolló dentro de VBA en Microsoft Excel 2013 y que responde al algoritmo 1.

Cevallos y Botto en [6] indica que para realizar la simulación de los datos de una muestra real se debe determinar el comportamiento que siguen dichos datos. Por lo cual en primera instancia se debe determinar que tipo de distribución siguen esos datos para luego realizar el proceso de simulación [19].

De tal manera que los datos obtenidos completan la muestra de los datos referentes a la sumatoria de las compras y ventas de los productos durante el periodo de tres años, como se muestra tabulado en la Tabla 1.

Tabla 1. Muestra total del inventario de productos desde Enero/2017 hasta Diciembre/2019.

	Año 2017		Año 2018		Año 2019	
Mes	Compras + Inv. Ini.	Ventas	Compras + Inv. Ini.	Ventas	Compras + Inv. Ini.	Ventas
Enero	217341	160160	180666	167038	188350	153426
Febrero	206181	133929	194628	154207	166424	156110
Marzo	263752	216367	257421	251471	188314	155565
Abril	315385	271941	232450	198182	158549	138704
Mayo	189944	148050	218268	180390	135645	95380
Junio	244894	139560	145878	96792	129865	84655
Julio	228334	153977	184586	130960	301810	260795
Agosto	248357	188139	205626	139549	299215	135551
Septiembre	224218	169929	199077	145810	207464	122936
Octubre	238289	195912	232267	193320	310728	263416
Noviembre	293377	231514	278447	212191	238712	161640
Diciembre	354363	252197	314256	251906	241572	150487

Para proyectar las estimaciones de las compras y ventas óptimos para el año 2020 se hace uso de una función objetivo que permita la minimización de costos al momento de realizar pedidos de los productos. Para ello se tiene en consideración que las ganancias obtenidas mediante la venta de tarjetas de la distribuidora son destinadas completamente al saldo del personal, este a su vez se distribuye en:

Tabla 2. Distribución del sueldo del personal de la distribuidora.

Personal	Sueldo (\$)
Asesores	8866
Supervisores	500
Diler	67.2
Jefe de ventas	1200
Movilización del sup-jefe	220
Total	10853.2

Además, se considera la Fig. 3 que detalla el porcentaje de gastos por compras de producto en el año 2017 y 2018, pudiendo constatar así que los productos Paq. \$1 y Paq. \$3 generan muchos más gastos, alrededor del 42%, en comparación con los otros dos productos que como máximo llegan al 12%. El costo total es representado por la fórmula 5.

$$CT = \text{sueldo del personal} + 0,98X_1 + 1,84X_2 + 2,76X_3 + 4,6X_4$$

Es así como se determina la función objetivo junto con sus restricciones en base a los datos anteriores. Quedando de la siguiente manera.

$$Z = 0,92X_1 + 1,84X_2 + 2,76X_3 + 4,6X_4$$

Restricciones:

$$0,92X_1 \leq 0,42CT$$

$$2,76X_3 \leq 0,42CT$$

$$1,84X_2 \leq 0,12CT$$

$$4,6X_4 \leq 0,12CT$$

$$X_1 + 2X_2 + 3X_3 + 5X_4 \geq CT$$

Donde X_n representa a los productos Paq. \$1, Paq. \$2, Paq. \$3 y Paq. \$5 respectivamente, multiplicado por su valor unitario. Y las restricciones se basan en el porcentaje máximo al que puede llegar cada producto de acuerdo con el costo total del pedido. Por último, se utilizó la herramienta Solver de la hoja de Excel para determinar la eficacia de la función objetivo, dando como resultado la Fig. 3

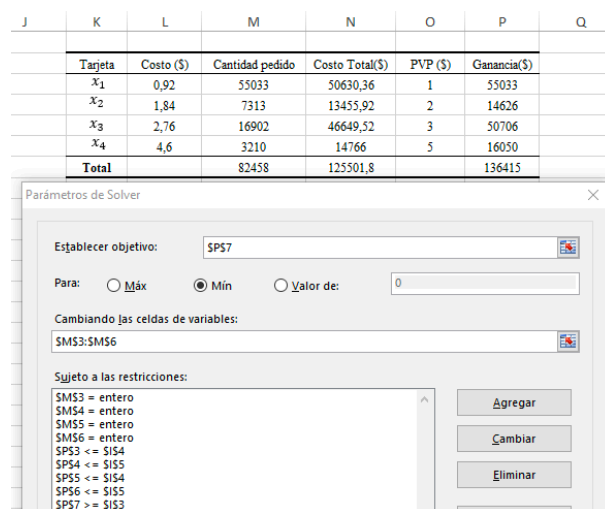


Figura 3. Solución de Solver hacia la función objetivo planteada y sus restricciones.

Para realizar las simulaciones del periodo 2020 se utiliza el Algoritmo Metaheurístico Genético, implementando la función objetivo y sus restricciones para la aceptación de las soluciones más óptimas en cuanto a estimaciones de pedidos y ventas con la

intención de minimizar los costos por la adquisición de los productos, su algoritmo es el I y el diagrama se presenta en la Fig. 4.

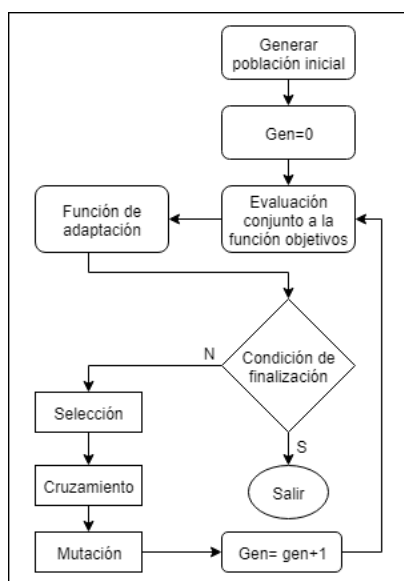


Figura 4. Diagrama del Algoritmo Genético utilizado en este estudio.

Resultados y Discusión

A partir del histórico de datos reales se determinan los parámetros necesarios que se utilizaron en el sistema de Simulación Metaheurístico desarrollado en el presente proyecto, que permite obtener las compras óptimas del periodo 2020 para la optimización del inventario. Por aquello, se pudo evidenciar que con el uso del modelo presentado como solución existe un aproximado del 10% de minimización de los gastos por concepto de la compra de tarjetas en comparación a los gastos generados durante los periodos que van del 2017 al 2019.

Tabla 3. Tabla de compras estimadas para el periodo 2020 mediante el modelo de Simulación Metaheurístico.

Compras 2020				
Meses	Paq. \$1	Paq. \$2	Paq. \$3	Paq. \$5
Enero	71895	12532	77096	1866
Febrero	72313	10193	25135	9161
Marzo	64124	10573	78401	6052
Abril	94288	6763	61318	4150
Mayo	52630	3141	69718	6692
Junio	71086	7186	74488	5054
Julio	90606	5781	52801	13236
Agosto	73378	11774	51734	18840
Septiembre	62212	4103	54635	4980
Octubre	86237	9393	82526	6353
Noviembre	53981	7304	49947	3097
Diciembre	46947	6822	73154	4893

De manera detallada, el proceso de simulación se llevó a cabo utilizando los valores máximos y mínimos de las compras en los periodos anteriores, permitiendo que los valores estimados sean muy cercanos a los reales, por tanto, el comportamiento de las compras no sufrió ningún tipo de alteración a considerar durante su simulación, lo que hace a los datos confiables para su utilización.

Los datos presentados en la tabla 3, son resultado de varios procesos de simulación donde se visualizó como cambiaban su comportamiento en cada iteración, sobresaliendo la característica principal de los modelos Metaheurístico, el aprendizaje automático, donde se van descartando las respuestas más alejadas a la función de minimización.

Conclusiones

La presente investigación tuvo como objeto de estudio un centro de distribución de varios productos, entre ellos las tarjetas de recarga de saldo para móviles, los cuales representan una gran demanda de usuarios en sus diferentes denominaciones, lo que exige un correcto control de inventario sobre ellos para evitar quedarse sin stock o más aún, analizar el comportamiento de las ventas para no llegar a tener muchos de esos productos en inventario.

Por ello se tuvo acceso al inventario que va desde enero del año 2017 hasta junio del 2019 para el análisis de la forma en que se controla actualmente el inventario de dichos productos, con aquello se define el comportamiento de los datos haciendo uso de Stat::Fit con el fin de obtener la distribución de probabilidad para la simulación de las ventas y compras en los últimos 6 meses del 2019 mediante el método de Simulación Monte Carlo. De tal forma que se completaría la muestra correspondiente a tres periodos anuales. Luego se desarrolló el modelo de simulación Metaheurístico basado en el Algoritmo Genético por el cual se estimaron las compras del siguiente año para conocer los posibles gastos futuros.

El modelo de simulación desarrollado en la presente investigación tiene como principal característica la ventaja de que combina diferentes conceptos derivados de la inteligencia artificial, la evolución biológica y los mecanismos estadísticos. Todos ellos relacionados por su objetivo de simular el comportamiento real en las máquinas para la solución de una amplia gama de problemas debido a su flexibilidad y con resultados óptimos.

Como trabajo futuro se recomienda analizar las estacionalidades que se pueden dar durante los periodos de venta, debido al impacto que puede llegar a tener con los resultados obtenidos. Además, se propone llevar el modelo presentado hacia uno Híbrido para considerar los métodos de investigación cualitativos permitiendo profundizar más sobre el tema y determinar resultados más precisos.

Referencias Bibliográficas

- [1] Arias, S.; Londoño, M.: Algoritmos Genéticos: Una solución alternativa para optimizar el modelo de inventario (Q,r), Medellín. Accedido en 2009.
- [2] Montenegro, L.: Diseño e implementación de un sistema de inventarios, aplicando simulación Monte Carlo, en una empresa de servicios petroleros. Quito, Ecuador. Accedido en febrero del 2011.
- [3] Izar J.; Ynzunza: «Método Híbrido de Inventario con Tiempo de Entrega Aleatorio», Conciencia Tecnológica, n° 48, pp. 12-16, 2014.

- [4] Azofeifa y Carlos E.: «Aplicación de la simulación Monte Carlo en el cálculo de riesgo usando Excel.» Tecnología en Marcha, vol. 17, n° 1, p. 13.
- [5] Guamantica, V.: "Diseño del modelo de cantidad económica de pedido (EOQ) del inventario de la empresa general motores del Ecuador". Quito. Accedido en 2013.
- [6] Cevallos-Torres, Lorenzo, & Botto-Tobar, Miguel, "Case Study: Probabilistic Estimates in the Application of Inventory Models for Perishable Products in SMEs," in Problem-Based Learning: A Didactic Strategy in the Teaching of System Simulation, Guayaquil, Springer, 2019, p. 144.
- [7] Causado, E.: Modelo de inventarios para control económico de pedidos en empresa comercializadora de alimentos. Medellín. Accedido en 2015.
- [8] González, J.: Introducción del Factor Humano al Análisis de Riesgo. Barcelona, España. Accedido en 2015.
- [9] Tamborero, J., Cejalvo, A.: NTP 418: Fiabilidad: la distribución lognormal. España. Accedido en 1999.
- [10] Gestal, M., River, D., Rabuñal, J., Dorado, J.: Introducción a los Algoritmos Genéticos y la Programación Genética. Coruña, 2010.
- [11] Cuesta, Y.: Solver en Excel. Accedido el 17 de febrero del 2017.
- [12] Z. Michalewicz, Genetic Algorithms + Data Structures = Evolution Programs. Springer Verlag, 1996.
- [13] T. Back, D.B. Fogel, Z. Michalewicz, Handbook of Evolutionary Computation, Institute of Physics Publishers, 1997.
- [14] Lorenzo Cevallos-Torres, Miguel Botto-Tobar. " Case Study: Project-Based Learning to Evaluate Probability Distributions in Medical Area" *Problem-Based Learning: A Didactic Strategy in the Teaching of System Simulation*. Springer, pp.113., 2019.
- [15] J. I. Córdoba García. "Propuesta de un sistema de gestión de inventarios de producto terminado para la empresa Alimentos Exquisitos de la ciudad de Palmira, Valle Del Cauca". 11 Enero 2016.