



Universidad Popular Autónoma del Estado de Puebla

Centro Interdisciplinario de Posgrados

Investigación y Consultoría

Doctorado en Logística y Dirección de la Cadena de Suministro

Determinación óptima de centros de distribución en cadenas de suministro
aplicando modelos evolutivos.

Tesis para obtener el grado de Doctor en

Logística y Dirección de la Cadena de Suministro

Presenta

Héctor Domínguez Martínez

Director de Tesis

PhD. Carlos Alberto Reyes García

Puebla, México

Septiembre 2013



UPAEP – Secretaría General

Dirección General de Apoyos Académicos

Dirección del Centro de Recursos para el Aprendizaje y la Investigación.

Biblioteca Central - **Karol Wojtyla**

Tesis Digitales Restricciones de uso:


DERECHOS RESERVADOS ©

PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de textos, imágenes, gráficas, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente de donde la obtuvo mencionando el autor o autores involucrados en el documento.

Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



Universidad Popular Autónoma del Estado de Puebla

Centro Interdisciplinario de Posgrados

Investigación y Consultoría

Departamento de Ingeniería

Doctorado en Logística y Dirección de la Cadena de
Suministro

Por este medio nos permitimos informar a Uds. la aprobación de la Tesis:
**“Determinación Óptima de Centros de Distribución en Cadenas de
Suministro aplicando Modelos Evolutivos”**, que presenta el alumno:
Héctor Domínguez Martínez como requisito para obtener el Grado de
Doctorado en este programa académico.

Atte.

Comité Doctoral



Dr. Carlos Alberto Reyes García
Director de Tesis



Dr. José Federico Ramírez Cruz
Asesor



Dr. José Luis Martínez Flores
Asesor

Puebla, México.

Septiembre del 2013

DEDICATORIA:

A Rocío Terrazas Herrera, mi esposa por soportar mi carácter todos estos años de estudio, ya que sin su apoyo y comprensión no podría haberlos habrí concluido satisfactoriamente.

A mi hijo Héctor, que es la razón de mi existencia y mi impulso para salir adelante.

A Eufemia, mi madre (q.e.p.d.) que me enseñó los caminos correctos de la vida y que al final cumplí como ella hubiera querido ver.

AGRADECIMIENTOS:

Al Dr. CARLOS ALBERTO REYES GARCÍA amigo entrañable y además mi director de Tesis.

A mis maestros, en especial a mi asesor de tesis Dr. JOSÉ LUIS MARTÍNEZ FLORES por sus consejos y dedicación al trabajo.

Al Dr. FEDERICO RAMÍREZ CRUZ asesor de mi trabajo profesional además de ser compañero y amigo.

INDICE GENERAL

CAPITULO 1. Introducción.....	1
1.1. Antecedentes.....	1
1.2. Problema de investigación.....	4
1.3. Justificación.....	5
1.4. Objetivos de investigación.....	6
1.4.1. Objetivo general.....	6
1.4.2. Objetivos específicos.....	6
1.5. Preguntas de investigación.....	7
1.6. Alcances y limitaciones.....	7
1.6.1. Alcances.....	6
1.6.2. Limitaciones.....	6
CAPITULO 2. Marco Teórico.....	8
2.1 Centro de Distribución.....	8
2.1.1. Cadena de suministro.....	8
2.1.2. Reducción de costos de transporte.....	9
2.2. Criterios que influyen en la decisión de ubicación de instalaciones.....	10
2.3. Modelos de localización.....	10
2.3.1. Clasificación de problemas de localización.....	10
2.3.2. Modelos determinísticos básicos.....	10
2.4. Modelos estocásticos.....	13
2.5. Modelos evolutivos.....	14
2.5.1 Programación evolutiva.....	14
2.5.2 Estrategias evolutivas.....	15
2.5.3 Algoritmos genéticos.....	16
2.5.4 Programación genética.....	18
2.5.5 Evolución diferencial.....	20
2.6. Ejercicio de aplicación de algoritmo genético.....	21
CAPITULO 3. Metodología.....	24
3.1 Alcance y enfoque de la investigación.....	24
3.2 Descripción del objeto en estudio.....	25
CAPITULO 4. Experimentación.....	28

4.1 Descripción del experimento 1	28
4.1.1 Aplicación del método propuesto del experimento 1	30
4.1.2 Aplicación de los parámetros utilizados en el experimento 1	31
4.2 Descripción del experimento 2	33
4.2.1 Proceso de solución propuesto del experimento 2	35
4.2.2 Resultados del experimento 2	37
4.3 Descripción del experimento 3	38
4.3.1 Aplicación del método propuesto del experimento 3	42
CAPITULO 5 Análisis de resultados	45
CAPITULO 6 Conclusiones recomendaciones y trabajo futuro	47
Referencias	49
Anexo 1	52
Anexo 2	53
Anexo 3	56
Anexo 4	57
Anexo 5	59
Anexo 6	60
Anexo 7	61

INDICE DE FIGURAS

Figura 2.1 Clasificación de los problemas de localización de diversos puntos de vista.	11
Figura 2.2 Ejemplo de la codificación (mediante cadenas binarias usada tradicionalmente con algoritmos genéticos).....	17
Figura 2.3 Representación de diagrama de árbol de P.G.....	18
Figura 2.4 Representación típica de cruce en P.G.....	19
Figura 2.5 Cadena representativa de un cromosoma de optimización.....	22
Figura 2.6 Uso de 2 puntos de cruce entre 2 individuos.....	23
Figura 3.1 Ejemplo de codificación usada tradicionalmente en algoritmos genéticos...	24
Figura 3.2 Cadena de cuatro bits del experimento 1 para determinar el origen uno.....	25
Figura 3.3 Cadena de cuatro bits del experimento 1 para determinar el origen dos.....	25
Figura 3.4 Cadena de 12 bits para determinar los destinos del experimento 1.....	26
Figura 3.5 Cadena de 12 bits para determinar los orígenes del experimento 2.....	26
Figura 3.6 Cadena de 12 bits para determinar los destinos del experimento 2.....	26
Figura 3.7 Matriz de 6x4 del experimento 3.....	27
Figura 3.8 Ejemplo de cromosoma de 24 bits codificado del experimento 3.....	27
Figura 4.1 Cromosoma de 24 bit.....	30
Figura 4.2 Solución experimento 1 de cromosoma codificado.....	31
Figura 4.3 Gráfica de mejores soluciones por generación del experimento 1.....	32
Figura 4.4 Gráfica de mejores soluciones encontradas por cada una de las 10 ejecuciones del algoritmo genético del experimento 1.....	32
Figura 4.5. Cromosoma de 24 bits del experimento 2.....	36
Figura 4.6. Cromosoma resultante del experimento 2.....	36
Figura 4.7 Gráfica de mejores soluciones por generación para los mejores resultados encontrados en experimento 2.....	37
Figura 4.8 Gráfica de las mejores soluciones encontradas para cada una de las 10 ejecuciones del algoritmo genético del experimento 2.....	38
Figure 4.9 Costos variables de instalación.....	40
Figura 4.10 Cromosoma de 24 bits del experimento 3.....	43
Figura. 4.11 Solución del experimento No.3 ya codificado.....	43

INDICE DE TABLAS

Tabla 2.1 Datos obtenidos con la investigación de mercado en cada una de las regiones	22
Tabla 4.1 Distancia (en millas) entre terminales en el experimento 1(parte 1).....	29
Tabla 4.2 Distancia (en millas) entre terminales en el experimento 1(parte II).....	30
Tabla 4.3 Distancias (en kilómetros) entre plantas de producción potenciales y mercados en el problema de Goutte.....	33
Tabla 4.4. Costos de operación de planta (en dólares canadienses por año) y capacidad (en hectolitros -100 litros- por año) en el problema Goutte.....	34
Tabla 4.5. Demanda (en hectolitros por año) de las ventas distritales en el problema Goutte.....	34
Tabla 4.6. Costos de transportación (en dólares canadienses por año) c_{ij} , $i \in V_1$, $j \in V_2$, en el problema Goutte.....	35
Tabla 4.7. Entradas de demanda (en cientos de kilogramos por año) contra costos variables de instalación (en dólares) como reportan los históricos en problema Logconsult.....	39
Tabla 4.8 Distancias (en millas) entre las localizaciones potenciales y los distritos de venta en el problema Logconsult.....	42
Tabla 4.9 Costo anual (en dólares) $t_{i,j}$, $i \in V_1$, $j \in V_2$, en el problema Logconsult.....	42
Tabla 4.10 Fracción de demanda anual de las ventas del distrito $j \in V_2$, satisfechas por la instalación $i \in V_1$, en el problema Logconsult.....	42

RESUMEN

En este trabajo de investigación se propone utilizar los Modelos Evolutivos, en particular los Algoritmos Genéticos como un medio para determinar centros de distribución en la cadena de suministro. El Modelo propuesto es una alternativa más para buscar una solución muy cercana a la óptima, el cual está dirigido a formular una serie de propuestas y metodologías diferentes a los métodos tradicionales. Se determinara la ubicación de centros de distribución en diferentes escenarios y permitiendo así la optimización de cromosomas que nos lleven a determinar un algoritmo genético que nos proporcione una solución cercana a la óptima.

Se formulan tres experimentos tomados de -Gianpaolo Ghiani, Gilbert Laporte and Roberto Musmanno .*Introduction to Logistics: Systems Planning and Control*, John Wiley and Sons 2004 pp.81-90. Los cuales son resueltos por medio de AG's. Debido a que los Modelos Evolutivos son inspirados biológicamente en la evolución de los seres vivos según la teoría de Darwin de la evolución natural, se requieren programas computacionales cuyo fin es el de imitar el proceso de selección natural que rige el curso de la evolución. Para poder simular el proceso evolutivo en una computadora se requiere codificar las estructuras que se replicarán, operaciones que afecten a los individuos, una función de aptitud y un mecanismo de selección. El software utilizado para resolver los experimentos fue MATLAB 7.6 V 2.8. Los resultados obtenidos en los tres experimentos fueron muy cercanos al óptimo, lo cual nos indica que los AG's son una buena alternativa para buscar el óptimo en este tipo de problemas.

CAPITULO 1. Introducción

1.1. Antecedentes

Los problemas de localización parten de la necesidad de encontrar centros de distribución más convenientes para ubicar instalaciones como: una planta de producción, un centro de distribución o almacenes comerciales y/o de servicios, un tiradero de basura, una estación de bomberos, una estación de policía y tránsito e inclusive una tienda de abarrotes. Entonces cómo saber que el Centro de Distribución (CD), que se pretende poner esté en el lugar adecuado, donde tanto el cliente como el distribuidor tengan las mejores ventajas logísticas, determinando que éste sea el más cercano al óptimo, y donde se puedan minimizar los costos en general. Y entonces caben las siguientes interrogantes:

1. ¿Cuál es el número mínimo necesario de instalaciones que se deben utilizar para optimizar la distribución de productos?
2. ¿La ubicación del CD es la idónea o dónde se requiere ubicarlas de manera que los costos sean mínimos?
3. ¿Cuál debe ser el tamaño de los CD de manera que se optimicen todos los espacios posibles?
4. ¿Cuáles son los clientes que debe atender cada instalación y cuántos deben ser para minimizar los tiempos totales de entrega?
5. ¿Qué métodos se deben utilizar para tener la certeza de que los centros de distribución determinados sean lo más cercano a lo óptimo posible?

A partir de la década de los años 70, los problemas de localización se han estudiado de forma continua por investigadores de diversas áreas; Albernathy & Hersey (1972) realizaron la investigación sobre localización de centros regionales de salud, Gleason (1975) hizo investigaciones sobre paraderos o estaciones de autobús, Moore & ReVelle(1982) lo hicieron sobre centros de emergencia, Cohon et al.,(1980) realizaron investigaciones sobre plantas de generación de energía eléctrica, Birge & Malyshko(1985) realizaron investigaciones sobre la ubicación de terminales de camiones, Flynn & Ratick(1988) aportaron su investigación sobre servicios aéreos, Dezner(1988) realizó su trabajo sobre orbitas satelitales, Hogan (1990) lo realizó sobre pluviómetros, Hodgson et al.,(1996) investigó sobre estaciones de inspección de vehículos, Cho & Sarrafzahed(1994) realizó su investigación sobre plantas de manufactura de procesadores, y también Higgins et al., sobre estacionamientos de vagones de carga(Current 2002). Los modelos básicos más nombrados en la literatura de localización son citados por

(Current, 2002.), donde el objetivo principal de todos los modelos es localizar nuevas Instalaciones para optimizar algún objetivo particular.

En cuanto a los algoritmos de solución de P- medianas Alba& Domínguez (2006) dice que los enfoques clásicos que existen para solucionar estos tipos de problemas son la relajación Lagrangeana usando Ramificación y acotamiento (Branch and Bound), búsqueda local y método Tabú. Existen algoritmos de solución que van desde la búsqueda del óptimo haciendo simplificaciones del modelo como es el caso de COBRA, propuesto por Church(2003)- , hasta la aplicación de meta-heurísticas como algoritmos genéticos, recocido simulado, herramientas de clustering, etc., todos estos algoritmos van sobre la búsqueda del óptimo.

En cuanto a modelos de localización de sistemas de producción-distribución existe una amplia literatura, Smith (2001) en su artículo realiza una clasificación de los modelos teniendo en cuenta 15 criterios establecidos anteriormente por Aikens (1985) y Vidal y Goetschalckx (1996) quienes resumen los diferentes modelos de producción y distribución realizados hasta esa fecha, haciendo énfasis en la parte global de la cadena de abastecimiento (Vidal & Goetschalckx, 1997). Zhi-Long Chen (2001) realiza otra clasificación basada en el nivel de decisión, estructura y parámetros de los modelos existentes (Chen, 2004). Dentro de este contexto, puede verse que casi todos los modelos son formulados con Programación Mixta Entera (MIP) y debido a que las formas exactas para resolver este tipo de problemas en tamaños medianos requieren de grandes esfuerzos computacionales, las aproximaciones heurísticas son usadas para resolver los problemas reales. Las principales técnicas utilizadas son modelos de descomposición, jerarquización, relajación Lagrangeana, ramificación y acotamiento y algunas meta-heurísticas como: recocido simulado y algoritmos genéticos. (Pirkul & Jayaraman, 1998). Hindi y Basta en 1994 utilizaron la técnica de ramificación y acotamiento para trabajar el mismo modelo de Geoffrion & Graves, añadiendo la restricción de capacidad limitada, calculando los límites inferiores a través de transformaciones estructuradas (Hindi & Basta, 1994). Jayaraman y Ross,(2003) utilizan la meta-heurística de recocido simulado, describen un modelo llamado PLOT, para el diseño de sistemas de distribución, caracterizado por múltiples productos, una planta central, múltiples centros de distribución y centros de crossdocking, con el objetivo de determinar la mejor configuración de la red de centros de distribución y crossdocking y la cantidad de productos transportados, ellos compararon los resultados obtenidos con los óptimos(utilizando LINGO) y encontraron diferencias menores al 4%; sin embargo, el tiempo de solución oscilaba entre 300 y 400 veces menos.

Jang Chang y Park (2002) utilizan la meta-heurística de algoritmos genéticos para el diseño de una red de producción/distribución el cual es dividido en 4 módulos (abastecimiento, planeación de la producción y distribución de materiales de proveedores a clientes, administración y manejo de datos). El primer módulo fue resuelto con una heurística utilizando relajación Lagrangeana y el segundo módulo, debido a que la planeación de las actividades ocurre frecuentemente y el tiempo de toma de decisiones es corto, utilizó

algoritmos genéticos lo que permite generar buenas soluciones teniendo en cuenta la calidad y el tiempo.

Gen y Syarifm (2005) estudian la integración más eficiente del sistema de producción, distribución e inventarios para múltiples productos y en múltiples periodos de tiempo, utilizando esta técnica junto con controladores de lógica difusa (Fuzzy Logic Controller) los cuales ayudan a auto-regular los parámetros necesarios para implementar Algoritmos Genéticos(GA). Los autores comparan los resultados obtenidos con el GA estándar y el GA con FCL, mostrando mayor eficiencia en el segundo método.

1.2. Problema de investigación

La determinación de un centro de distribución, es una decisión muy importante que se debe hacer estratégicamente, ya que ésta debe satisfacer algunos criterios de costo-beneficio si se quiere permanecer en el mercado competitivo, y esto va a depender del éxito o fracaso de los objetivos que la empresa haya trazado. Se deben tomar en cuenta situaciones como políticas gubernamentales, condiciones económicas, aspectos sociales, e inclusive ecológicos que no afecten el entorno de la región y justificar su determinación del centro de distribución.

Es necesario que se examinen a fondo este tipo de decisiones y es imprescindible que se determinen todos los factores que van a influir en la operación técnica y económica del centro de distribución, e igual de importante es analizar el ciclo de vida y sus objetivos para garantizar la inversión de la misma.

Para determinar la ubicación de un centro de distribución, lo primero que se analizará es que se tenga la infraestructura requerida para su funcionamiento y una red de comunicaciones para que la transportación de los materiales sea fluida desde una planta de producción hasta los posibles mercados o centros de distribución.

De igual manera se debe tomar en cuenta el tipo de planta que se va ubicar, si es altamente contaminante o que represente un riesgo para la salud de los habitantes de poblaciones cercanas.

En esta tesis se propone utilizar los modelos evolutivos, en especial los algoritmos genéticos para optimizar la ubicación y determinación de los centros de distribución.

1.3. Justificación de la investigación

Se examinará el beneficio de aplicar los métodos evolutivos en la determinación de los centros de distribución. En este proyecto de investigación se pretende proponer un modelo diferente a los que ya se conocen por los métodos tradicionales, esto con el fin de poder determinar el número óptimo de uno o varios centros de distribución en la cadena de suministro.

La propuesta es aplicar los Métodos Evolutivos, utilizando solamente **los algoritmos genéticos**. Estos nos llevarán a determinar de una manera óptima y efectiva un centro de distribución, y así de ésta forma tendremos una metodología alterna en la parte de los sistemas logísticos para llegar a obtener una solución cercana a la óptima, y de esta forma compararla con los métodos tradicionales ya conocidos y demostrar su aplicación en la parte de optimización de la cadena de suministro ya que a la fecha no se ha explotado como debiera ser. Los modelos evolutivos tienen ciertas ventajas con respecto a otras técnicas de búsqueda los cuales se mencionan a continuación:

- a) No necesitan conocimientos específicos sobre el problema que intentan resolver.
- b) Operan de forma simultánea con varias soluciones, en vez de trabajar de forma secuencial como las técnicas tradicionales.
- c) Al utilizarlos en problemas de optimización resultan menos afectados por los máximos locales (falsas soluciones) que las tradicionales.
- d) Usan operadores probabilísticos en vez de los típicos operadores determinísticos de las otras técnicas.

El presente trabajo está dirigido a formular una serie de propuestas y metodologías diferentes a los métodos tradicionales, la cual permita la optimización de cromosomas que nos lleven a determinar un algoritmo genético el cual aplicándolo en problemas para la determinación de centros de distribución nos dé una solución cercana a la óptima utilizando para ello los parámetros que requiere el algoritmo.

1.4. Objetivos de la investigación

1.4.1. Objetivo General.

Proponer un modelo evolutivo (algoritmo genético) en la determinación y ubicación de un centro de distribución en la cadena de suministro, y de esta manera aplicarlo en diferentes escenarios con el fin de determinar el número óptimo de centros de distribución, y mejorar o cambiar su ubicación para maximizar la operatividad de la cadena de suministros de forma dinámica.

1.4.2. Objetivos Específicos.

- Describir el problema de la cadena de suministro a solucionar.
- Establecer las variables y los parámetros tanto de entrada como de salida.
- Identificar las restricciones que intervienen para el logro de las metas.
- Identificar metas y soluciones deseadas.
- Desarrollar la codificación que represente las soluciones potenciales
- Desarrollar la(s) función(es) de aptitud más adecuada(s).
- Seleccionar las metodologías evolutivas más acordes al problema.
- Obtener los resultados de los métodos seleccionados y adoptar los más convenientes.

1.5. Preguntas de investigación.

- ¿Qué tan confiable es el sistema logístico que utilizamos actualmente?
- ¿Qué otros métodos alternativos existen para encontrar soluciones óptimas?
- ¿Al tratar de determinar un centro de distribución por métodos evolutivos, cómo podemos asegurar que nos ofrece la mejor ubicación para maximizar la cadena de suministro?
- ¿Qué herramientas computacionales están disponibles para la solución de los problemas planteados?
- ¿Cómo obtener mejores alternativas de localización de un CD con los métodos evolutivos que con los tradicionales?
- ¿Cómo afirmar que el método de solución que se propone nos lleva a obtener soluciones de calidad, óptimos locales y globales?

1.6. Alcances y limitaciones

1.6.1. Alcances

- Desarrollar la metodología que nos permita resultados lo más cercano a la optimización de un centro de distribución.
- Obtener soluciones buenas, casi óptimas a un costo de recursos razonable aunque sin garantizar optimalidad de las mismas.
- Desarrollar soluciones con solo dos métodos diferentes con fines de comparación.
- Proponer y resolver un modelo evolutivo para determinar la ubicación de un centro de distribución en la cadena de suministro muy cercano al óptimo.
- Se exploraran espacios bien delimitados que aseguren que se puede encontrar una solución adecuada y aceptable.

1.6.2. Limitaciones

- Los algoritmos genéticos no aseguran una solución óptima aunque son métodos de búsqueda que tratan de acercarse al óptimo a lo largo de todas las generaciones.
- Su optimización dependerá de la calidad y cantidad de la información proporcionada.

CAPITULO 2. Marco Teórico

2.1. Centro de distribución.

El estudio de la teoría de localización formalmente inicio en el año 1909 en el que Alfred Weber planteo el localizar un único almacén, esto con el fin de minimizar la distancia total entre el almacén y varios clientes. A partir de ahí la teoría de localización se impulsó con pocas aplicaciones, y no fue sino que hasta que Hakimi (1964) en una publicación gano el interés de los investigadores. Esta teoría se remonta a un estudio analítico en que Pierre de Fermat y Batista Cavallieri, proponen cada uno en forma independiente el problema básico de la media espacial Euclidiana a inicios del siglo XVII.

La teoría de localización dedica sus estudios a los modelos, algoritmos y técnicas para elegir la localización de instalaciones bajo ciertas restricciones (Sinha, 2004), para obtener la máxima rentabilidad de sus operaciones ante cualquier tipo de inversión y a la vez que cumpla con los objetivos de la empresa.

Un centro de distribución es una infraestructura logística en la cual se almacenan productos, y se embarcan órdenes de salida para su distribución al comercio minorista o mayorista. Generalmente se constituye por uno o varios almacenes, en los cuales ocasionalmente se cuenta con sistemas de refrigeración o aire acondicionado, áreas para organizar la mercancía y compuertas, rampas u otras infraestructuras para cargar los vehículos. La implementación de centros de distribución dentro de la cadena de suministro surge de la necesidad de lograr una distribución más eficiente, flexible y dinámica, es decir asegurar una capacidad de respuesta rápida al cliente, de cara a una demanda cada vez más especializada. La implementación también ofrece una reducción de costos en las empresas y evita cuellos de botella.

2.1.1. Cadena de suministro.

La Gestión de la cadena de suministro (GCS) y la Gestión Logística en particular se han convertido en un factor relevante en la consecución de la ventaja competitiva de la empresa (Kant et al.1994). El propio proceso de globalización ha traído consigo una mayor dispersión de la cadena de suministro y de los clientes finales, lo que ha afectado de forma directa al diseño logístico. También y no menos importante las nuevas tecnologías de la información han hecho emerger determinados ámbitos específicos donde el papel de la función logística es determinante. Refiriéndonos al denominado E-business (Ellinger, et al. 2003), así como la consolidación de los sistemas flexibles de producción del tipo Lean Production (Claycomb et al 1999).

Algunos autores amplían el ámbito tradicional de la gestión logística, entendiéndola como la gestión del flujo de materiales a través de los diferentes eslabones de la cadena de suministro (lo que denominan logística integral) e incluso llegan a equipararla con el concepto de gestión de cadena de suministro. Handfield y Nichols (2002) definen la cadena de suministro como aquella que incluye todas las actividades asociadas con el flujo y la transformación de bienes desde la fase de las materias primas hasta el consumidor final, así como la información incluida en todo el proceso. Según el Council of Supply Chain Management Professionals, la

gestión logística es una parte de la cadena de suministro que tiene como objetivo la planificación, la implementación y control eficiente y efectivo del flujo directo e inverso y almacenamiento de bienes, servicios e información relacionada, desde el origen al cliente, y con el fin de satisfacer sus necesidades. En contra de lo que sugieren las reflexiones, hasta muy recientemente, ni el campo académico ni en el aplicado, se han valorado suficientemente las implicaciones estratégicas de las actividades logísticas (Stock, 2002). Pueden mencionarse sin embargo algunas excepciones en los trabajos de Porter (1980, 1985) y su concepto de cadena de valor y otros como los de Heskett (1973), Shapiro (1984) o Sharman (1984), que han servido para atraer la atención sobre el valor de la logística en la planificación y dirección estratégica (Kant et al 1994) y en general han ayudado a la difusión de la logística dentro de los ámbitos de la estrategia empresarial.

La Gestión Logística y la Gestión de la Cadena de Suministro en general han acaparado buena atención por parte de los investigadores (Alfaro et al 2002; Nof 1999 St.John et al 2001).

En definitiva la gestión logística ha de entenderse como una parte esencial de la gestión corporativa y una actividad que puede, más allá de reducir costos de producción, estar en la base de la ventaja competitiva sostenible de la empresa (Kant et al 1994). Así entonces la gestión logística puede conceptualizarse como un recurso estratégico esencial de la estrategia corporativa.

El factor más relevante a la hora del diseño de las redes de distribución, es el exigente y creciente nivel de servicio al cliente, lo cual es lógico y coincide con los conceptos teóricos de la relación del costo operativo y el nivel de servicio deseado por el mercado.

2.1.2. Reducción de costos de transporte.

Dentro del costo total de la logística integral aproximadamente el 50% es adjudicado al costo de transporte. Por eso vale la pena examinar la potencialidad de su reducción, enfocándose a la eliminación de deficiencias. Algunas causas de incrementos de los costos de transporte son los siguientes:

- Ordenes de carga incompletas
- Llegadas tarde del transporte
- Documentación incompleta o atrasada
- Transporte sobredimensionado
- Pérdida de la conexión con avión o barco
- Descarga en tiempo excesivo
- Ordenes retenidas por restricciones en la capacidad del transporte
- Reducción de inventarios

Existe un consenso tácito generalizado que dependiendo del tipo de productos, entre el 60 y el 80% del costo total de mantención del inventario está constituido por el costo de oportunidad del capital invertido. El porcentaje restante está conformado por los costos de espacio, mermas, seguros, infraestructura y personal asociados al inventario (Flores Urquiza) 2003.

2.2 Criterios que influyen en la decisión de ubicación de instalaciones

Según Chase, Jacobs y Aquilano (2005), las decisiones de localización se guían por una variedad de criterios imperativos de competitividad algunos de ellos son los siguientes:

- **Costo total.** Seleccionar el lugar con el costo total mínimo, incluyendo los costos regionales, costos de insumos, costos de distribución, costos de adquisición del inmueble, construcción, mano de obra, impuestos y costos de energía, incluyendo algunos costos ocultos difíciles de medir.
- **Infraestructura.** Este punto es vital ya que involucra las vías de comunicación para fácil acceso a la empresa.
- **Proximidad de los clientes.** La disminución de los costos de transporte ayuda a garantizar que las necesidades de los clientes se incorporen al desarrollo y construcción de los productos.
- **Proveedores.** La cercanía de las plantas de los proveedores competitivos y de alta calidad hacen que un lugar determinado sea adecuado, ya que también soporta métodos de producción lean
- **Otras instalaciones.** La ubicación de otras plantas o centros de distribución de la misma compañía influyen grandemente en la ubicación de una nueva red.
- **Barreras gubernamentales.** Las barreras legislativas deben ser consideradas en el plan de ubicación.
- **Ventaja competitiva.** Esta se da cuando se estimula la innovación, el desarrollo tecnológico y se proporciona un mejor ambiente para la competitividad global

2.3. Modelos de localización de instalaciones.

2.3.1. Clasificación de los problemas de localización.

De acuerdo con Valhonrat *et al.* (1991), ya que esto es un problema complejo, admite clasificaciones diversas, según el punto de vista que se adopte (figura 2.1)

2.3.2. Modelos determinísticos básicos.

- **Problema de localización de cobertura (set covering).** Es propuesto por Toregas en 1971, su objetivo es localizar el mínimo número de instalaciones requeridas para cubrir todos los nodos de demanda. El objetivo se generaliza al incluir costos del sitio específico como coeficientes de las variables de decisión. Las versiones son NP-hard (Current et al. 2004).
- **Problema de localización de máxima cobertura (maximal covering location problem MCLP).** Este problema fue propuesto por Church y Reville en 1974 (citado en Current et al. 2004) se formuló para hacer frente a las situaciones de planificación que tienen un límite en el número de instalaciones a ubicar. Su objetivo es localizar un número predeterminado de instalaciones p , de tal manera que se maximice la demanda cubierta.

Clasificaciones de los problemas de localización
Manufactura / Servicio Espacio continuo / Discreto Una / Múltiples instalaciones Sin / Con interacción Determinísticos / Estocásticos Deseables / Indeseables Según la estructura de las comunicaciones Distancia rectangular / Euclidiana / ... ¹

Figura 2.1. Clasificación de los problemas de localización desde diversos puntos de vista.

Fuente: Obtenida a partir de Vallhonrat *et al.* (1991)

- **Problema de localización p-centro (p- center location problem).** Este problema fue propuesto por Hakimi en 1964 (citado en Current et al. 2004), aborda el problema de reducir al mínimo la distancia máxima que es demandada desde su instalación más cercana dado que estamos ubicando un número determinado de instalaciones.
- **Problema p-dispersión (p-dispersion problem PDP).** Este problema fue propuesto por Kuby en 1987 (Citado en Current et al. 2004), solo considera la distancias entre las nuevas instalaciones y su objetivo es minimizar la distancia entre un par de instalaciones.
- **Problema de localización con cargo fijo (fixed charge location problem FCLP).** Es una relajación del problema p-mediana cuyo objetivo es minimizar las instalaciones totales y los costos de transporte. Esto determina el número óptimo y la localización de las instalaciones así como las asignaciones de la demanda a las instalaciones. Dado que las instalaciones tienen capacidad, la demanda no puede ser asignada a su instalación más cercana (Current et al. 2004).
- **Problema de localización de concentradores (hub location problem).** Fue propuesto por O'Kelly en 1986 (citado en Current et al. 2004), en él se asume que un producto o un bien determinado puede enviarse entre los nodos de una determinada red, pero éste envío debe realizarse necesariamente a través de nodos especiales denominados concentradores. Estos tienen la función de aglutinar el producto y distribuirlos entre los nodos destino y otros concentradores que los distribuyen a su destino. Se tiene que considerar el número de concentradores, la asignación y las limitaciones de capacidad.
- **Problema de localización maxisuma (maxisum location problem).** Se aplica normalmente a la ubicación de instalaciones no deseadas, su objetivo general es obtener las mejores localizaciones que nos aseguren el mínimo impacto sobre la población y que por otra parte satisfagan los requerimientos de los demandantes de los servicios que prestan este tipo de instalaciones. Una variante es el p-maxisum-sum o p-defense, que maximiza la dispersión promedio entre instalaciones. Este modelo más complejo genera una solución distribuida hacia la periferia de la región considerada y

tiene la ventaja de considerar todas las distancias y no únicamente las distancias mínimas (Bosque et al. 2006).

- **El Problema de la P-Mediana:** Consideraremos el problema de la p-mediana, común en el ámbito de la logística, en donde se asume que el costo de operación es proporcional a la distancia entre un proveedor y un cliente, además de la demanda de este último. De acuerdo con Kariv & Hakimi (1979) pertenece al conjunto NP-Hard. Genéricamente se trata de una red de nodos y arcos, en donde cada nodo representa un foco de demanda y una posible locación para una instalación. “El objetivo es ubicar exactamente p instalaciones, minimizando la distancia total, a la vez que se satisfacen todas las demandas”. Suponiendo que no existen restricciones de capacidad, la formulación del problema como un modelo de programación lineal entera (binaria) mixta, detallada por Daskin (1995), es como sigue:

n : cantidad de clientes (nodos)

i, j : índices referenciales de un nodo.

d_{ij} : distancia más corta entre los nodos i y j

h_i : demanda del nodo i

y_{ij} = 1: si la demanda del nodo i es asignada a la instalación j
0: en cualquier otro caso

x_j = 1: si una instalación es ubicada en j y la demanda de j es asignada a ésta
0: en cualquier otro caso.

p : cantidad de instalaciones que deben ser ubicadas

Utilizando esta notación podemos describir el modelo de la siguiente manera:

Minimizar

$$z = \sum_{i=1}^n \sum_{j=1}^n h_i d_{ij} y_{ij}$$

Sujeto a

$$\sum_{j=1}^n y_{ij} = 1$$

$$\sum_{j=1}^n x_j = p$$

$$y_{ij} - x_i \leq 0, \quad i \neq j$$

$$y_{ij} \in \{0,1\}$$

$$x_i \in \{0,1\}$$

$$\forall i = 1, \dots, n; j = 1, \dots, n$$

2.4 Modelos Estocásticos.

Se denominan estocásticos (del latín *stochasticus*, que a su vez procede del griego *στοχαστικός*, “hábil de conjuntar”) (DRAE) a los modelos cuyo comportamiento es intrínsecamente no determinístico. Un proceso estocástico es aquel cuyo comportamiento es no determinista en la medida en que el subsiguiente estado del sistema esté determinado por tanto por las acciones predecibles del proceso como por elementos aleatorios. Según M. Kac (1976) y E. Nelson (1985) cualquier desarrollo temporal (sea determinístico o esencialmente probabilístico) que pueda ser analizado en términos de probabilidad merece ser denominado como un proceso estocástico.

En los problemas de ubicación de instalaciones, la incertidumbre juega un papel importante. Situaciones como la demanda, el tiempo de transporte, los costos de instalación, etc., involucran aleatoriedad. Los problemas en situaciones de riesgo se conocen como problemas de optimización estocástica, una meta podría ser la optimización de la función objetivo. A la solución de problemas bajo incertidumbre se le conoce como optimización robusta y por lo regular busca optimizar el rendimiento en el peor caso del sistema.

Según *Current et al. (2004)* Hay cuatro enfoques básicos para la localización de problemas de instalaciones estocásticas las cuales son:

- * El primer enfoque aproxima la incertidumbre a un sustituto determinista *Bean et al. (1992)* los cuales formularon un problema determinístico remplazando la demanda estocástica por su tendencia determinística y modificaron sus costos por una nueva tasa de interés que es más pequeña que la original, en proporción aproximada de la demanda.

- * El segundo enfoque aproxima cambios en modelos restringidos. *Daskin (1983)* formuló una extensión probabilística del problema de cobertura máxima en que las instalaciones son asumidas como ocupadas con una probabilidad p . Si está ocupada no puede satisfacer la demanda.

- * El tercer enfoque tiene de manera explícita la interacción de colas que se producen en un sistema de administración de colas especialmente distribuidas con localización de instalaciones múltiples en una red. *Larson (1974)* formuló un modelo de hipercubo de colas con 2^N estados para contar todas las posibles combinaciones de N instalaciones que están o no disponibles.

- * El cuarto enfoque aproxima planificación de escenarios. Estos representan posibles valores de los parámetros que pueden variar en el horizonte de planificación. *Sheppard (1974)* fue uno

de los primeros en aplicar planificación de escenarios, el cual minimizaba el costo esperado sobre todos los escenarios.

2.5 Modelos Evolutivos

Es una técnica de resolución de problemas inspirada biológicamente en la evolución de los seres vivos según la teoría de Darwin de la evolución natural, se requieren programas computacionales cuyo fin es el de imitar el proceso de selección natural que rige el curso de la evolución. Para poder simular el proceso evolutivo en una computadora se requiere lo siguiente:

- Codificar las estructuras de los individuos.
- Operaciones que afecten a los individuos.
- Una función de aptitud.
- Un mecanismo de selección

Diferencias entre los distintos tipos de algoritmos evolutivos existentes:

- Programación evolutiva
- Estrategias evolutivas
- Algoritmos genéticos
- Evolución diferencial.
- Programación genética.

Cada una de estos paradigmas se origina de manera independiente y con motivaciones muy distintas.

2.5.1. Programación Evolutiva.

Lawrence J. Fogel propuso en los años de 1960s una técnica denominada “programación evolutiva”, en el cual la inteligencia se ve como un comportamiento adaptativo.

Son una estrategia de optimización estocástica similar a los AGs, pero hacen un énfasis específico en los operadores evolutivos tal como se observan en la naturaleza en la y las estructuras de datos que utilizan se enfocan al problema de adaptación. Por esto, a diferencia de los AGs, los PEs no son restrictivos en cuanto a la representación del problema. Mientras en los AGs se hace necesaria una codificación de las soluciones del problema; en los PEs, tal representación se hace de forma directa.

El algoritmo básico de la programación evolutiva es el siguiente:

- Generar aleatoriamente una población inicial.
- Se aplica mutación.

- Se calcula la aptitud de cada hijo y se usa un proceso de selección mediante torneo (por lo regular estocástico) para determinar cuáles serán las soluciones que se retendrán.

La programación evolutiva es una abstracción de la evolución al nivel de las especies, por lo que no se requiere el uso de un operador de recombinación (diferentes especies no se cruzan entre sí). Asimismo utiliza una selección probabilística.

Algunas aplicaciones de la programación evolutiva por David B. Fogel (1995) son:

- Predicción, generalización,
- juegos, control automático.
- problema del agente viajero.
- planeación de rutas.
- diseño y entrenamiento de redes neuronales.
- reconocimientos de patrones.

2.5.2. Estrategias Evolutivas.

Las estrategias evolutivas fueron desarrolladas por un grupo de estudiantes de ingeniería encabezados por Ingo Rechenberg (1973) en Alemania, para resolver problemas hidrodinámicos de alto grado de complejidad.

El algoritmo en su versión original (1+1)-EE usaba un solo padre y con él se generaba un solo hijo. Este se mantenía si era mejor que el padre, o de lo contrario se eliminaba, (a este tipo de selección se le llama extintiva, porque los peores individuos obtenían una probabilidad de ser seleccionado de cero).

En la (1+1)-EE un individuo nuevo es generado usando lo siguiente:

$$\mathbf{x}^{t+1} = \mathbf{x}^t + \mathbf{N}(0, \sigma)$$

donde t se refiere a la generación (o iteración) en la que nos encontramos, y $\mathbf{N}(0, \sigma)$ es un vector de números Gaussianos independientes con una media de cero y desviaciones estándar $\sigma = 1$

Considere el siguiente ejemplo de una (1+1)-EE (estrategia evolutiva de dos miembros):

Supongamos que queremos maximizar:

$$f(x_1, x_2) = 100(x_1^2 - x_2)^2 + (1 - x_1)^2$$

dónde: $-2.048 \leq x_1, x_2 \leq 2.048$

ahora supongamos que nuestra población consiste del siguiente individuo (generado aleatoriamente):

$$(x, \sigma) = (-1.0, 1.0), (1.0, 1.0)$$

Supongamos también que las mutaciones producidas son las siguientes:

$$x_1^{t+1} = x_1^t + N(0, 1.0) = -1.0 + 0.61 = 0.39$$

$$x_2^{t+1} = x_2^t + N(0, 1.0) = 1 + 0.57 = 1.57$$

Ahora comparamos al padre con el hijo:

$$\text{Padre} \quad f(x_t) = f(-1.0, 1.0) = 4.0$$

$$\text{Hijo} \quad f(x_{t+1}) = f(-0.39, 1.57) = 201.416$$

Dado que: $201.416 > 4.0$ el hijo reemplazará al padre en la siguiente generación. Ingo Rechenberg (1973) introdujo el concepto de población, al proponer una estrategia evolutiva llamada $(\mu+1)$ -EE, en la cual hay μ padres y se genera un solo hijo, el cual puede reemplazar al peor padre de la población (selección extintiva).

Hans-Paul Schwefel (1977 y 1981) introdujo el uso de múltiples hijos en las denominadas $(\mu+\lambda)$ -EE y (μ, λ) -EE. La notación se refiere al mecanismo de selección utilizado:

- En el primer caso, los μ mejores individuos obtenidos de la unión de padres e hijos sobreviven.
- En el segundo caso, solo los μ mejores hijos de la siguiente generación sobreviven.

2.5.3. Algoritmos genéticos.

Los algoritmos genéticos (denominados originalmente “planes reproductivos genéticos”) fueron desarrollados por John H. Holland a principios de los 1960s, motivado por resolver problemas de aprendizaje automático.

El algoritmo genético enfatiza la importancia de la cruce sexual (operador principal) sobre el de mutación (operador secundario), y utiliza selección probabilística.

El algoritmo básico es el siguiente:

- Generar (aleatoriamente) una población inicial
- Calcular aptitud de cada individuo.
- Seleccionar (probabilísticamente en base de aptitud).
- Aplicar operadores genéticos (cruza y mutación) para generar la siguiente población.
- Ciclar hasta que cierta condición se satisfaga.

La representación tradicional de un individuo es la binaria, tal como se ejemplifica en la figura. 2.2.




Figura 2.2 Ejemplo de la codificación (mediante cadenas binarias) usada tradicionalmente con algoritmos genéticos.

A la cadena binaria se le llama “cromosoma”. A cada posición de la cadena se le denomina “gene” y al valor dentro de esta posición se le llama “alelo”.

Para poder aplicar el algoritmo genético se requiere de los 5 componentes básicos siguientes:

- Una representación de las soluciones potenciales del problema
- Una forma de crear una población inicial de posibles soluciones (por lo regular un proceso aleatorio).
- Una función de evaluación que juegue el papel del ambiente, clasificando las soluciones en términos de su “aptitud”.
- Operadores genéticos que alteren la composición de los hijos que se producirán para las siguientes generaciones.
- Valores para los diferentes parámetros que utiliza el algoritmo genético (tamaño de la población, probabilidad de cruza, probabilidad de mutación, número máximo de generaciones, etc.)

Ha sido demostrado por Günter Rudolph (1994) que el algoritmo genético requiere de elitismo(o sea, retener intacto el mejor individuo de cada generación) para poder converger al óptimo. Los AGs no son normalmente auto-adaptativos, aunque el uso de dicho mecanismo es posible, y ha sido explorado extensivamente en la literatura especializada Tomas Bäck (1992), Lawrence Davis (1989).

2.5.4 Programación genética (PG).

- Es un algoritmo evolutivo y su metodología está inspirada por la evolución biológica para encontrar programas de computadora que realicen una tarea definida por el usuario. Es una especialización de algoritmos genéticos donde el individuo es un programa de computadora. Michael Lynn Cramer (1985) y posteriormente John R Koza (1989) propusieron de forma independiente el uso de representación de árbol en la que se implementó un operador de cruza para intercambiar sub-árboles entre los diferentes programas de una población generada al azar (con ciertas restricciones de sintaxis del lenguaje de programación utilizado). La diferencia fundamental del trabajo de estas investigaciones es que Cramer usó una función de aptitud interactiva (es decir el usuario debía asignar a mano el valor de aptitud de cada árbol de la población) en tanto que John R Koza logró automatizarlo. La propuesta de Koza se denomina *programación genética* y fue implementada originalmente usando expresiones-S en LISP, aunque actualmente existen implementaciones en muchos lenguajes de programación. Su técnica es casi independiente del dominio y ha sido utilizada en un sinnúmero de aplicaciones entre las que destacan la compresión de imágenes, el diseño de circuitos, el reconocimiento de patrones y la planeación de movimientos de robots, John R Koza (1992). Para aplicar programación genética para un dominio particular, se debe definir la función primitiva para ser considerado (por ejemplo, seno, cos, $\sqrt{x}$, +, -, exponenciales), así como los terminales (por ejemplo, x, y constantes tales como 2). Los programas manipulados por PG son normalmente representados por los árboles correspondientes al árbol de análisis sintáctico del programa. Cada llamada a la función se representa con un nodo en el árbol y los argumentos de la función son dados por sus nodos descendientes. Por ejemplo, la figura 2.3 ilustra esta representación del árbol de función $\sin(x) + \sqrt{x^2 + y}$




Figura 2.3 Representación del árbol de la de función $\sin(x) + \sqrt{x^2 + y}$

Al igual que en un algoritmo genético, el algoritmo prototípico de programación genética mantiene una población de individuos (en este caso árbol de programa). En cada iteración, se produce una nueva generación de individuos que utilizan la selección, cruce y mutación. La aptitud de un programa determinado individuo en la población se determina típicamente mediante la ejecución del programa en un conjunto de formación actualizada. Operaciones crossover se realizan mediante la sustitución de un subárbol elegido al azar de un programa de los padres por un subárbol de otro programa para padres. Los operadores genéticos principales de PG son la cruce y la mutación.

- **Cruza.** Es aplicada a un individuo simplemente intercambiando uno de sus nodos con otro nodo de otro individuo en la población. Con una representación basada en árbol, substituir un nodo significa substituir un subárbol completo. Esto agrega mayor eficacia al operador de la cruce. Las expresiones que resultan de la cruce son muy diferentes a los padres iniciales. La figura 2.4 ilustra una operación típica de cruce.
- **Mutación.** La mutación afecta a un individuo de la población. Puede substituir un nodo entero en el individuo seleccionado, o puede substituir apenas la información del nodo. Para mantener la integridad, las operaciones deben ser a pruebas de fallas o del tipo de información. Por ejemplo la mutación debe estar enterada de que existen nodos binarios de la operación, o el operador debe poder manejar valores que falten.




Figura 2.4 Operación de cruce de programas de dos árboles (padres), los punto de cruce (aparecen en negrita) son elegidos al azar. Los subárboles (hijos) aparecen en la parte inferior una vez que son intercambiados los nodos.

2.5.5. Evolución Diferencial

Originalmente el método estaba enfocado en la resolución del problema de ajuste de polinomio de Tchebychev utilizando una variante del método llamada Recocido Genético (genetic annealing) el cual había sido desarrollado por Price el año 1994. En 1996 ED fue presentado en el First International Contest Evolutionary Optimization que buscaba comparar el potencial de distintos métodos de optimización de computación evolutiva terminando ED en tercer lugar. Hoy en día ED representa una de las corrientes principales de la investigación en computación evolutiva.

Algoritmo. El algoritmo asume que las variables del problema a optimizar están codificadas como un vector de números reales. La longitud de estos vectores (**n**) es igual al número de variables del problema, y la población está compuesta de **NP** (Número de padres) vectores. Se define un vector x_p^g , en donde **p** es el índice del individuo en la población ($p = 1 \dots NP$) y **g** es la generación correspondiente. Cada vector está a su vez compuesto de las variables del problema $x_{p,m}^g$, en donde **m** es el índice de la variable en el individuo ($m = 1 \dots n$).

Se asume que el dominio de las variables del problema está restringido entre valores mínimos y máximos x_m^{min} y x_m^{max} , respectivamente.

ED se compone básicamente de cuatro pasos:

- Inicialización
- Mutación
- Recombinación
- Selección.

La inicialización se realiza al principio de la ejecución de la búsqueda, y los pasos de mutación-recombinación-selección se realizan repetidas veces hasta que una condición de término sea satisfecha (número de generaciones, tiempo transcurrido, calidad de solución alcanzada, entre otras).

Inicialización. La población es inicializada (primera generación) aleatoriamente considerando los valores mínimos y máximos de cada variable:

$$x_{p,m}^1 = x_m^{min} + rand(0, 1) \cdot (x_m^{max} - x_m^{min})$$

para $p = 1 \dots NP$, $m = 1 \dots n$, y $rand(0,1)$ un número aleatorio en el rango $[0,1]$.

Mutación. La mutación consiste en la construcción de **NP** vectores aleatorios ruidosos (noisy random vectors), los cuales son creados a partir de tres individuos elegidos al azar, llamados vectores objetivo (target vectors), x_a, x_b, x_c . Los vectores aleatorios ruidosos (n_p^g) son obtenidos de la siguiente manera:

$$n_p^g = x_c + F \cdot (x_a - x_b)$$

con p, a, b y c distintos entre sí, y $p=1...NP$

F es un parámetro que controla la tasa de mutación, y se encuentra en el rango $[0,2]$

Recombinación. Una vez obtenidos los NP vectores aleatorios ruidosos, la recombinación se efectúa de manera aleatoria, comparándolos con los vectores originales (x_p^g), obteniendo los vectores de prueba (trial vectors, t_m^g) de la siguiente manera:

$$t_{p,m}^g = \begin{cases} n_{p,m}^g & \text{si } rand(0, 1) < GR \\ x_{p,m}^g & \text{en otro caso} \end{cases}$$

para $p = 1...NP, m = 1...n$.

GR es un parámetro que controla la tasa de recombinación. Nótese que la comparación se hace variable por variable, por lo que el vector de prueba será una mezcla de los vectores aleatorios ruidosos y originales.

Selección. Finalmente, la selección se realiza simplemente comparando los vectores de prueba con los originales, de manera que el vector de la generación siguiente será aquel que tenga el mejor valor de función de desempeño **fit**:

$$x_p^{g+1} = \begin{cases} t_p^g & \text{si } fit(t_p^g) > fit(x_p^g) \\ x_p^g & \text{en otro caso} \end{cases}$$

2.6 Aplicación de algoritmo genético en un problema de inversión.

Con la finalidad de aclarar mejor los conceptos cubiertos previamente, presentaremos ahora una sencilla aplicación del algoritmo genético a un problema de optimización tomado de Kaufmann, A. y Faure, R. (1977). Un grupo de financieros mexicanos ha resuelto invertir 10 millones de pesos en la nueva marca de vino "Carta Nueva".

Así pues, en 4 ciudades de las principales de México se decide iniciar una vigorosa campaña comercial:

México en el centro, Monterrey en el noroeste, Guadalajara en el occidente y Veracruz en el oriente. A esas 4 ciudades van a corresponder las zonas comerciales I, II, III y IV. Un estudio de mercado ha sido realizado en cada una de las zonas citadas y han sido establecidas curvas de ganancias medias en función de las inversiones totales (almacenes, tiendas de venta, representantes, publicidad, etc.) Estos datos se ilustran en la Tabla 2.1.

Para simplificar los cálculos, supondremos que las asignaciones de créditos o de inversiones deben hacerse por unidades de 1 millón de pesos. La pregunta es: ¿en dónde se deben de asignar los 10 millones de pesos de los que se dispone para que la ganancia total sea máxima?

Tabla 2.1 Datos obtenidos con la investigación de mercado en cada una de las regiones.

Inversión(en millones)	Beneficio 1	Beneficio 2	Beneficio 3	Beneficio 4
0	0	0	0	0
1	0.28	0.25	0.15	0.20
2	0.45	0.41	0.25	0.33
3	0.65	0.55	0.40	0.42
4	0.78	0.65	0.50	0.48
5	0.90	0.75	0.62	0.53
6	1.02	0.80	0.73	0.56
7	1.13	0.85	0.82	0.58
8	1.23	0.88	0.90	0.60
9	1.32	0.90	0.96	0.60
10	1.38	0.90	1.00	0.60

1) Representación: Lo primero que necesitamos determinar para poder aplicar el algoritmo genético, es cuál será el esquema a utilizarse para representar las posibles soluciones del problema. En este caso necesitamos 4 bits ($2^4 = 16$) para representar cada solución, porque cada una admite 11 valores posibles (de 0 a 10). Como existen 4 valores independientes (uno por cada zona de estudio), se requieren entonces 16 bits (4×4) por cada cromosoma. De tal forma, una cadena representativa de un cromosoma será como se muestra en la figura 2.4. Es importante hacer notar que se requiere una función de codificación (i.e., que transforme el valor de la inversión a binario) y una de decodificación (i.e., que realice el proceso inverso). Debido a que en este caso los 4 bits utilizados para representar una solución pueden producir más valores de los que se necesitan, se usará una función de ajuste que haga que los resultados producidos siempre se encuentren en el rango válido.




Figura2.5: Cadena representativa de un cromosoma de los utilizados en nuestro ejemplo de optimización. Las cadenas 1, 2, 3 y 4 corresponden a las cantidades invertidas en las zonas económicas respectivas.

2) Función de Aptitud: Dado que el objetivo es obtener las inversiones que sumen 10, y que tengan un beneficio máximo, podemos usar la siguiente función de aptitud penalizada:

$$F(x) = \frac{c1+c2+c3+c4}{500 \cdot V + 1}$$

donde **c1**, **c2**, **c3** y **c4** son las ganancias por zona, que se calculan de acuerdo a los valores de la Tabla 2.1, y **v** es el valor absoluto de la diferencia entre la suma obtenida y 10. Nótese que cuando no se viole ninguna restricción (i.e., cuando la suma de inversiones sea exactamente 10, la función de aptitud no será "castigada").




Figura2.6: Uso de 2 puntos de cruce entre 2 individuos. Note como en este caso se mantienen los genes de los extremos, y se intercambian los del centro. También aquí existe la posibilidad de que uno o ambos puntos de cruce se encuentren en los extremos de la cadena, en cuyo caso se hará una cruce usando un solo punto, o ninguna cruce, según corresponda.

3) Operadores: Se usará una cruce de 2 puntos, la cual se efectúa de la forma que se indica en la Figura 2.5. La probabilidad que se dará a la misma será del 80%. En cuanto a la mutación, se le asignará una probabilidad baja, tal y como sugiere Goldberg (1989), por lo que será del orden del 1%.

El tamaño de población manejado para este ejemplo será de 50 cromosomas, y se correrá el algoritmo genético durante 20 generaciones.

4) Resultados: El resultado obtenido en una corrida típica es de \$1.81 (en millones de pesos), correspondiente a los valores de C1=4 millones, C2=3 millones, C3=1 millón y C4=2 millones. Esta es la solución óptima, la cual se obtuvo originalmente mediante programación dinámica. El tiempo que le tomó al algoritmo genético encontrar este valor fue de sólo 3 segundos. Para realizar la experimentación se utilizó una computadora Celeron 1.6 ghz y un gb en ram, el cual fue programado y ejecutado en Matlab. El código fuente de este experimento se encuentra en el Anexo 1. Debe hacerse notar que, en este caso, si deseáramos analizar inversiones que sumen otra cantidad, y en unidades menores al millón, el algoritmo genético tendría que modificarse de manera mínima, mientras que la programación dinámica requeriría una cantidad tal de trabajo que prácticamente se volvería inoperante.

CAPITULO 3

Metodología.

3.1 Alcances y enfoque de la investigación.

Con el fin de obtener otra forma de encontrar una solución cercana a la óptima a los problemas de optimización, en este caso la determinación de un centro de distribución en la cadena de suministro, se planteó la aplicación de un algoritmo genético (AG) a partir de varios ejercicios teóricos tomados del libro de Gianpaolo Ghiani, et.al (2003) los cuales fueron resueltos en Lingo. Se analizó la necesidad de utilizar los Modelos Evolutivos y dadas las características de los AG, se determinó utilizarlos ya que estos son aplicables a los problemas de optimización. Las características principales de un proceso evolutivo son las siguientes:

- a) Codificar las estructuras
- b) Operaciones que afecten a los individuos
- c) Una función de aptitud
- d) Un mecanismo de selección

En el caso del algoritmo genético, éste enfatiza la importancia de la cruce sexual (operador principal) sobre el de mutación (operador secundario), y utiliza selección probabilística.

El algoritmo básico es el siguiente:

- Generar (aleatoriamente) una población inicial
- Calcular aptitud de cada individuo.
- Seleccionar (probabilísticamente en base a la aptitud).
- Aplicar operadores genéticos (cruza y mutación) para generar la siguiente población.
- Iterar hasta que cierta condición se satisfaga.




Figura 3.1 Ejemplo de la codificación (mediante cadenas binarias) usada tradicionalmente en los algoritmos genéticos

La representación es la binaria tal y como se muestra en la figura 3.1. A la cadena binaria se le llama cromosoma. A cada posición de la cadena se le denomina gene y al valor dentro de esta

posición se le llama alelo. Para poder aplicar el algoritmo en los experimentos a tratar se requiere de cinco componentes básicos siguientes:

- Una representación de las soluciones potenciales del problema.
- Una forma de crear una población inicial de posibles soluciones, por lo regular se requiere un proceso aleatorio.
- Una función de evaluación que juegue el papel de ambiente, clasificando las soluciones en términos de aptitud.
- Operadores genéticos que alteren la composición de los hijos que se producirán para las siguientes generaciones.
- Valores para los diferentes parámetros que utiliza el algoritmo genético por ejemplo el tamaño de la población, la probabilidad de cruce, la probabilidad de mutación, el número máximo de generaciones, etc. Estos tendrán que programarse en Matlab para que nos determine la solución del experimento.

3.2 Descripción del objeto en estudio

Con el objeto de desarrollar el algoritmo genético en un problema de optimización para la determinación de centros de distribución se utilizaron tres ejemplos tomados de Gianpaolo Ghiani, et. al (2003). El primer experimento plantea primeramente un ejercicio donde se utiliza la p-mediana y se asume que el costo de operación es proporcional a la distancia entre un proveedor y un cliente, además de la demanda de este último. El objetivo es determinar el número de instalaciones $p=2$ bajo el supuesto de que no existen restricciones de capacidad. Dada las características del experimento, primeramente se determina cromosoma de 20 bits ya que se tienen doce posibles orígenes y doce destinos a designar, los cuales se cubren con un cromosoma de 20 bits, esto de acuerdo al valor binario de la posición que requieran.

Los primeros 4 bits van a corresponder al origen número 1 a determinar. En la figura 3.2 se tiene un valor igual a 2 por su posición binaria en el cromosoma y éste correspondería a la instalación 2 de los posibles doce a determinar.

0	0	1	0
---	---	---	---

Figura 3.2 Cadena de cuatro bits

Los bits del número 5 al número 8 corresponden al origen 2 a determinar. En la figura 3.3 se tiene valor igual a 9 por su posición binaria en el cromosoma correspondería al instalación 9 de los posible doce a determinar.

1	0	1	0
---	---	---	---

Figura 3.3 Cadena de cuatro bits

Del bit número 9 al bit número 20 corresponden a todos los posibles destinos, ya que el ejercicio pide determinar solo dos orígenes y a la vez seleccionar de los doce destinos lo más

cercano a lo óptimo. En la figura 3.4 se ejemplifica la determinación de los doce destinos. Aquellos destinos cuyo valor tengan uno (1) en el cromosoma corresponden al origen 1 determinado, y aquellos destinos que tengan valor cero (0) corresponden al origen 2 determinado.

0	1	0	1	1	0	0	1	1	0	1	0
---	---	---	---	---	---	---	---	---	---	---	---

Figura 3.4 Cadena de 12 bits para determinar los destinos del experimento 1

El segundo experimento (Goutte) plantea la oportunidad de abrir una nueva planta en la cual algo de su producción de otras fábricas se pueda mover, esto por el motivo de que recientemente ha logrado un incremento inesperado de sus ventas de bebidas gaseosas. El proceso de producción hace uso de agua, disponible en cualquier parte en Canadá en una cantidad ilimitada a un costo insignificante, y de extractos de azúcar los cuales componen un modesto porcentaje del peso total del producto terminado. Por ésta razón, los costos de abastecimiento son despreciables comparados con los costos de distribución de productos terminados. El experimento muestra las distancias entre plantas de producción potenciales y los mercados a atender, además de los costos de operación anual y capacidades de las plantas potenciales así como también las demandas anuales de las ventas por distrito. De acuerdo a las características del experimento se determinó un cromosoma de 24 bits. De los bits número 1 al bit número 12 corresponden a los orígenes posibles a determinar para alcanzar el más óptimo. Cada origen es codificado con cuatro bits y se determina de acuerdo a su valor binario el cual se muestra en la figura 3.5.

Origen				Origen				Origen			
0	0	1	0	0	1	0	1	1	0	1	0

Figura 3.5. Cadena de 12 bits para determinar los orígenes del experimento 2

Por ejemplo y dado los valores binarios de la cadena en la figura 3.5, las plantas potenciales a abrir serian la planta No. 2, la planta No. 5 y la planta No. 10.

En cuanto a los bits número 13 al bit número 24 van a corresponder a los destinos, los cuales son codificados con dos bits cada uno de los posibles seis a elegir para así determinar los más cercanos al óptimo (figura 3.5).

Destino		Destino		Destino		Destino		Destino		Destino	
0	1	1	0	1	1	1	0	1	1	0	1

Figura 3.6 cadena de 12 bits para determinar los destinos del experimento 2

Para determinar los destinos se realizará lo siguiente: El valor (0,1) representará el destino del origen 1; el valor (1,0) representará el destino del origen 2 y el valor (1,1) representará el destino del origen 3.

El tercer experimento (Logconsult) es una compañía de consultoría americana comisionada para proponer cambios al sistema de logística de Gélido, una firma mexicana distribuidora de mariscos congelado. Un estudio preliminar del problema condujo a la identificación de cerca de $|V_1| = 30$ lugares potenciales donde los almacenes pueden abrirse o ya existen. En cada lugar varios tipos diferentes de almacenes pueden ser usualmente instalados. Nosotros mostramos como puede estimarse la función de costo $i \in V_1$ de una instalación potencial. Los costos fijos de la instalación incluyen renta, amortización de maquinaria, seguros de locales y maquinaria, y salarios del personal son mostrados en el ejercicio. Los costos variables están relacionados con el almacenamiento y la manipulación de mercancías los cuales son mostrados con datos históricos. Los costos variables de instalación son influenciados por costos de inventario los cuales generalmente aumentan con la raíz cuadrada de la demanda. De acuerdo a las características del experimento se determinó un cromosoma de 24 bits ya que en el mismo se tienen seis orígenes y cuatro destinos a seleccionar como se muestra en la figura 3.7. De los 24 bits seleccionados del cromosoma, cada gen representa un valor de la matriz con valor real tal como se muestran en la figura 3.8.

0	0	0	1
0	0	0	0
0	0	0	0
1	0	0	0
0	1	0	1
1	0	0	0

Figura 3.7 Matriz de 6x4 del experimento 3.

El valor (1) representa el origen al posible destino seleccionado de acuerdo al lugar que ocupa en el cromosoma; el valor (0) significa que no existe selección.

0	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	1	1	0	0	0
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Figura. 3.8 Ejemplo de cromosoma de 24 bits ya codificado del experimento 3.

De acuerdo con la posición del valor binario del cromosoma el AG determinó lo siguiente. Los bits con valor 1 corresponden a los seleccionados de la matriz 6x4. Esto es, que la posición 4 del cromosoma corresponde al origen 1 con destino 4. La posición 13 corresponde al origen 4 con destino 1; la posición 18 corresponde al origen 5 con destino 2; la posición 20 corresponde al origen 5 con destino 4 y la posición 21 corresponde al origen 6 con destino 1. Los bits con valor 0 significa que no fueron seleccionados.

CAPITULO 4 Experimentación

4.1 Descripción del experimento No.1.

Koster Express es una empresa de transportación en Oklahoma (USA), la cual proporciona un servicio organizado a través de un subsistema de distribución, un grupo de terminales y un subsistema de transportación de largo trayecto. Gianpaolo Ghiani, et. al (2003). La distribución del subsistema usa camiones que cargan mercancía de salida de 1:00 p.m. a 7:00 p.m. y reciben productos de 9:00 a.m. a 1:00 p.m. Las terminales son equipadas en áreas donde las mercancías de salida son colectadas y consolidadas en pallets, y en donde las mercancías de entrada son abiertas, clasificadas y dirigidas a su destino. Sus camiones tienen una capacidad de 14 a 18 pallets; es decir aproximadamente de 0.8 a 1 tonelada. Koster Express tiene 9 terminales en: Ardmore, Bartlesville, Duncan, Enid, Lawton, Muskogee, Oklahoma City, Ponca City y Tulsa, entre las cuales existe un subsistema de transportación de largo trayecto. Los productos que vienen de Enid y destinados a Oklahoma City son traídos de Tulsa, donde son enviados al centro de Duncan junto con los productos que vienen de Ponca City, Muskogee, Bartlesville y Tulsa respectivamente, y finalmente son enviados a Oklahoma City. Los productos que están destinados a Lawton viniendo de Ardmore son enviados a Duncan, mantenidos en ese centro, hasta la llegada de los camiones que vienen de Tulsa, a su llegada, se envían a Lawton junto con los productos que vienen de las otras terminales. Por crecimiento la empresa ofreció la apertura de nuevas terminales en Altus, Edmond y Stillwater, además de la relocalización de los dos centros anteriores (Duncan y Tulsa).

Las distancias de los centros de distribución a las terminales se muestran en las tablas 4.1 y 4.2.

El objetivo, con la apertura de estas nuevas terminales, es tratar de reducir costos de transportación logísticos de ida y vuelta entre dos centros. Para la solución de este problema será necesario formularlo a través del problema de localización de P-Mediana.

$$\text{Minimizar } \sum_{i \in V_1} \sum_{j \in V_2} c_{ij} x_{ij} \quad (4.1.1)$$

Sujeto a:

$$\sum_{i \in V_1} x_{ij} = 1, j \in V_2 \quad (4.1.2)$$

$$\sum_{j \in V_2} x_{ij} \leq |V_2| y_i, \quad i \in V_1 \quad (4.1.3)$$

$$\sum_{i \in V_1} y_i = 2 \quad (4.1.4)$$

$$x_{ij} \in \{0, 1\}, \quad i \in V_1, \quad j \in V_2, \quad (4.1.5)$$

$$y_i \in \{0, 1\}, \quad i \in V_1, \quad (4.1.6)$$

Donde $V_1=V_2$ representan el conjunto de terminales antiguos y nuevos; $y_i, i \in V_1$, es una variable de decisión binaria cuyo valor es igual a 1 si la terminal tiene capacidad para un centro y 0 en caso contrario; $x_{ij}, i \in V_1, j \in V_2$, es una variable de decisión binaria cuyo valor es igual a 1 si el centro ubicado en la terminal sirve de terminal y 0 en caso contrario, sin embargo debido a la estructura particular de las restricciones del problema, las variables no pueden ser fraccionadas ni mayor que 1, por lo tanto pueden ser remplazadas con $x_{ij} \geq 0$, $i \in V_1, j \in V_2$. Dado que los productos de entrada y salida todos los días desde cada terminal puede ser transferido por un solo camión con una capacidad de 14 pallets, los costos de transporte todos los días (en dólares) entre un par de terminales, $i \in V_1, V_2 \in j$ está dada por $C_{ij} = 2 \times 0.74 \times l_{ij}$, donde 0.74 es el costo de transporte (en dólares por milla), y l_{ij} es la distancia (en millas) entre los terminales(ver tabla 4.1 y 4.2).

Tabla4.1. Distancia (en millas) entre terminales en el problema Koster Expres (Parte I)

	Altus	Ardmore	Bartlesville	Duncan	Edmond	Enid
Altus	0.0	169.8	291.8	88.2	153.9	208.2
Ardmore	169.8	0.0	248.6	75.9	112.5	199.0
Bartlesville	291.8	248.6	0.0	231.5	146.0	132.4
Duncan	88.2	75.9	231.5	0.0	93.5	137.5
Edmond	153.9	112.5	146.0	93.5	0.0	88.8
Enid	208.2	199.0	132.4	137.5	88.8	0.0
Lawton	54.2	115.8	238.7	34.1	100.7	145.0
Muskogee	274.2	230.4	92.2	231.5	147.5	166.4
Oklahoma City	141.1	100.5	151.4	80.9	14.4	87.6
Ponca City	245.0	202.2	70.2	184.8	91.9	64.5
Stillwater	209.2	162.6	115.0	145.3	53.0	65.8
Tulsa	248.0	204.6	45.6	187.8	102.2	118.4

Tabla4.2. Distancia (en millas) entre terminales en el problema Koster Expres (Parte II)

	Lawton	Muskogee	Oklahoma City	Ponca City	Stillwater	Tulsa
Altus	54.2	274.2	141.1	245.0	209.2	248.0
Ardmore	115.8	230.0	100.5	202.2	162.6	204.6
Bartlesville	238.7	92.2	151.4	70.2	115.0	45.6
Duncan	34.1	231.5	80.9	184.8	145.3	187.8
Edmond	100.7	145.7	14.4	91.9	53.0	102.2
Enid	145.0	166.4	87.6	64.5	65.8	118.4
Lawton	0.0	220.6	88.0	191.9	152.5	194.9
Muskogee	220.6	0.0	140.4	142.5	119.2	48.1
Oklahoma City	88.0	140.4	0.0	104.7	66.6	107.6
Ponca City	191.9	142.5	104.7	0.0	41.9	96.5
Stillwater	152.5	119.2	66.6	41.9	0.0	71.2
Tulsa	194.9	48.1	107.6	96.5	71.2	0.0

4.1.1 Aplicación del modelo propuesto.

Originalmente el problema fue solucionado como un modelo matemático determinístico de la P-mediana, programado y corrido en el software **Lingo Versión 10** obteniéndose los resultados siguientes:

1. Centro de Distribución1 (Duncan): va a atender a Altus, Duncan, Ardmore y Lawton;
2. Centro de Distribución2 (Stillwater): va a atender a Bartlesville, Edmond, Enid, Muskogee, Oklahoma City, Ponca City, Stillwater y Tulsa .Con un costo de 1'081,732.00 USD. **Anexo 2**

Con la finalidad de utilizar los conceptos ya conocidos previamente, presentaremos ahora la propuesta de aplicación de este experimento al problema de optimización desarrollando paso a paso el algoritmo genético implementado en MATLAB 7.6 V 2.8.

- a) Dada las características del experimento, se determinó un cromosoma de 20 bits (figura 4.1); ya que se tienen doce posibles orígenes y seis destinos a designar, los cuales se cubren con un cromosoma de 20 bits, esto de acuerdo al valor binario de la posición que requieran
- b) Los primeros 4 bits van a corresponder al origen número 1, los bits del número 5 al número 8 corresponden al origen 2;
- c) Del bit número 9 al bit número 20 corresponden a todos los posibles destinos, ya que el ejercicio pide determinar solo dos orígenes y a la vez seleccionar de los doce destinos lo más cercano a lo más óptimo.




Figura. 4.1 Cromosoma de 20 bit

4.1.2 Aplicación de los parámetros utilizados en la ejecución del Algoritmo Genético en el experimento No.1.

El experimento fue ejecutado en Matlab en 10 ocasiones utilizando la siguiente información:

- A) Se utilizó un tipo de población binaria, el número de individuos fueron 20, con 100 generaciones como número máximo,
- B) El método de selección fue por torneo,
- C) Se empleó una probabilidad de cruce de 0.8,
- D) El tipo de cruce utilizado fue de un punto,
- E) La probabilidad de mutación utilizada fue de 0.1,
- F) El tipo de mutación realizada fue uniforme,
- G) La función de aptitud es el costo total de transportación de cada uno de los orígenes a cada uno de los destinos correspondientes.
- H) El cromosoma óptimo resultante es el mostrado en la figura 4.2.




Figura. 4.2 Solución Experimento 1 de cromosoma codificado.

La interpretación del cromosoma resultante de acuerdo al valor binario determinó lo siguiente:

- 1) El origen 1 corresponde a la posición No.4 (Duncan) y el origen 2 corresponde a la posición 11(Stillwater) dentro de los primeros 8 bits.
- 2) Todos los destinos determinados en los bits del 9 al 20 que tengan uno (1) corresponden al origen 1, todos los destinos que tengan cero (0) corresponden al origen 2, esto de acuerdo a las tablas 3.1 y 3.2 del problema original.

Experimentos y resultados del problema 1.

En la figura 4.3 se muestra la gráfica del experimento que dio como resultado el aplicar AGs donde se determina como resultado las mejores soluciones por generación para obtener la mejor solución cercana a la óptima siendo esta en la generación 22 los resultados obtenidos son los siguientes:

- a) el tiempo promedio obtenido de las 10 ejecuciones fue de 0.94605 seg. ,
- b) donde 0.8406 seg. fue el mejor tiempo obtenido.
- c) el tiempo de 1.1757 seg. fue el peor que se obtuvo en este experimento, estos se muestran en la figura 4.3.
- d) el costo promedio obtenido de las 10 ejecuciones fue de 1'157,152.80 USD,
- e) donde el mejor costo obtenido de este experimento fue 1'081,732.00 USD

- f) el peor costo obtenido fue de 1'275,168.00 USD. En la fig. 3.4 se observan las mejores soluciones por generación por cada una de las 10 ejecuciones.




Figura 4.3 Gráfica de mejores soluciones por generación del experimento 1.

De acuerdo con la mejor solución encontrada, los centros de distribución y los puntos de destino seleccionados con el criterio del menor costo son:

Centro de distribución 1 es la Planta ubicada en (Duncan): la cual va a abastecer Altus, Ardmore, Duncan, Lawton; Centro de distribución 2 es la planta ubicada en (Stillwater): y esta abastecerá a Bartlesville, Edmond, Enid, Muskogee, Oklahoma City, Ponca City, Stillwater, Tulsa.




Figura 4.4 Grafica de mejores soluciones encontradas por cada una de las 10 ejecuciones del algoritmo genético.

En conclusión con la implementación descrita se obtuvo la misma solución por Lingo fue de **\$ 1'081,732.00 USD** el experimento fue ejecutado en 10 ocasiones y el mejor resultado fue en la **generación 22** en un tiempo cercano al óptimo de **0.8406** segundos. Se utilizó una computadora con procesador Celeron a 1.6 ghz y un gb en ram. Anexo 3.

En el Anexo 4 se realiza el mismo experimento determinando utilizar tres centros de distribución lo que por lógica resulta mucho más caro que utilizar dos CDs.

4.2 Descripción del experimento No. 2.

Goutte es una compañía canadiense de manufactura y distribución de bebidas ligeras Gianpaolo Ghiani, et. al (2003). La firma recientemente ha logrado un incremento inesperado de sus ventas mayormente debido al lanzamiento de una nueva bebida que se ha vuelto muy popular en consumidores jóvenes. La administración está ahora considerando la oportunidad de abrir una nueva planta en la cual algo de su producción de otras fábricas se pueda mover.

El proceso de producción hace uso de agua, disponible en cualquier parte en Canadá en una cantidad ilimitada a un costo insignificante, y de extractos de azúcar los cuales componen un modesto porcentaje del peso total del producto terminado. Por ésta razón, los costos de abastecimiento son despreciables comparados con los costos de distribución de productos terminados, y los costos de transportación son un producto independiente. La Tabla 4.3 proporciona las distancias entre plantas potenciales y mercados.

Tabla 4.3 Las distancias (en kilómetros) entre plantas de producción potenciales y mercados en el problema de Goutte.

		Mercados					
		Brossard	Granby	Saint-Julie	Sherbrooke	Valleyfield	Verdum
Plantas de producción potenciales	Brossard	0.0	76.1	30.4	139.4	72.6	11.7
	Granby	76.1	0.0	71.0	77.2	144.5	83.7
	LaSalle	20.8	92.9	47.2	156.1	47.5	11.7
	Mascouche	54.7	113.3	52.9	187.2	93.0	45.2
	Montreal	13.5	85.5	28.0	148.7	67.3	9.3
	Saint-Julie	30.4	71.0	0.0	138.2	94.5	38.1
	Sherbrooke	139.4	77.2	138.2	0.0	207.9	146.9
	Terrebonne	47.8	106.5	46.2	180.2	86.7	38.9
	Valleyfield	72.6	144.5	94.5	207.9	0.0	63.4
	Verdum	11.7	83.7	38.1	146.9	63.4	0.0

Los costos de operación anual y capacidades de las plantas potenciales se muestran en la Tabla 4.4 mientras que las demandas anuales de las ventas por distrito se reportan en la Tabla 4.5.

Tabla 4.4. Costos de operación de planta (en dólares canadienses por año) y capacidad (en hectolitros -100 litros- por año) en el problema Goutte.

Sitio	Costo fijo	Capacidad
Brossard	81400	22000
Granby	83800	24000
LaSalle	88600	28000
Mascouche	91000	30000
Montreal	79000	20000
Saint-Julie	86200	26000
Sherbrooke	88600	28000
Terrebonne	91000	30000
Valleyfield	79000	20000
Verdum	80200	21000

Tabla 4.5. Demanda (en hectolitros por año) de las ventas distritales en el problema Goutte.

Sitio	Demanda
Brossard	14000
Granby	10000
Saint-Julie	8000
Sherbrooke	12000
Valleyfield	10000
Verdum	9000

La distancia máxima entre una planta potencial y un mercado es sucesivamente igual a ∞ y 70 km. Los camiones tienen una capacidad de 150 hectolitros y un costo (incluyendo los salarios de la tripulación) de 0.92 dólares canadienses por kilómetro. El problema de Goutte entonces se modela con una formulación CPL, de la siguiente manera.

$$\text{Minimizar } \sum_{i \in V_1} \sum_{j \in V_2} c_{ij} x_{ij} + \sum_{i \in V_1} f_i y_i \quad (4.2.1)$$

Sujeto a

$$\sum_{i \in V_1} x_{ij} = 1 \quad j \in V_2, \quad (4.2.2)$$

$$\sum_{j \in V_2} d_i x_{ij} \leq q_i y_i, \quad i \in V_1, \quad (4.2.3)$$

$$0 \leq x_{ij} \leq 1, \quad i \in V_1, \quad j \in V_2, \quad (4.2.4)$$

$$y_i \in \{0, 1\}, \quad i \in V_1, \quad (4.2.5)$$

$$\text{donde: } c_{ij} = c_{ij} d_j, i \in V_1, \quad j \in V_2, \quad (4.2.6)$$

donde $V_1 = \{\text{Brossard, Granby, LaSalle, Mascouche, Montreal, Saint-Julie, Sherbrooke, Terrebonne, Valleyfield, Verdum}\}$ y $V_2 = \{\text{Brossard, Granby, Saint-Julie, Sherbrooke,}$

Valleyfield, Verdum}; x_{ij} , $i \in V_1, j \in V_2$, es una variable de decisión representando la fracción de la demanda anual del mercado j satisfecha por la planta i ; y_i , $i \in V_1$, es una variable de decisión binaria, en la que el valor es igual a 1 si la planta potencial i está abierta, 0 de cualquier otra manera. Los costos de transportación c_{ij} , $i \in V_1, j \in V_2$ (ver Tabla 4.6), son calculados a través de la ecuación (4.2.6), observando que los camiones siempre viajan con carga completa en el viaje de ida y vacíos en el viaje de regreso. Por ejemplo, a partir de la distancia entre la planta potencial localizada en Granby y los costos distritales de Brossard es de 76.1 Km., el costo de transportación es $2 \times 76.1 \times 0.92 = 140.06$ dólares canadienses por la transportación de 150 hectolitros. Puesto que la demanda de las ventas distritales de Brossard es de 14000 hectolitros por año, el costo de transportación anual para satisfacer la demanda completa del mercado Brossard desde la planta potencial de Granby es $(14000/150) \times 140.06 = 13072.32$ dólares canadienses.

Tabla 4.6. Costos de transportación (en dólares canadienses por año) c_{ij} , $i \in V_1, j \in V_2$, en el problema Goutte

	Brossard	Granby	Saint-Julie	Sherbrooke	Valleyfield	Verdum
Brossard	0.00	9337.37	2984.80	20514.58	8903.08	1296.97
Granby	13072.32	0.00	6964.54	11370.67	17727.19	9238.67
LaSalle	3565.18	11390.41	4627.23	22978.23	5823.52	1296.97
Mascouche	9396.60	13897.49	5195.76	27550.19	11410.15	4992.43
Montreal	2321.51	10482.34	2747.91	21888.54	8251.63	1030.47
Saint-Julie	5223.40	8705.67	0.00	20348.76	11587.82	4210.70
Sherbrooke	23933.68	9475.56	13565.84	0.00	25505.04	16220.97
Terrebonne	8208.20	13068.37	4532.48	26531.56	10640.26	4299.53
Valleyfield	12464.31	17727.19	9270.25	30606.05	0.00	7000.07
Verdum	2017.50	10265.19	3742.85	21627.96	7777.85	0.00

4.2.1 Proceso de solución propuesto al experimento No. 2.

Originalmente el problema fue solucionado por medio del software tradicional Lingo, la solución óptima nos conduce a la apertura de tres plantas de producción. Brossard que atenderá a Brossard y Saint-Julie; Granby que atenderá a Granby y Sherbrooke; y la tercera es Valleyfield que atenderá Valleyfield y Verdum. Los mejores costos logísticos anuales equivalen a 265,283.12 USD. (Anexo 5).

Al igual que el experimento No.1 y con la finalidad de utilizar los conceptos ya conocidos previamente, presentaremos ahora la propuesta de aplicación de este experimento al problema de optimización desarrollando paso a paso el algoritmo genético implementado en MATLAB 7.6 V 2.8.

- a) De acuerdo a las características del experimento se determinó un cromosoma de 24 bits (figura 4.5).

- b) De los bits número 1 al bit número 12 corresponden a los orígenes posibles a determinar para alcanzar el más óptimo.
- c) Cada origen es codificado con cuatro bits y se determina de acuerdo con su valor binario.
- d) De los bits número 13 al bit número 24 corresponden a los destinos, los cuales son codificados con dos bits cada uno de los posibles seis a elegir para así determinar los más cercanos al óptimo.
- e) El valor (0,1) representa el destino del origen 1; el valor (1,0) el destino del origen 2 y el valor (1,1) el destino del origen 3, de acuerdo con la tabla 4.3.

Origen 1				Origen 2				Origen 3				Destino 1		Destino 2		Destino 3		Destino 4		Destino 5		Destino 6	
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24

Figura 4.5. Cromosoma de 24 bits del experimento 2.

El algoritmo genético para este ejercicio fue ejecutado 10 veces con los parámetros siguientes:

- 1) Se utilizó un tipo de población binaria,
- 2) El número de individuos o cromosomas fueron 24,
- 3) Se establecieron 100 generaciones como número máximo,
- 4) El método de selección fue por torneo,
- 5) Se utilizó una probabilidad de cruce de 0.8,
- 6) El tipo de cruce utilizado fue de un punto,
- 7) La probabilidad de mutación fue de 0.1
- 8) El tipo de mutación utilizada fue la uniforme,
- 9) La función de aptitud es el costo de transportación penalizando las restricciones. El cromosoma óptimo resultante es el mostrado en la Figura 4.6

Origen				Origen				Origen				Destino		Destino		Destino		Destino		Destino		Destino	
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
0	0	0	1	0	0	1	0	1	0	0	1	0	1	1	0	0	1	1	0	1	1	1	1

Figura 4.6. Cromosoma resultante del experimento 2.

De acuerdo con la posición del valor binario del cromosoma el AG determinó lo siguiente:

- 1) El origen 1 corresponde a la posición 1(Brossard), el origen 2 corresponde a la posición 2(Granby) y el origen 3 corresponde a la posición 9(Valleyfield) dentro de los primeros 12 bits.
- 2) Todos los destinos determinados en los pares de bits del 13 al 24 que tengan el valor (0,1) corresponden al origen 1; los que tengan el valor (1,0) corresponden al origen 2 y los que tengan el valor (1,1) corresponden al origen 3, esto de acuerdo a la tabla 4.3.

4.2.2. Resultados obtenidos del problema 2.

En la Figura 4.7 se muestra la gráfica de las mejores soluciones por generación para encontrar el mejor resultado el cual fue alcanzado en la generación 46, los resultados obtenidos son los siguientes:

- a) El tiempo promedio obtenido de las 10 ejecuciones fue de 4.9564 seg. ,
- b) El mejor tiempo obtenido fue de 3.8632 seg.
- c) el tiempo peor obtenido del experimento fue de 5.9365 seg. , estos tiempos se muestran en la figura 4.7.
- d) el costo promedio obtenido de las 10 ejecuciones fue de 279,811.34 USD,
- e) el mejor costo que se obtuvo fue de 265,555.54 USD
- f) el peor costo fue de 292,236.89 USD. Ver figura 4.8.




Figura 4.7 Grafica de mejores soluciones por generación para los mejores resultados encontrados en experimento 2.

De acuerdo con la mejor solución encontrada y su interpretación en el cromosoma de solución, los centros de distribución y los puntos de destino son de la siguiente manera: Brossard atenderá Brossard y Saint-Julie; Granby atenderá a Granby, Sherbrooke y finalmente Valleyfield atenderá a Valleyfield y Verdum.




Figura 4.8 Grafica de las mejores soluciones encontradas para cada una de las 10 ejecuciones del algoritmo genético del experimento 2.

En conclusión con la implementación descrita se obtuvo la misma solución que por LINGO la cual fue de **\$265,555.54 USD**. El mejor resultado fue alcanzado en la **generación 46**. Para realizar la experimentación se utilizó una computadora con procesador Celeron a 1.6 ghz y un gb en ram (Anexo 6).

Por otra parte nuestro modelo tiene la ventaja de poder ser ejecutado continuamente con diferentes conjuntos de parámetros, generando diferentes alternativas de solución desde sus puntos de origen hasta los centros de distribución.

4.3 Descripción del experimento No. 3. Logconsult es una compañía de consultoría americana comisionada para proponer cambios al sistema de logística de Gélido, una firma mexicana distribuidora de mariscos congelado Gianpaolo Ghiani, et. al (2003). Un aspecto clave es la relocalización del centro de distribución Gélido. Un estudio preliminar del problema condujo a la identificación de cerca de $|V_1| = 30$ lugares potenciales donde los almacenes pueden abrirse o ya existen. En cada lugar varios tipos diferentes de almacenes pueden ser usualmente instalados. Nosotros mostramos como puede estimarse la función de costo $i \in V_1$ de una instalación potencial. Los costos fijos de la instalación incluyen renta, amortización de maquinaria, seguros de locales y maquinaria, y salarios del personal. Que alcanzan \$80,000 por año. Los costos variables están relacionados con el almacenamiento y la manipulación de mercancías. Logconsult ha estimado los costos variables de Gélido en base a datos históricos (ver tabla 4.7).

Tabla4.7. Entradas de demanda (en cientos de kilogramos por año) contra costos variables de instalación (en dólares) como reportan los históricos en el problema Logconsult

Demanda	Costo variable
1000	17579
2500	56350
3500	62208
6000	76403
8000	85491
9000	90237
9500	96251
12000	109429
13500	107355
15000	122432
16000	116816
18000	124736

Los costos variables de instalación (ver figura 4.9) son influenciados por costos de inventario los cuales generalmente aumentan con la raíz cuadrada de la demanda. Esta relación sugiere aproximar la función de costos de la instalación potencial $i \in V_1$ a través de la ecuación (4.3.1), donde $u_i' = 3500$ cientos de kilogramos por año. Los valores de f_i' , f_i'' , g_i' y g_i'' pueden obtenerse por mediante la aplicación de regresión lineal para cada uno de los dos conjuntos de datos disponibles. De esta forma se obtienen las siguientes relaciones:

$$\begin{aligned}
 f_i' &= 80000 + 2252 = 82252 \text{ dólares por año;} \\
 g_i' &= 18.5 \text{ dólares por cientos de kilogramos;} \\
 f_i'' &= 80000 + 54400 = 134400 \text{ dólares por año;} \\
 g_i'' &= 4.1 \text{ dólares por cientos de kilogramos.}
 \end{aligned}$$

$$F_i(u_i) = \begin{cases} f_i'' + g_i'' u_i, & \text{si } u_i > u_i' \\ f_i' + g_i' u_i, & \text{si } 0 < u_i \leq u_i', i \in V_1, \\ 0 & \text{si } u_i = 0 \end{cases} \quad (4.3.1)$$




Figure 4.9 Costos variables de instalación.

El problema puede por lo tanto ser modelado como en (4.3.2), (4.3.3)-(4.3.7), siempre que cada instalación potencial $i \in V_1$ sea remplazada por dos instalaciones prototipo i' e i'' con costos fijos iguales a f_i' y f_i'' , y costos marginales iguales a g_i' y g_i'' , respectivamente.

Donde

$$\sum_{i \in V_1} \sum_{j \in V_2} t_{ij} x_{ij} + \sum_{i \in V_1} f_i y_i \quad (4.3.2)$$

$$t_{ij} = c_{ij} = g_i d_j, \quad i \in V_1, \quad j \in V_2, \quad (4.3.3)$$

Sujeto a:

$$\sum_{i \in V_1} x_{ij} = 1, \quad j \in V_2, \quad (4.3.4)$$

$$\sum_{j \in V_2} d_j x_{ij} \leq q_i y_i, \quad i \in V_1, \quad (4.3.5)$$

$$\sum_{i \in V_1} y_i = p, \quad (4.3.6)$$

$$0 \leq x_{ij} \leq 1, \quad i \in V_1, \quad j \in V_2,$$

$$y_i \in \{0, 1\}, \quad i \in V_1, \quad (4.3.7)$$

$$c_{ij} = c_{ij} d_j, \quad i \in V_1, \quad j \in V_2, \quad (4.3.8)$$

A modo de ejemplo, esta aproximación es aplicada para simplificar la versión del problema donde las instalaciones potenciales están en Linares, Monclova y Monterrey, cada una de ellas

tiene una capacidad de 20,000 cientos de kilogramos por año, y los distritos de ventas están concentrados en cuatro áreas, alrededor de Bustamante, Saltillo, Santa Catarina y Montemorelos respectivamente. La demanda anual equivalen a 6200 cientos de kilogramos para Bustamante, 6600 cientos de kilogramos para Saltillo, 5800 cientos de kilogramos para Santa Catarina y 4400 cientos de kilogramos para Montemorelos. El transporte se lleva a cabo en camiones cuya capacidad es 10 cientos de kilogramos y cuyo costo es igual a \$0.98 por milla.

El problema de localización de Gélido puede ser modelado como una formulación CPL:

Minimizar :

$$\sum_{i \in V_1} \sum_{j \in V_2} t_{ij} x_{ij} + \sum f_i y_i$$

Sujeto a:

$$\sum_{i \in V_1} x_{ij} = 1, \quad j \in V_2,$$

$$\sum_{j \in V_2} d_j x_{ij} \leq q_i y_i, \quad i \in V_1,$$

$$0 \leq x_{ij} \leq 1, \quad i \in V_1, j \in V_2,$$

$$y_i \in \{0, 1\}, \quad i \in V_1,$$

Donde $V_1 = \{Linares', Linares'', Monclova', Monclova'', Monterrey', Monterrey''\}$

$V_2 = \{Bustamante, Saltillo, Santa Catarina, Montemorelos\}$. *Linares' y Linares'' representan dos instalaciones ficticias que pueden ser abiertas en Linares con una capacidad igual a:*

$q' = 3500$ Cientos de kilogramos por año

$q'' = 20000$ Cientos de kilogramos por año

respectivamente ,lo mismo se hace para *Monclova', Monclova'', Monterrey', Monterrey''* $x_{ij}, i \in V_1, j \in V_2$, es una variable de decisión que representa la fracción de la demanda anual de ventas del distrito j satisfechas para la instalación i ; $y_i, i \in V_1$, es una variable de decisión binaria, cuyo valor es igual a 1 si la instalación potencial i es abierta, 0 en cualquier otro caso. Los costos $t_{ij}, i \in V_1, j \in V_2$, reportados en la tabla 3.9, son obtenidos por medio de la ecuación (4.3.3), donde las cantidades $c_{ij}, i \in V_1, j \in V_2$, son a su vez obtenidas con la

ecuación (4.3.8). En otras palabras, $c_{ij} = \tau_{ij} d_j$, con $\tau_{ij} = \lfloor 0.98 \times 2 \times l_{ij} \rfloor / 10$, donde l_{ij} , $i \in V_1$, $j \in V_2$, representa la distancia (en millas) entre la instalación i y el mercado j (ver tabla 4.8).

Tabla 4.8 Distancias (en millas) entre las localizaciones potenciales y los distritos de venta en el Logconsult

	Bustamante	Saltillo	Santa Catarina	Montemorelos
Linares	165.0	132.5	92.7	32.4
Monclova	90.8	118.5	139.0	176.7
Monterrey	84.2	51.6	11.9	49.5

Tabla 4.9 Costo anual (en dólares) $t_{i,j}$, $i \in V_1$, $j \in V_2$, en el problema Logconsult

	Bustamante	Saltillo	Santa Catarina	Montemorelos
Linares´	315208	293502	212681	109342
Linares´´	225928	198462	129161	45982
Monclova´	225040	275392	265315	233786
Monclova´´	135760	180352	181795	170426
Monterrey´	217020	188850	120828	124089
Monterrey´´	127740	93810	37308	60729

La asignación óptima de demanda (tabla 4.10) conduce a un costo igual a 569,383.52 USD por año. Dos instalaciones son localizadas en Linares y Monterrey, con un nivel de actividad igual a 3000 cientos de kilogramos por año y 20000 cientos de kilogramos por año, respectivamente (esto significa que la instalaciones ficticias *Linares´*, *Monterrey´´* son abiertas). Esto fue resuelto por Lingo (Anexo 7).

Tabla 4.10 Fracción de demanda anual de las ventas del distrito $j \in V_2$, satisfechas por la instalación $i \in V_1$, en el problema Logconsult

	Bustamante	Saltillo	Santa Catarina	Montemorelos
<i>Linares´</i>	0.00	0.00	0.00	0.68
<i>Linares´´</i>	0.00	0.00	0.00	0.00
<i>Monclova´</i>	0.00	0.00	0.00	0.00
<i>Monclova´´</i>	0.00	0.00	0.00	0.00
<i>Monterrey´</i>	0.00	0.00	0.00	0.00
<i>Monterrey´´</i>	1.00	1.00	1.00	0.32

4.3.1 Aplicación del método propuesto.

Al igual que el experimento No.1 y 2, y con la finalidad de utilizar los conceptos ya conocidos previamente, presentaremos ahora la propuesta de aplicación de este experimento al problema de optimización desarrollando paso a paso el algoritmo genético:

- De acuerdo a las características del experimento se determinó un cromosoma de 24 bits ya que en el mismo se tienen seis orígenes y cuatro destinos a seleccionar (figura 4.10).
- De los 24 bits seleccionados del cromosoma, cada gen representan un valor de la matriz con valor real.
- El valor (1) representa el origen al posible destino seleccionado de acuerdo al lugar que ocupa en el cromosoma; el valor (0) significa que no existe selección, esto de acuerdo con la tabla 4.9.

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
---	---	---	---	---	---	---	---	---	----	----	----	----	----	----	----	----	----	----	----	----	----	----	----

Figura 4.10 Cromosoma de 24 bits del experimento 3.

La aplicación de los parámetros utilizados en la ejecución del Algoritmo Genético en el experimento No.3 fue ejecutado en MATLAB en veinte ocasiones hasta llegar a encontrar un resultado más cercano al óptimo utilizando la siguiente información:

- Se utilizó un tipo de población binaria, el número de individuos fueron 24, con 100 generaciones como número máximo,
- El método de selección fue por torneo,
- Se empleó una probabilidad de cruce de 0.8,
- El tipo de cruce utilizado fue de un punto,
- La probabilidad de mutación utilizada fue de 0.1,
- El tipo de mutación realizada fue uniforme,
- La función de aptitud es el costo total anual de cada uno de los orígenes a cada uno de los destinos correspondientes.
- El cromosoma óptimo resultante es el mostrado en la figura 4.11.

0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Figura. 4.11 Solución del experimento No.3 ya codificado.

De acuerdo con la posición del valor binario del cromosoma el AG determinó lo siguiente:

- Los bits con valor 1 corresponden a los seleccionados de la matriz 6x4 de la tabla 4.9. Esto es, que la posición 4 del cromosoma corresponde al origen 1 con destino 4. La posición 21 corresponde al origen 6 con destino 1; la posición 22 corresponde al origen 6 con destino 2; la posición 23 corresponde al origen 6 con destino 3 y la posición 24 corresponde al origen 6 con destino 4.
- Los bits con valor 0 significa que no fueron seleccionados.

De acuerdo con la mejor solución encontrada y su interpretación en el cromosoma de solución, los centros de distribución y los puntos de destino son de la siguiente manera:

1. Se localizan dos instalaciones en Linares y Monterrey, con un nivel de actividad igual a 3000 cientos de kilogramos por año y 20000 cientos de kilogramos por año, respectivamente.

Esto significa que la instalaciones ficticias *Linares'* y *Monterrey''* son abiertas).

2. El costo es igual a 569,383.52 USD por año.

CAPITULO 5

ANALISIS DE RESULTADOS.

De los resultado obtenidos de los tres experimentos propuestos, la similitud de los mismos son prácticamente iguales, mientras que el Software Lingo utiliza operadores determinísticos, los algoritmos genéticos utilizan operadores probabilísticos, y requieren de elitismo(o sea retener intacto al mejor individuo de cada generación) para poder converger al óptimo.

En el experimento No. 1(Koster express) el resultado fue de abrir dos centros de distribución. El centro de Distribución1 ubicado en la ciudad de Duncan el cual va a atender a las terminales ubicadas en Altus, Duncan, Ardmore y Lawton. El centro de Distribución 2 ubicado en Stillwater va a atender las terminales ubicadas en Bartlesville, Edmond, Enid, Muskogee, Oklahoma City, Ponca City, Stillwater y Tulsa. El objetivo, con la apertura de estas nuevas terminales fue de reducir los costos de transportación logísticos de ida y vuelta entre dos centros y el resultado fue de 1'081,732.00 USD. Tanto en los resultados que obtiene el modelo determinístico P-med por medio de Lingo como en los obtenidos con el modelo evolutivos propuestos AGs, llegamos a obtener soluciones muy cercanas al óptimo en ambos casos, una de las diferencias es el tiempo de programación.

En el experimento No. 2(Goutte), la solución óptima nos conduce a la apertura de tres plantas de producción. La planta No.1 ubicada en Brossard que atenderá a los mercados ubicados en Brossard y Saint-Julie; La planta No. 2 ubicada en Granby que atenderá a los mercados ubicados en Granby y Sherbrooke; y la tercera Planta ubicada en Valleyfield que atenderá los mercados ubicados en Valleyfield y Verdum. Los resultados arrojaron que los mejores costos logísticos anuales equivalen a 265,283.12 USD.

En el caso del método determinístico es necesario en primera instancia diseñar el modelo matemático que satisfaga las condiciones, así como también establecer las restricciones del problema y posteriormente programar el proceso en el software correspondiente, siendo Lingo v10 el utilizado en el caso presentado. Ahora bien cuando aplicamos AGs, solo se requiere insertar las tablas de valores del problema y establecer las condiciones de la función aptitud siendo la codificación más simple y por ende más rápida con respecto al tiempo de programación, y su correspondiente implementación en Matlab **2008^a**.

En el experimento No. 3(Logconsult), la asignación óptima de demanda conduce a abrir dos instalaciones. La instalación No.1 es ubicada en Linares', que tendrá su distrito de venta en proporción del 68% en Montemorelos. La instalación No.2 es ubicada Monterrey'', y tendrá sus distritos de venta en Bustamante, Saltillo, Santa Catarina y Montemorelos con un 32%.el costo anual es de 569,383.52 USD.

De esta forma se presenta este novedoso medio para llegar a determinar centros de distribucion en la cadena de suministro y que no se había explorado anteriormente para este fin. Una de las ventajas principales de este enfoque es que los resultados obtenidos muestran

que hay otras alternativas de solución en cada iteración y alcanzan una aproximación al valor más óptimo con un costo computacional mucho más bajo. Es importante destacar las diversas ventajas que presenta el uso de técnicas evolutivas para resolver problemas de búsqueda y optimización, ya que tiene simplicidad conceptual, una amplia aplicabilidad, son superiores a las técnicas tradicionales en muchos problemas y un potencial para incorporar conocimiento sobre el dominio y para hibridizarse con otras técnicas de búsqueda/optimización, David E. Goldberg (1987).

CONCLUSIONES .Recomendaciones y trabajo futuro

La experimentación de los Algoritmos Genéticos en la optimización de la localización de centros de distribución, es una alternativa que no se ha aprovechado en todo su potencial, en la literatura investigada, poco o casi nada se reporta para esta aplicación. En la actualidad el desarrollo industrial ha traído como consecuencia la apertura de innumerables centros de distribución con la incertidumbre de conocer realmente si la ubicación en un futuro es la adecuada para poder subsistir en los mercados tan competitivos. Esta situación complica y dificulta la decisión de ubicar algunos tipos de almacenes. Para apoyar este tipo de decisiones se propuso en este trabajo de investigación, la utilización de los Modelos Evolutivos, en especial los algoritmos genéticos. Cabe mencionar que los AGs por ser una técnica de búsqueda basada en la Teoría de la evolución Darwin no aseguran la solución más óptima, esto de acuerdo a los mecanismos de selección los cuales los individuos más aptos son los que sobreviven al adaptarse más fácilmente a los cambios que se producen en el entorno. Sin embargo la aplicación más común de los AGs es en la solución de problemas de optimización donde han demostrado ser muy eficientes y confiables. Los resultados de los tres ejercicios propuestos nos demuestran la valía de los AGs como una alternativa diferente para llegar a soluciones muy cercanas a las óptimas. Los AGs por otra parte definen y explotan de manera más específica los criterios de diversificación e intensificación mediante los operadores de selección, cruce y mutación. Hasta el momento existe en la literatura gran diversidad de trabajos dedicados al estudio y aplicación de los AGs, sin embargo se han limitado en su aplicación a la optimización en la cadena de suministro de los centros de distribución minimizando la importancia de su aplicación de esta herramienta para el tipo de problemas de localización de centros de distribución.

Los AGs suele considerarse como una técnica que es buena para encontrar rápidamente regiones prometedoras del espacio de búsqueda, sin embargo para realizar verdaderamente optimización, se ha demostrado que en muchas instancias los híbridos de un AG con otra técnica parecen dar mejores resultados.

Kenneth De Jong (1993) ha argumentado elocuentemente que contrario a lo que se cree, los AGs no son optimizadores, sino más bien “satisfactores de metas” o decisiones secuenciales que pueden modificarse para actuar como optimizadores de funciones.

Para la realización de trabajos futuros se propone la utilización de un híbrido entre los algoritmos evolutivos con otras técnicas para incrementar sustancialmente su eficiencia de búsqueda, los algoritmos evolutivos obtenidos mediante la hibridación con otras técnicas de búsqueda local son denominados algoritmos meméticos.

Las técnicas de búsqueda local y algoritmos evolutivos, presentan un especial énfasis en uno de estos componentes de la búsqueda. Las principales diferencias, que suponen tanto ventajas como desventajas, entre los métodos de búsqueda local y algoritmos evolutivos se deben a que los primeros potencian en su búsqueda la explotación de las mejores soluciones, ya que las nuevas soluciones son variaciones de la mejor encontrada hasta el momento, mientras que los algoritmos evolutivos potencian más el factor de exploración, con las nuevas soluciones, al generarse mediante combinación de más de un individuo, presentan mayor diversidad respecto a cualquiera de sus progenitores. Por tanto, el proceso de exploración de vecinos de la búsqueda local permite obtener soluciones precisas de forma muy eficiente, mediante una alta explotación de las soluciones encontradas; mientras que los algoritmos evolutivos como los algoritmos genéticos, al mantener simultáneamente una población de múltiples soluciones, realizan una exploración simultánea de varias regiones, pudiendo obtener una amplia búsqueda en dominios complejos

REFERENCIAS

- Albernathy, W.J. & Hershey, J.C., 1972. A Spatial-Allocation Model for Regional Health-Services Planning. *Operations Research*, 20(3), pp.629-42.
- Barricelli, Nils Aall (1954), *Evoluzione de los di de Esempi numerici di processi*, Methodos, pp. 45-68.
- Bartholdi III JJ and GueKR2000 Reducing labour costs in anLTLcrossdocking terminal. *Operations Research* 48, 823–832.
- Birge, J.R. & Malyshko, V., 1985. Methods for a network design problem in solar power systems. *Computers & Operational Research*, 12(1), pp.125-38.
- Cohon, R.L. et al., 1980. Application of a Multiobjective Location Model to Power Plant Siting in a Six State Region of the U.s. *Computers and Operations Research*, 7, pp.107-24.
- Colin B. Reeves, editor Modern Heuristic Techniques for Combinatorial problems, John Wiley & Sonds, Great Britain, 1993.
- Current, J.D.M.S.D., 2002. Facility Location: Applications and Theory Discrete network location models models. In: Drezner, Z., Hamacher, H. (Eds.). *Springer-Verlag, Berlin*, p.81–118.
- Current J., Daskin M. y Schilling D. (2004). Discrete Network Location Models. En Zvi Drezner Horst W. Hamacher (Eds). *Facility Location: Application and Theory*, pp. 81-108. Berlin, Alemania.
- Chase R., Jacobs R. y Aquilano N. (2005). *Operations Management for Competitive Advantage*. McGraw-Hill/Irwin. 11 edition.
- Church L. Richard, Cobra: A new Formulation of the Clasic P-Median Location Problem, *Annals Operation Research*, p-103.
- David B.Fogel. *Evolutionary Computation. Toward a New Philosophy of Machine Intelligence*. The Institute of Electronic and Electronic Engineers, New York, 1995.
- David E. Goldberg. *Genetic Algorithms In search Optimization Machine learning* 1990.
- David E. Goldberg. Simple Genetic Algorithms and the Minimal Deceptive Problem. In Lawrence Davis, editor, *Genetic Algorithms and Simulated Annealing*. Morgan Kaufmann Publishers, San Mateo, California, 1987
- Dezner, Z., 1988. Location Strategies For Satellites Orbita. *Naval Research Logistics*, 35,pp.503-12.
- Diccionario (DRAE) para el término “estocástico”.
- Efroymsen, M. and T. Ray. (1966). “A Branch and Bound Algorithm for Plant Location. “*Operations Research* 14,361-368.
- E. Nelson, *Quantum Fluctuations*, Princeton University Press, Princeton, 1985.
- Flynn, J. & Ratick, S.,1988. A Multiobjective Hierarchical Covering Model For The Essential Air Services Program. *Transportation science*, 22, pp.139-47.
- Ghiandi, Giancarlo, Introduction to Logistic Systems Planning and Control, Jhon Wiley and Sons, Ltd, England 2004, P.81-83. Nation Online Project.

Gianpaolo Ghiani, Gilbert Laporte and Roberto Musmanno .Introduction to Logistics: *Systems Planning and Control*, John Wiley and Sons 2004 pp.81-90.

Gleason, J., 1975. A Set Covering Approach To Bus Stop Location. *Omega*, 3, pp.605-08.

Goldberg, David E. "Genetic Algorithms in Search, Optimization, and Machine Learning", Addison-Wesley Publishing Company, 1989, 412 p.

Hakimi, S.L.(1964). "Optimum Location of Switching Centers and the Absolute Centers and Medians of a Grap." *Operations Research* 12,450-459.

Hakimi, S.L.(1965). "Optimum Distribution of Switching Centers and Some Graph-Related Theoretic Problems." *Operations Research* 13,462-475.

Hans-Paul Schwefel. *Numerische Optimierung von Computer-Modellen mittels der Evolutionsstrategie*. Birkhäuser, Basel, Alemania, 1977.

Hans-Paul Schwefel. *Numerical Optimization of Computer Models*. Wiley, Chichester, UK, 1981.

Higgins, A., Kozan, E. & Ferreira, L., 1977. Modeling The Number And Location Of Sidings On A Single Line Railway. *Computers and operations research*, 24, pp.209-20.

Ingo Rechenberg. *Evolutions strategie: Optimierung technischer Systemenach Prinzipien der biologischen Evolution*. Frommann-Holzboog, Stuttgart, Alemania, 1973.

Introduction to Logistics Systems Planning and Control Gianpaolo Ghiani *Department of Innovation Engineering, University of Lecce, Italy*

J. David Schaffer and Amy Morishima. An Adaptive Crossover Distribution Mechanism for Genetic algorithms. In John J. Grefenstette, editor. *Genetic Algorithms and their Applications: Proceedings of the Second International Conference on Genetic Algorithms*, page36-40. Lawrence Erlbaum Associates, Hillsdale, New York, July 1987.

J. H. Holland. Outline for a logical theory of adaptive systems. *Journal of the ACM*, 3:297–314, 1962.384.

J. H. Holland. *Adaptation in Natural and Artificial Systems*.University of Michigan Press, Ann Arbor, MI, 1975

Hodgson, M.J., Rosing, K.E. & Zhang, J., 1996. Locating Vehicle Inspection Stations to Protect a Transportation Network. *Geographical Analysis*, 28, pp.299-314.

Hogan, K., 1990. Reducing Errors in Rainfall Estimates through Rain Gauge Location. *Geographical Analysis*, 22, pp.33-49.

J. Joines, M.A.Gokce,D Gupta, R. King and M. Kay (2002). "Supply Chain Multi-Objetive Simulation Optimization," *Proceedings of the 2002 Winter Simulation Conference*, pp. 1306-1314.

Kaufmann, A. y Faure, R. "Invitación a la Investigación de Operaciones", Segunda Edición, CECSA, México,1977, 311 p.

Kenneth A. De Jong, William M. Spears and Diana F. Gordon. Using Markov Chains to Analyze GAFOs. In L. Darrell Whitley and Michael D. Vose, editors, *Foundations of Genetic Algorithms* 3, pages 115-137. Morgan Kaufmann Publishers, San Mateo, California, 1994.

Koza, J.R .Hierarchical genetic algorithms operating on populations of computer programs. In N.S. Sridharan, editor, *Proceedings of the 11th International Joint Conference on Artificial Intelligence*, pages 768-774, Morgan Kaufman, San Mateo, California, 1989

- Koza, J.R. (1992), *Programación genética: Al programar de computadoras por medio de la selección natural*, Prensa del MIT
- Koza, J.R. (1994), *II de programación genético: Descubrimiento automático de programas reutilizables*, Prensa del MIT .
- Lawrence Davis. Adapting Operator Probabilities In Genetic Algorithms. In J. David Schafer, editor, *Proceedings of the Third International Conference on Genetic Algorithms*, page 61-69, San Mateo, California, 1989. Morgan Kaufmann Publishers.
- Lawrence J. Fogel. *Artificial Intelligence through Simulated Evolution*, John Wiley, New York, 1966.
- Lawrence J. Fogel. *Artificial Intelligence through Simulated Evolution. Forty Years of Evolutionary Programming*. John Wiley and Sons, Inc., New York, 1999.
- Logística, administración de la cadena de suministro (2004) Ronald H. Ballou Pearson/Prentice Hall ISBN: 970260 .Modeling the Supply Chain (2000) by Jeremy F. Shapiro Publisher: Brooks/Cole ISBN: 053437363 ISBN-13: 9780534373634
- M. Kac & J. Logan, en *Fluctuation Phenomena*, eds. E.W. Montroll & J.L. Lebowitz, North-Holland, Ámsterdam, 1976.
- Moore, G.C. & ReVelle, C., 1982. The hierarchical service location problem. *Management Science*, 28, pp.775-80.
- Nichal Lynn Cramer. A Representation for the Adaptive Generation of Simple Sequential Programs. In John J. Grefenstette, editor, *Proceedings of the First International Conference on Genetic Algorithms and Their Applications*, pages 183-187. Lawrence Erlbaum Associates, Hillsdale, New Jersey, 1985.
- ReVelle, C.S.and Swain. (1970).“Central Facilities Location.” *Geographical Analysis* 2, 30-42.
- ReVelle, C. (1987) “Urban Public Facility Location.” In E.S. Mills(ed.) *Handbook of Regional and Urban Economics*, Vol. 2, Amsterdam: Elsevier Science.
- Rosing, K.E. ReVelle, and Rosing-Vogelaar. (1979). “The p -Median and its Linear Programming Relaxation: An Approach to Large Problems.” *Journal of the Operational Research Society* 30,815-822.
- Sinha A. (2004). Location, location, location and location: Facility location incorporating demand uncertainty, logistic network design, product heterogeneity and competition. Thesis. Tepper scholl of business, Carnegie Mellon University.
- Smith, R.E.; Goldberg, D.E., and Erickson, J.A., "SGA-C : A C language Implementation of a Simple Genetic Algorithm", TCGA Report No. 91002, The Clearinghouse for Genetic Algorithms, The University of Alabama, May 14, 1991.
- Sridharan R., The Capacitated Plan Location Problem, *European Journal of Operational Research* 87 (1995) pp-203 – 205.
- Vallhonrat J., Vallhonrat Bou J. y Corominas A. (1991). Localización, distribución en planta y manutención. Productica. Barcelona, España.
- T.H. Truong and F. Azadivar (2003). “Simulation Based Optimization for Supply Chain Configuration Design,” *Proceedings of the 2003 Winter Simulation Conference*, pp. 1268-1275.

Anexo 1. Código fuente del ejercicio de inversión.

```
% function merito = inversion(cromosoma)
% valores = decodificaCromosoma(cromosoma);
% beneficio = beneficit(valores);
% merito = (500 * abs((sum(valores) - 10)) + 1) / (sum(beneficio) + ...
% 500 * abs(sum(valores) - 10) + 1);
%
% function valor = decodificaCromosoma(cromosoma)
% valor = zeros(4,1);
% for i = 1:4
%   cromosomaTmp = cromosoma((i-1)*4+1:i*4);
%   cadena = mat2str(cromosomaTmp);
%   valor(i) = min(bin2dec(cadena(2:end-1)),10);
% end
%
% function beneficio = beneficit(valores)
% beneficio = zeros(size(valores));
% beneficiosTabla = [0 0 0 0
% 0.28 0.25 0.15 0.20
% 0.45 0.41 0.25 0.33
% 0.65 0.55 0.40 0.42
% 0.78 0.65 0.50 0.48
% 0.90 0.75 0.62 0.53
% 1.02 0.80 0.73 0.56
% 1.13 0.85 0.82 0.58
% 1.23 0.88 0.90 0.60
% 1.32 0.90 0.96 0.60
% 1.38 0.90 1.00 0.60];
% for i = 1:length(valores)
%   beneficio(i) = beneficiosTabla(valores(i)+1,i);
% end
```

Anexo 2

Experimento 1 de P-mediana por software Lingo

Minz=

251.304X12 + 431.864X13 + 130.536X14 + 227.772X15 + 308.136X16 + 80.126X17 + 405.816X18 + 208.828X19 + 326.6X110
+ 309616X111 + 307.04X112 + 251.304X21 + 367.98X23 + 112.332X24 + 166.5X25 + 294.52X26 + 171.384X27 + 340.992X28
+ 148.74X29 + 299.56X210 + 240.68X211 + 302.808X212 + 431.84X31 + 367.928X32 + 342.62X34 + 216.08X35 + 195.952X36
+ 353.75X37 + 136.456X38 + 224.072X39 + 103.896X310 + 170.2X311 + 67.488X312 + 130.58X41 + 112.332X42 + 342.62X43
+ 138.38X45 + 203.5X46 + 50.468X47 + 315.98X48 + 119.732X49 + 273.504X410 + 215.044X411 + 277.944X412 +
227.772X51 + 166.5X52 + 216.08X53 + 138.38X54 + 131.424X56 + 140.036X57 + 215.636X58 + 21.4312X59 + 136.012X510 +
78.44X511 + 151.256X512 + 308.136X61 + 294.52X62 + 195.952X63 + 203.5X64 + 131.424X65 + 214.6X67 + 246.272X68 +
129.648X69 + 95.46X610 + 97.384X611 + 175.232X612 + 80.216X71 + 171.384X72 + 353.276X73 + 50.468X74 + 149.036X75
+ 214.6X76 + 326.488X78 + 130.24X79 + 284.012X710 + 225.7X711 + 288.452X712 + 405.816X81 + 340.992X82 +
136.456X83 + 315.98X84 + 215.636X85 + 246.272X86 + 326.488X87 + 207.792X89 + 210.9X810 + 176.416X11 + 71.188X812
+ 208.828X91 + 148.74X92 + 224.072 + X93 + 119.732X94 + 21.312X95 + 129.648X96 + 130.24X97 + 207.792X98 +
154.956X910 + 98.568X911 + 159.248X912 + 362.6X101 + 299.256X102 + 103.896X103 + 273.504X104 + 136.012X105
+ 95.46X106 + 284.012X107 + 210.9X108 + 154.956X109 + 62.012X1011 + 142.82X1012 + 309.616X1101 + 240.648X1102 +
170.2X1103 + 215.044X1104 + 78.44X1105 + 97.384X1106 + 225.7X1107 + 176.416X1108 + 98.568X1109 + 62.012X1110 +
105.376X1112 + 367.04X1201 + 302.808X1202 + 67.488X1203 + 277.944X1204 +
152.256X1205 + 175.232X1206 + 288.452X1207 + 71.188X1208 + 159.248X1209 + 142.82X1210 + 105.376X1211;

Sujeto a:

X11 + X12 + X13 + X14 + X15 + X16 + X17 + X18 + X19 + X110 + X111 + X112 = 1;
X21 + X22 + X23 + X24 + X25 + X26 + X27 + X28 + X29 + X210 + X211 + X212 = 1;
X31 + X32 + X33 + X34 + X35 + X36 + X37 + X38 + X39 + X310 + X311 + X312 = 1;
X41 + X42 + X43 + X44 + X45 + X46 + X47 + X48 + X49 + X410 + X411 + X412 = 1;
X51 + X52 + X53 + X54 + X55 + X56 + X57 + X58 + X59 + X510 + X511 + X512 = 1;
X61 + X62 + X63 + X64 + X65 + X66 + X67 + X68 + X69 + X610 + X611 + X612 = 1;
X71 + X72 + X73 + X74 + X75 + X76 + X77 + X78 + X79 + X710 + X711 + X712 = 1;
X81 + X82 + X83 + X84 + X85 + X86 + X87 + X88 + X89 + X810 + X811 + X812 = 1;
X91 + X92 + X93 + X94 + X95 + X96 + X97 + X98 + X99 + X910 + X911 + X912 = 1;
X101 + X102 + X103 + X104 + X105 + X106 + X107 + X108 + X109 + X1010 + X1011 + X1012 = 1;
X1101 + X1102 + X1103 + X1104 + X1105 + X1106 + X1107 + X1108 + X1109 + X1110 + X1111 + X1112 = 1;
X1201 + X1202 + X1203 + X1204 + X1205 + X1206 + X1207 + X1208 + X1209 + X1210 + X1211 + X1212 = 1;
X11 + X22 + X33 + X44 + X55 + X66 + X77 + X88 + X99 + X1010 + X1111 + X1212 = 2;

X12 ≤ X22;
X13 ≤ X33;
X14 ≤ X44;
X15 ≤ X55;
X16 ≤ X66;
X17 ≤ X77;
X18 ≤ X88;
X19 ≤ X99;
X110 ≤ X1010;

. . . .
. . . .
. . . .
. . . .

X1201 ≤ X11;
X1202 ≤ X22;
X1203 ≤ X33;
X1204 ≤ X44;
X1205 ≤ X55;
X1206 ≤ X66;
X1207 ≤ X77;
X1208 ≤ X88;

X1209 ≤ X99;
X1210 ≤ X1010;
X1211 ≤ X1111;

@BIN(X11); @BIN(X12); @BIN(X13); @BIN(X14); @BIN(X15); @BIN(X16); @BIN(X17); @BIN(X18); @BIN(X19); @BIN(X110);
@BIN(X111); @BIN(X112); @BIN(X11); @BIN(X1205); @BIN(X1206);
@BIN(X1207); @BIN(X1208); @BIN(X1209); @BIN(X1210); @BIN(X1211); @BIN(X1212);
END

```

LINGO - [LINGO Model - koster-1-Cobra-p]
File Edit LINGO Window Help

Min = 251.304 * x12 + 431.864 * x13 + 130.536 * x14 + 227.772 * x15 + 308.136 * x16 + 80.216 * x17 + 405.816 * x18 + 208.828 * x19 + 362.6 * x110 + 309.616 * x111 + 367.04 * x112 +
251.304 * x21 + 367.928 * x23 + 112.332 * x24 + 166.5 * x25 + 294.52 * x26 + 171.384 * x27 + 340.992 * x28 + 148.74 * x29 + 299.256 * x210 + 240.648 * x211 + 302.808 * x212 + 431.864 *
x31 + 367.928 * x32 + 342.62 * x34 + 216.08 * x35 + 195.952 * x36 + 353.276 * x37 + 136.456 * x38 + 224.072 * x39 + 103.896 * x310 + 170.2 * x311 + 67.488 * x312 + 130.536 * x41 +
112.332 * x42 + 342.62 * x43 + 138.38 * x45 + 203.5 * x46 + 50.468 * x47 + 315.98 * x48 + 119.732 * x49 + 273.504 * x410 + 215.044 * x411 + 277.944 * x412 + 227.772 * x51 + 166.5 * x52 +
216.08 * x53 + 138.38 * x54 + 131.424 * x55 + 149.036 * x57 + 215.636 * x58 + 21.312 * x59 + 136.012 * x510 + 78.44 * x511 + 151.256 * x512 + 308.136 * x61 + 294.52 * x62 + 195.952 * x63
+ 203.5 * x64 + 131.424 * x65 + 214.6 * x67 + 246.272 * x68 + 129.648 * x69 + 95.46 * x610 + 97.384 * x611 + 175.232 * x612 + 80.216 * x71 + 171.384 * x72 + 353.276 * x73 + 50.468 * x74 +
149.036 * x75 + 214.6 * x76 + 326.488 * x78 + 130.24 * x79 + 284.012 * x710 + 225.7 * x711 + 288.452 * x712 + 405.816 * x81 + 340.992 * x82 + 136.456 * x83 + 315.98 * x84 + 215.636 * x85
+ 246.272 * x86 + 326.488 * x87 + 207.792 * x89 + 210.9 * x810 + 176.416 * x811 + 71.188 * x812 + 208.828 * x91 + 148.74 * x92 + 224.072 * x93 + 119.732 * x94 + 21.312 * x95 + 129.648 *
x96 + 130.24 * x97 + 207.792 * x98 + 154.956 * x910 + 98.568 * x911 + 159.248 * x912 + 362.6 * x101 + 299.256 * x102 + 103.896 * x103 + 273.504 * x104 + 136.012 * x105 + 95.46 * x106 +
284.012 * x107 + 210.9 * x108 + 154.956 * x109 + 62.012 * x1011 + 142.82 * x1012 + 309.616 * x1101 + 240.648 * x1102 + 170.2 * x1103 + 215.044 * x1104 + 78.44 * x1105 + 97.384 * x1106
+ 225.7 * x1107 + 176.416 * x1108 + 98.568 * x1109 + 62.012 * x1110 + 105.376 * x1112 + 367.04 * x1201 + 302.808 * x1202 + 67.488 * x1203 + 277.944 * x1204 + 151.256 * x1205 + 175.232
* x1206 + 288.452 * x1207 + 71.188 * x1208 + 159.248 * x1209 + 142.82 * x1210 + 105.376 * x1211;

!Sujeto a;
x11 + x12 + x13 + x14 + x15 + x16 + x17 + x18 + x19 + x110 + x111 + x112 = 1;
x21 + x22 + x23 + x24 + x25 + x26 + x27 + x28 + x29 + x210 + x211 + x212 = 1;
x31 + x32 + x33 + x34 + x35 + x36 + x37 + x38 + x39 + x310 + x311 + x312 = 1;
x41 + x42 + x43 + x44 + x45 + x46 + x47 + x48 + x49 + x410 + x411 + x412 = 1;
x51 + x52 + x53 + x54 + x55 + x56 + x57 + x58 + x59 + x510 + x511 + x512 = 1;
x61 + x62 + x63 + x64 + x65 + x66 + x67 + x68 + x69 + x610 + x611 + x612 = 1;
x71 + x72 + x73 + x74 + x75 + x76 + x77 + x78 + x79 + x710 + x711 + x712 = 1;
x81 + x82 + x83 + x84 + x85 + x86 + x87 + x88 + x89 + x810 + x811 + x812 = 1;
x91 + x92 + x93 + x94 + x95 + x96 + x97 + x98 + x99 + x910 + x911 + x912 = 1;
x101 + x102 + x103 + x104 + x105 + x106 + x107 + x108 + x109 + x1010 + x1011 + x1012 = 1;
x1101 + x1102 + x1103 + x1104 + x1105 + x1106 + x1107 + x1108 + x1109 + x1110 + x1111 + x1112 = 1;
x1201 + x1202 + x1203 + x1204 + x1205 + x1206 + x1207 + x1208 + x1209 + x1210 + x1211 + x1212 = 1;
x11 + x22 + x33 + x44 + x55 + x66 + x77 + x88 + x99 + x1010 + x1111 + x1212 = 2;

!Ubicaciones;
x12 <= x22;
x13 <= x33;
x14 <= x44;
x15 <= x55;
x16 <= x66;
x17 <= x77;
x18 <= x88;

```

Continuación.

```
LINGO - [LINGO Model - koster-1-Cobra-p]
File Edit LINGO Window Help

x1205<=x55;
x1206<=x66;
x1207<=x77;
x1208<=x88;
x1209<=x99;
x1210<=x1010;
x1211<=x1111;

!Convierte a Binario;
@BIN(x11); @BIN(x12); @BIN(x13); @BIN(x14); @BIN(x15); @BIN(x16); @BIN(x17); @BIN(x18); @BIN(x19); @BIN(x110); @BIN(x111);
@BIN(x112);
@BIN(x21); @BIN(x22); @BIN(x23); @BIN(x24); @BIN(x25); @BIN(x26); @BIN(x27); @BIN(x28); @BIN(x29); @BIN(x210); @BIN(x211);
@BIN(x212);
@BIN(x31); @BIN(x32); @BIN(x33); @BIN(x34); @BIN(x35); @BIN(x36); @BIN(x37); @BIN(x38); @BIN(x39); @BIN(x310); @BIN(x311);
@BIN(x312);
@BIN(x41); @BIN(x42); @BIN(x43); @BIN(x44); @BIN(x45); @BIN(x46); @BIN(x47); @BIN(x48); @BIN(x49); @BIN(x410); @BIN(x411);
@BIN(x412);
@BIN(x51); @BIN(x52); @BIN(x53); @BIN(x54); @BIN(x55); @BIN(x56); @BIN(x57); @BIN(x58); @BIN(x59); @BIN(x510); @BIN(x511);
@BIN(x512);
@BIN(x61); @BIN(x62); @BIN(x63); @BIN(x64); @BIN(x65); @BIN(x66); @BIN(x67); @BIN(x68); @BIN(x69); @BIN(x610); @BIN(x611);
@BIN(x612);
@BIN(x71); @BIN(x72); @BIN(x73); @BIN(x74); @BIN(x75); @BIN(x76); @BIN(x77); @BIN(x78); @BIN(x79); @BIN(x710); @BIN(x711);
@BIN(x712);
@BIN(x81); @BIN(x82); @BIN(x83); @BIN(x84); @BIN(x85); @BIN(x86); @BIN(x87); @BIN(x88); @BIN(x89); @BIN(x810); @BIN(x811);
@BIN(x812);
@BIN(x91); @BIN(x92); @BIN(x93); @BIN(x94); @BIN(x95); @BIN(x96); @BIN(x97); @BIN(x98); @BIN(x99); @BIN(x910); @BIN(x911);
@BIN(x912);
@BIN(x101); @BIN(x102); @BIN(x103); @BIN(x104); @BIN(x105); @BIN(x016); @BIN(x107); @BIN(x108); @BIN(x109); @BIN(x1010);
@BIN(x1011); @BIN(x1012);
@BIN(x1101); @BIN(x1102); @BIN(x1103); @BIN(x1104); @BIN(x1105); @BIN(x1106); @BIN(x1107); @BIN(x1108); @BIN(x1109); @BIN
(x1110); @BIN(x1111); @BIN(x1112);
@BIN(x1201); @BIN(x1202); @BIN(x1203); @BIN(x1204); @BIN(x1205); @BIN(x1206); @BIN(x1207); @BIN(x1208); @BIN(x1209); @BIN
(x1210); @BIN(x1211); @BIN(x1212);
end

Ready MOD Ln 188, Col 9 8:00 pm
```

Anexo 3

Experimento 1 de P mediana formulado por algoritmos genéticos con dos centros de distribución.

```
function costo = Pmed(cromosoma)
a = [0,169.8,291.8,88.2,153.9,208.2,54.2,274.2,141.1,245,209.2,248
    169.8,0,248.6,75.9,112.5,199,115.8,230.4,100.5,202.2,162.6,204.6
    291.8,248.6,0,231.5,146,132.4,238.7,92.2,151.4,70.2,115,45.6
    88.2,75.9,231.5,0,93.5,137.5,34.1,213.5,80.9,184.8,145.3,187.8
    153.9,112.5,146,93.5,0,88.8,100.7,145.7,14.4,91.9,53,102.2
    208.2,199,132.4,137.5,88.8,0,145,166.4,87.6,64.5,65.8,118.4
    54.2,115.8,238.7,34.1,100.7,145,0,220.6,88,191.9,152.5,194.9
    274.2,230.4,92.2,213.5,145.7,166.4,220.6,0,140.4,142.5,119.2,48.1
    141.1,100.5,151.4,80.9,14.4,87.6,88,140.4,0,104.7,66.6,107.6
    245,202.2,70.2,184.8,91.9,64.5,191.9,142.5,104.7,0,41.9,96.5
    209.2,162.6,115,145.3,53,65.8,152.5,119.2,66.6,41.9,0,71.2
    248,204.6,45.6,187.8,102.2,118.4,194.9,48.1,107.6,96.5,71.2,0];
a = 2 * 0.74 * a;
origen1 = cromosoma(1:4) + 2 - 2;
origen2 = cromosoma(5:8) + 2 - 2;

origen1c = mat2str(origen1);
origen2c = mat2str(origen2);
cadena1 = origen1c(2:end-1);
cadena2 = origen2c(2:end-1);
origen1 = max(min(bin2dec(cadena1),12),1);
origen2 = max(min(bin2dec(cadena2),12),1);

if (origen1 ~= origen2)
    destino1 = cromosoma(9:20);
    destino2 = xor(destino1,ones(1,12));
    destino1 =logical(destino1);
    destino2 =logical(destino2);
    origen1f = zeros(12,1);
    origen1f(origen1) = 1;
    origen1f = logical(origen1f);
    origen2f = zeros(12,1);
    origen2f(origen2) = 1;
    origen2f = logical(origen2f);
    costo1 = sum(a(origen1f,destino1));
    costo2 = sum(a(origen2f,destino2));
    costo = costo1 + costo2;
else
    costo = inf;
end
```

Anexo 4

Experimento 1 de P mediana formulado por algoritmos genéticos con tres centros de distribución.

```
function costo = Pmed(cromosoma)
% Tabla con las distancias entre los diferentes lugares
a = [0,169.8,291.8,88.2,153.9,208.2,54.2,274.2,141.1,245,209.2,248
169.8,0,248.6,75.9,112.5,199,115.8,230.4,100.5,202.2,162.6,204.6
291.8,248.6,0,231.5,146,132.4,238.7,92.2,151.4,70.2,115,45.6
88.2,75.9,231.5,0,93.5,137.5,34.1,213.5,80.9,184.8,145.3,187.8
153.9,112.5,146,93.5,0,88.8,100.7,145.7,14.4,91.9,53,102.2
208.2,199,132.4,137.5,88.8,0,145,166.4,87.6,64.5,65.8,118.4
54.2,115.8,238.7,34.1,100.7,145,0,220.6,88,191.9,152.5,194.9
274.2,230.4,92.2,213.5,145.7,166.4,220.6,0,140.4,142.5,119.2,48.1
141.1,100.5,151.4,80.9,14.4,87.6,88,140.4,0,104.7,66.6,107.6
245,202.2,70.2,184.8,91.9,64.5,191.9,142.5,104.7,0,41.9,96.5
209.2,162.6,115,145.3,53,65.8,152.5,119.2,66.6,41.9,0,71.2
248,204.6,45.6,187.8,102.2,118.4,194.9,48.1,107.6,96.5,71.2,0];
% Se multiplica cada distancia por el costo de transporte
a = 2 * 0.74 * a;
% Se definen tres orígenes, los proveedores. Para cada proveedor
% se tienen 4 bits, el primero los bits del 1 al 4; el segundo
% los bits del 5 al 8; el tercero del 9 al 12.
origen1 = cromosoma(1:4)+ 0;
origen2 = cromosoma(5:8)+ 0;
origen3 = cromosoma(9:12)+ 0;
destino1 = cromosoma(13:24)+ 0;
destino2 = cromosoma(25:36)+ 0;
destino3 = cromosoma(37:48)+ 0;
% Se convierte el valor binario a su correspondiente valor decimal.
% La instrucción mat2str permite convertir el vector de bits a una cadena.
% La instrucción bin2dec permite convertir una cadena de bits a su valor
decimal.
% La instrucción min obtiene el mínimo de dos valores, en este caso el
resultado
% de la conversión binario-decimal con el 12, porque son dos posibles
lugares.
% La instrucción max permite obtener el máximo de dos valores, en este
caso el resultado
% de la operación mínimo con el número 0.
origen1c = mat2str(origen1);
origen2c = mat2str(origen2);
origen3c = mat2str(origen3);

origen1 = max(min(bin2dec(origen1c(2:end-1)),12),1);
origen2 = max(min(bin2dec(origen2c(2:end-1)),12),1);
origen3 = max(min(bin2dec(origen3c(2:end-1)),12),1);
valorand = and(and(destino1,destino2),destino3);
valorxor = xor(xor(destino1,destino2),destino3);
fprintf('valorMedio = %f, origen1 = %d, origen2 =%d, origen3 =
%d\n',valorMedio,origen1,origen2,origen3);
% Comparamos que no se hayan seleccionado el mismo origen
if (origen1 ~= origen2 && origen1 ~=origen3 && origen2 ~=origen3 && ...
    mean(valorand) == 0 && mean(valorxor) == 1)
    disp('destinos');
    disp(destino1);
```

```

        disp(destino2);
        disp(destino3);
        % Si no es el mismo origen, definimos nuestro destino1 con los bits en
las posiciones
        % de la 9 a la posición 20, donde un valor de uno representa los
destinos seleccionados.
        % destino1 = cromosoma(9:20);
        % El destino2 es definido como el negado de los bits en el destino uno.
        % destino2 = xor(destino1,ones(1,12));
        % Transformamos los valores de destino en valores lógicos para poder
usarlos directamente en
        % las matrices.
        destino1 = logical(destino1);
        destino2 = logical(destino2);
        destino3 = logical(destino3);

        % Transformamos los valores de origen en valores lógicos para usarlos
en las matrices.
        origen1f = zeros(12,1);
        origen1f(origen1) = 1;
        origen1f = logical(origen1f);
        origen2f = zeros(12,1);
        origen2f(origen2) = 1;
        origen2f = logical(origen2f);
        origen3f = zeros(12,1);
        origen3f(origen3) = 1;
        origen3f = logical(origen3f);

        % El costo de cada origen a los diferentes destino es la suma de los
costos de transporte para cada destino.
        costo1 = sum(a(origen1f,destino1));
        costo2 = sum(a(origen2f,destino2));
        costo3 = sum(a(origen3f,destino3));

        % El costo total es la suma de los costos en cada origen.
        costo = costo1 + costo2 + costo3;
else
        % Si el origen es el mismo se castiga con un costo infinito.
        costo = inf;
end

```

Anexo 5

Experimento 2. Problema Goutte solución software Lingo.

```
MODEL:
SETS:
    FUENTES /1..10/:CAPACIDAD, COSTOSFIJOS,Y;
    DESTINOS /1..6/:DEMANDA;
    MATRIZ (FUENTES,DESTINOS):COSTOSTRANSPORTE, X;
ENDSETS
DATA:
    DEMANDA = 14000, 10000, 8000, 12000, 10000, 9000;
    CAPACIDAD = 22000, 24000, 28000, 30000, 20000, 26000, 28000, 30000, 20000,
    21000;
    COSTOSFIJOS = 81400, 83800, 88600, 91000, 79000, 86200, 88600, 91000,
    79000, 80200;
    COSTOSTRANSPORTE =
    0,          9337.37,      2984.8,      20514.58,      8903.08,      1296.97,
    13072.32,   0,          6964.54,      11370.67,      17727.19,      9238.67,
    3565.18,    11390.41,    4627.23,      22978.23,      5823.52,      1296.97,
    9396.6,     13897.49,    5195.76,      27550.19,      11410.15,      4992.43,
    2321.51,    10482.34,    2747.91,      21888.54,      8251.63,      1030.47,
    5223.4,     8705.67,      0,          20348.76,      11587.82,      4210.7,
    23933.68,   9475.56,      13565.84,    0,          25505.04,      16220.97,
    8208.2,     13068.37,    4532.48,      26531.56,      10640.26,      4299.53,
    12464.31,   17727.19,    9270.25,      30606.05,      0,          7000.07,
    2017.5,     10265.19,    3742.85,      21627.96,      7777.85,      0;
ENDDATA
MIN = @SUM (MATRIZ (J,I) :
    COSTOSTRANSPORTE (J,I) *X (J,I) ) +@SUM (FUENTES (I) :COSTOSFIJOS (I) *Y (I) ) ;
@FOR (DESTINOS (I) :@SUM (FUENTES (J) : X (J,I) )=1;) ;
@FOR (FUENTES (J) :@SUM (DESTINOS (I) :DEMANDA (I) * X (J,I) ) <=
    CAPACIDAD (J) *Y (J) ) ;
@FOR (FUENTES (J) :@FOR (DESTINOS (I) :X (J,I) >=0) ) ;
@FOR (FUENTES (J) :@FOR (DESTINOS (I) :X (J,I) <=1) ) ;
@FOR (FUENTES (J) : @BIN (Y (J) ) ) ;
END
```

Global optimal solution found.

Objective value:	265283.1
Extended solver steps:	374
Total solver iterations:	9887

Anexo 6

Experimento 2. Problema Goutte formulado por algoritmos genéticos.

```
function costo = pgoutemod(cromosoma)

a = [0,9337.37, 2984.8, 20514.58, 8903.08,. . ., 3742.85, 21627.96,
7777.85, 0];

b = 1000 * [14, 10, 8, 12, 10,9]';

c = 100 * [814,220; 838,240; 886,280; 910,300; 790,200; 862,260; 886,280;
910,300;...790,200; 802,210];

cromosoma = double(cromosoma);
origen1 = cromosoma(1:4);
origen2 = cromosoma(4:8);
.
.
origen3 = mat2str(origen3);

origenes = [origen1,origen2,origen3];

destinos = zeros(6,1);
initial = 13;
.
.
if (origen1 ~= origen2 && origen1 ~= origen2 && origen2 ~= origen3)
costo = 0;
.
.
costo = costo + sum(a(origenes(j),z));
end
costo = costo + sum(c(origenes,1));
else
costo = inf;
end
```

Anexo 7

Experimento 3 Solución y formulación de Logconsult por software Lingo

MODEL:

```
[_1] MIN= 315208 * XVAR_O1_D1 + 293502 * XVAR_O1_D2 + 212681 *
XVAR_O1_D3 + 109342 * XVAR_O1_D4 + 225928 * XVAR_O2_D1 + 198462 *
XVAR_O2_D2 + 129161 * XVAR_O2_D3 + 45982 * XVAR_O2_D4 + 225040 *
XVAR_O3_D1 + 275392 * XVAR_O3_D2 + 265315 * XVAR_O3_D3 + 233786 *
XVAR_O3_D4 + 135760 * XVAR_O4_D1 + 180352 * XVAR_O4_D2 + 181795 *
XVAR_O4_D3 + 170426 * XVAR_O4_D4 + 217020 * XVAR_O5_D1 + 188850 *
XVAR_O5_D2 + 120828 * XVAR_O5_D3 + 124089 * XVAR_O5_D4 + 127740 *
XVAR_O6_D1 + 93810 * XVAR_O6_D2 + 37308 * XVAR_O6_D3 + 60729 *
XVAR_O6_D4 + 82252 * YVAR_O1 + 134400 * YVAR_O2 + 82252 * YVAR_O3 +
134400 * YVAR_O4 + 82252 * YVAR_O5 + 134400 * YVAR_O6 ;
[_2] XVAR_O1_D1 + XVAR_O2_D1 + XVAR_O3_D1 + XVAR_O4_D1 + XVAR_O5_D1 +
XVAR_O6_D1 = 1 ;
[_3] XVAR_O1_D2 + XVAR_O2_D2 + XVAR_O3_D2 + XVAR_O4_D2 + XVAR_O5_D2 +
XVAR_O6_D2 = 1 ;
[_4] XVAR_O1_D3 + XVAR_O2_D3 + XVAR_O3_D3 + XVAR_O4_D3 + XVAR_O5_D3 +
XVAR_O6_D3 = 1 ;
[_5] XVAR_O1_D4 + XVAR_O2_D4 + XVAR_O3_D4 + XVAR_O4_D4 + XVAR_O5_D4 +
XVAR_O6_D4 = 1 ;
[_6] 6200 * XVAR_O1_D1 + 6600 * XVAR_O1_D2 + 5800 * XVAR_O1_D3 + 4400 *
XVAR_O1_D4 - 3500 * YVAR_O1 <= 0 ;
[_7] 6200 * XVAR_O2_D1 + 6600 * XVAR_O2_D2 + 5800 * XVAR_O2_D3 + 4400 *
XVAR_O2_D4 - 20000 * YVAR_O2 <= 0 ;
[_8] 6200 * XVAR_O3_D1 + 6600 * XVAR_O3_D2 + 5800 * XVAR_O3_D3 + 4400 *
XVAR_O3_D4 - 3500 * YVAR_O3 <= 0 ;
[_9] 6200 * XVAR_O4_D1 + 6600 * XVAR_O4_D2 + 5800 * XVAR_O4_D3 + 4400 *
XVAR_O4_D4 - 20000 * YVAR_O4 <= 0 ;
[_10] 6200 * XVAR_O5_D1 + 6600 * XVAR_O5_D2 + 5800 * XVAR_O5_D3 + 4400 *
XVAR_O5_D4 - 3500 * YVAR_O5 <= 0 ;
[_11] 6200 * XVAR_O6_D1 + 6600 * XVAR_O6_D2 + 5800 * XVAR_O6_D3 + 4400 *
XVAR_O6_D4 - 20000 * YVAR_O6 <= 0 ;
[_12] XVAR_O1_D1 >= 0 ;
[_13] XVAR_O1_D2 >= 0 ;
[_14] XVAR_O1_D3 >= 0 ;
[_15] XVAR_O1_D4 >= 0 ;
[_16] XVAR_O2_D1 >= 0 ;
[_17] XVAR_O2_D2 >= 0 ;
[_18] XVAR_O2_D3 >= 0 ;
[_19] XVAR_O2_D4 >= 0 ;
[_20] XVAR_O3_D1 >= 0 ;
[_21] XVAR_O3_D2 >= 0 ;
[_22] XVAR_O3_D3 >= 0 ;
[_23] XVAR_O3_D4 >= 0 ;
[_24] XVAR_O4_D1 >= 0 ;
[_25] XVAR_O4_D2 >= 0 ;
[_26] XVAR_O4_D3 >= 0 ;
[_27] XVAR_O4_D4 >= 0 ;
[_28] XVAR_O5_D1 >= 0 ;
[_29] XVAR_O5_D2 >= 0 ;
[_30] XVAR_O5_D3 >= 0 ;
[_31] XVAR_O5_D4 >= 0 ;
[_32] XVAR_O6_D1 >= 0 ;
[_33] XVAR_O6_D2 >= 0 ;
```

```

[_34] XVAR_O6_D3 >= 0 ;
[_35] XVAR_O6_D4 >= 0 ;
[_36] XVAR_O1_D1 <= 1 ;
[_37] XVAR_O1_D2 <= 1 ;
[_38] XVAR_O1_D3 <= 1 ;
[_39] XVAR_O1_D4 <= 1 ;
[_40] XVAR_O2_D1 <= 1 ;
[_41] XVAR_O2_D2 <= 1 ;
[_42] XVAR_O2_D3 <= 1 ;
[_43] XVAR_O2_D4 <= 1 ;
[_44] XVAR_O3_D1 <= 1 ;
[_45] XVAR_O3_D2 <= 1 ;
[_46] XVAR_O3_D3 <= 1 ;
[_47] XVAR_O3_D4 <= 1 ;
[_48] XVAR_O4_D1 <= 1 ;
[_49] XVAR_O4_D2 <= 1 ;
[_50] XVAR_O4_D3 <= 1 ;
[_51] XVAR_O4_D4 <= 1 ;
[_52] XVAR_O5_D1 <= 1 ;
[_53] XVAR_O5_D2 <= 1 ;
[_54] XVAR_O5_D3 <= 1 ;
[_55] XVAR_O5_D4 <= 1 ;
[_56] XVAR_O6_D1 <= 1 ;
[_57] XVAR_O6_D2 <= 1 ;
[_58] XVAR_O6_D3 <= 1 ;
[_59] XVAR_O6_D4 <= 1 ;
@BIN( YVAR_O1); @BIN( YVAR_O2); @BIN( YVAR_O3); @BIN(
YVAR_O4); @BIN( YVAR_O5); @BIN( YVAR_O6);
END

```

Global optimal solution found.

Objective value:	569384.2
Extended solver steps:	0
Total solver iterations:	49

