

ARTÍCULO DE INVESTIGACIÓN CIENTÍFICA Y TECNOLÓGICA

DISEÑO DE UNA DISTRIBUCIÓN EN PLANTA CON ALGORITMOS GENÉTICOS Y BÚSQUEDA TABÚ



Msc. Leila Nayibe Ramírez Costañeda¹, Esp. Oscar Mayorga Torres²

RESUMEN

Este artículo presenta una comparación de las heurísticas, Búsqueda Tabú (BT) y Algoritmo Genético (AG), que han sido propuestas para la solución de problemas complejos de optimización combinatoria, en configuración de planta. Estas metodologías han obtenido distribuciones de departamentos, de calidad superior, evaluadas y reportadas en la literatura. Los resultados muestran qué técnica tiene mayor nivel de calidad, en la solución y rapidez computacional en problemas de distribución de espacios en plantas industriales.

PALABRAS CLAVE

heurísticas, Algoritmo Genético, Búsqueda Tabú.

ABSTRACT

This article presents a comparison of the heuristics, Tabu Search (TS) and Genetic Algorithm (GA), that have been proposed, for the solution of complex problems of combinatorial optimization in facility layout. These methodologies, have obtained distributions of departments of better quality, evaluated and reported in literature. The results show, which technique has greater quality level, in the solution and computational rapidity in problems of space distribution in industrial plants.

KEY WORDS

heuristics, Genetic Algorithm, Tabu Search.

Fecha de recepción del artículo: 23 de abril de 2008.

Fecha de aceptación del artículo: 22 de mayo de 2008.

¹ Ingeniera Industrial, Mec. Ingeniería Industrial, Docente Tiempo Completo Universidad de La Salle, Docente Investigador Universidad Libre.

² Ingeniero Industrial, Espc. Producción, Docente Tiempo Completo Escuela Colombiana de Carreras Industriales.

INTRODUCCIÓN

El problema de distribución en planta es de vital importancia para el manejo de materiales de una compañía, ya que el 40% del costo asociado al producto terminado, está dado por la distribución física de los elementos industriales³.

Ubicar los departamentos de manera óptima, se convierte en un problema complejo, dada la infinidad de soluciones que se pueden obtener de acuerdo con la variedad de combinaciones posibles de distribuciones en planta; entonces los algoritmos de inteligencia artificial del cual se destaca el algoritmo genético, son técnicas de búsqueda aleatoria, que pueden encontrar una solución óptima global.

El objetivo de este trabajo es aplicar el software desarrollado por Garcia (2001), para la distribución de plantas industriales a partir de algoritmos genéticos y se hará una comparación con un problema reportado en la literatura, en donde la localización de la solución es obtenida con la heurística Búsqueda Tabú.

El presente estudio contiene la sección 2, donde se definen las heurísticas utilizadas en este estudio y posteriormente en la sección 3, se describe el modelo matemático utilizado. En la sección 4, la breve descripción de la metodología usada; sección 5 se describe la aplicación a un caso real reportado por la literatura bajo la heurística de búsqueda BT; posteriormente en la sección 6, los resultados obtenidos por cada una de las aplicaciones. Finalmente, las conclusiones y recomendaciones se describen en la sección 7.

1. DEFINICIÓN DE LAS HEURÍSTICAS UTILIZADAS EN EL ESTUDIO

Las metodologías tratadas en este artículo se describen a continuación:

1.1 Algoritmo Genético

Los Algoritmos Genéticos funcionan con una familia de soluciones (conocida como la "población inicial") a

Figura 1. Etapas del GA



partir de la cual obtenemos la "siguiente generación" de soluciones. Cuando el algoritmo se emplea de forma adecuada, de una generación a la siguiente se obtiene, de manera progresiva, mejores soluciones. Es decir, las soluciones buenas se propagan de una generación a la siguiente y conducen a mejores soluciones conforme producimos más generaciones. A continuación se muestra las diferentes etapas de un GA.

Población Inicial: En la iniciación de la optimización, el GA requiere un grupo de soluciones iniciales (individuos con información genética), generadas aleatoriamente en concordancia, con una estructura de los cromosomas previamente definida.

Evaluación: Cada uno de los individuos, de la población inicial, se evalúa para obtener el valor de la función objetivo.

Selección: Se establecen criterios de selección, de tal manera que se dupliquen más copias de individuos, la selección es determinada por individuos aptos que tienen un valor pequeño dentro de la función objetivo, cuyo resultado es menores valores. Algunos criterios reconocidos para la selección son la ruleta, en la que la siguiente generación contiene los individuos, con mayores valores de acuerdo con una búsqueda aleatoria y selecciones basadas en rangos probabilidades.

³ Isler A.A. A genetic algorithm approach for multiple criteria facility layout design. *International Journal of production Research*, Vol 36, No. 6, 1998, 1549 - 1569.

Cruce: Una vez finalizada la operación de selección. Los individuos existentes (padres) obtenidos por los criterios de selección, crean dos nuevos individuos (hijos). Para lograr este objetivo se emplea un punto de cruce, escogiendo los dos individuos (padres) y un punto de corte al azar. Las colas del cromosoma, que son las partes después del punto de corte, se intercambian y dos nuevos individuos (hijos) son generados. En cada generación los mejores cromosomas son seleccionados para actuar como padres. Este principio se fundamenta en el proceso de selección de que un buen padre (solución) obtenga una mayor probabilidad de ser seleccionado, comparada con la de los malos padres.

Mutación: Probabilidad de mutación establecida, permite que los individuos muten al azar para generar un nuevo individuo. En esta etapa se considera la operación monódica, pues un solo padre, genera un solo nuevo hijo. Este operador de mutación hace que el algoritmo cree nuevas áreas y lo ayuda a evitar la convergencia prematura, aumentando la diversificación para encontrar el óptimo global.

El GA es modificado por el usuario de acuerdo con las siguientes variables, el tamaño de la población, la tasa de mutación, la tasa de reproducción elitista y el número de generaciones; estos parámetros afectan el funcionamiento y el tiempo de ejecución de un GA. El lector puede consultar Islier (1998) una excelente introducción, a los conceptos básicos y algunos avanzados de GA y su utilización en problemas de optimización.

1.2 Búsqueda Tabú

La BT es un método heurístico de búsqueda global, en el espacio de soluciones de un problema, en la cual una memoria de largo plazo registra las soluciones visitadas, y obliga a que el proceso de búsqueda visite de forma determinística soluciones no evaluadas; sin embargo, es posible hacer el proceso estocástico adicionando algunos elementos probabilísticos. En su forma tradicional, la BT opera sobre una cadena binaria que representa una posible solución del problema.

El proceso de optimización consiste en explorar las vecindades de la mejor solución encontrada hasta el momento, moviéndose a una nueva solución óptima, en la medida en que ella tenga un mejor valor de la función objetivo. Para evadir los óptimos locales, la BT evita visitar algunas de las soluciones vecinas a la solución óptima actual, considerando que los movimientos en el espacio de soluciones que llevan de una solución a la otra son tabú, de tal forma que ellos no pueden ser aceptados durante un cierto tiempo o un cierto número de iteraciones. Para ello, los movimientos aceptados son almacenados en una memoria de corto plazo.

Cuando el algoritmo converge, finalmente, a un punto de óptima local, para el cual no es posible encontrar soluciones vecinas mejores, la solución es almacenada como el mejor óptimo encontrado; posteriormente, la memoria de corto plazo es borrada, y se escoge como nuevo punto de arranque del algoritmo alguna de las soluciones previamente visitadas que se encuentran almacenadas, en la memoria de largo plazo. Para mayores detalles sobre el algoritmo véase a Glover y Laguna (1993)⁴.

2. MODELO MATEMÁTICO USADO

Para lograr una comparación entre las heurísticas mencionadas en este artículo se trabajó con el modelo matemático propuesto por Islier (1998) ya que su aplicación genera grandes beneficios y tiene excelente respuesta en la localización de soluciones factibles; a continuación se muestra una descripción del modelo:

Entonces los criterios de optimización que conforman el modelo son los siguientes:

2.1 Cálculo de distancias entre dos máquinas

La condición inicial de entrada para el modelo es el cálculo de las distancias entre dos máquinas o estaciones de trabajo i y j , esta se basa en centroides, es decir el centro del área. La distancia entre ellas está determinada por:

⁴ Glover, F. y Laguna, M. (1993). Tabu search in Modern Heuristic Techniques for Combinatorial Problems. Blackwell, Oxford. Solving facility layout problems with geometric constraints using parallel genetic algorithms: experimentation

$$d_{ij}(p) = \left(\sum_{k=1}^N |x_{ik} - x_{jk}|^p \right)^{1/p} \quad (1)$$

donde:

- i, j Índices de estaciones de trabajo donde i = 1,2,3.....n, j = 1,2,3.....n
- k Dimensión donde k = 1,2.
- p Determinante de la métrica usada (p=1 rectilíneo, p= 2 euclidiano) donde p = 1.
- d_i Distancia entre la estación de trabajo i y la j (rectilínea)
- x_{ik} Coordenada del centroide de la estación de trabajo i en la dimensión k
- x_{jk} Coordenada del centroide de la estación de trabajo j en la dimensión k
- N Número de dimensiones

2.2 Minimizar la carga de transporte

Para minimizar entonces la carga de transporte se ha creado un factor de carga, que es la razón entre la carga ideal por transportar de una estación de trabajo i a una estación de trabajo j y la carga realmente transportada de la estación de trabajo i a la j. Al maximizar este factor que siempre estará entre 0 y 1, se obtendrá el efecto contrario que es la reducción de la carga de transporte.

A continuación se presenta el Factor de Carga t:

$$t = \frac{V}{\sum_{i=1}^{n-1} \sum_{j=2}^n c_{ij} f_i d_{ij}} = \frac{\sum_{i=1}^{n-1} \sum_{j=2}^n f_i d_{ij}}{\sum_{i=1}^{n-1} \sum_{j=2}^n c_{ij} f_i d_{ij}} \quad (2)$$

donde:

- V Carga Ideal (No hay costos de transporte).
- i, j Indices de estaciones de trabajo i= 1,2,3.....n, j= 1,2,3.....n.
- d_i Distancia entre la estación de trabajo i y la j (rectilínea).

- c_{ij} Costo de transportar una unidad de carga por una unidad de longitud entre la estación de trabajo i y la j.
- f_i Número de unidades de carga que serán transportadas entre la estación de trabajo i y la j.
- n Número de estaciones de trabajo.

2.3 Maximizar el grado de compactación de las áreas de las estaciones de trabajo.

De esta forma la razón, entre el perímetro y el área, debe ser mínima, para obtener áreas de estaciones adecuadas; esto significa que se debe minimizar el siguiente factor de forma s:

$$s = \frac{\sum_{k=1}^n r_k}{\sum_{p=1}^b \sum_{q=1}^e \sum_{k=1}^n a_{pk}} = \frac{\sum_{k=1}^n u_{pk}^2}{\sum_{p=1}^b \sum_{q=1}^e \sum_{k=1}^n a_{pk}} \quad (3)$$

donde:

- k Índice de estaciones de trabajo k= 1,2,3l.
- p Índice de celdas p = 1,2,3 ...P.
- i Índice de filas en el plano de diseño de la planta.
- j Índice de columnas en el plano de diseño de la planta.
- b Número de filas en el plano de diseño de planta.
- e Número de columnas en el plano de diseño de planta.
- n Número de estaciones de trabajo.
- r_k Momento del área de la estación de trabajo.
- u_{pk} Distancia rectilínea del centroide de la estación de trabajo k al centroide de la celda p que está dentro de la estación de trabajo k.
- r_{ik} Momento de área de la estación de trabajo k.
- S_k Conjunto de celdas de la estación de trabajo k.
- a_{ijk} Indicador que es igual a 1 si la celda en la fila i y la columna j en el plano de diseño está en la estación de trabajo k.

Isler A.A. A genetic algorithm approach for multiple criteria facility layout design. *International Journal of Production Research*, Vol 36, No. 6, 1998, 1549 - 1569.

2.4 Minimizar la diferencia entre las áreas demandadas y las disponibles para cada estación de trabajo

Las diferencias entre las áreas demandadas y las asignadas se minimiza, manteniéndolas dentro de los límites predeterminados. Para minimizar estas diferencias se presenta el siguiente factor de desviación:

$$h = \frac{\sum_{k=1}^n |A_k - \sum_{i=1}^b \sum_{j=1}^e a_{ik}|}{\sum_{i=1}^b \sum_{j=1}^e \sum_{k=1}^n a_{ik}} \quad (4)$$

Donde:

- A_k Área más deseada para la estación de trabajo.
- k Índice de estaciones de trabajo $i = 1, 2, 3 \dots, t$
- i Índice de filas en el plano de diseño de la planta
- j Índice de columnas en el plano de diseño de la planta
- b Número de filas en el plano de diseño de planta
- e Número de columnas en el plano de diseño de planta
- n Número de estaciones de trabajo
- a_{ik} Indicador que es igual a 1 si la celda en la fila i y la columna j en el plano de diseño está en la estación de trabajo k .

Unificando estos tres criterios se tiene el siguiente modelo final con función objetivo y restricciones:

$$\text{Max} \quad \frac{t}{sh} = \frac{\text{Factor de carga}}{\text{Factor de forma} \cdot \text{Factor de desviación}} \quad (5)$$

$$\sum_{k=1}^n a_{ik} \leq 1 \quad \text{para todo } i \text{ y } j \quad (6)$$

$$A_{-k} \leq \sum_{i=1}^b \sum_{j=1}^e a_{ik} \leq A_k \quad \text{para todo } k \quad (7)$$

$$\sum_{i=1}^b \sum_{j=1}^e \sum_{k=1}^n a_{ik} \leq eb \quad (8)$$

- 6) La primera restricción, prohíbe que una máquina sea compartida por más de una estación de trabajo; esto significa que no se permite sobrepasar las estaciones de trabajo.
- 7) La segunda restricción, mantiene el número de máquinas de cada estación de trabajo, dentro de los límites predeterminados. A_{-k} y A_k son los límites inferiores y superiores para el número de máquinas, dentro de una estación de trabajo.
- 8) La tercera restricción, evalúa el número total de máquinas para todas las estaciones de trabajo, de tal forma que no excedan el área total disponible como parte del requerimiento.

Este es un problema multiobjetivo; se recomienda por su eficiencia en la búsqueda de soluciones, el algoritmo genético y la Búsqueda Tabú.

3. METODOLOGÍA

La función objetivo del modelo matemático, es multicriterio, debido a que se evalúan tres criterios que son: función de carga, factor de forma y factor de desviación. La comparación de los resultados obtenidos frente a esta función objetivo es difícil llevar a cabo dado que en la literatura no se encuentra aplicación exacta del modelo presentado anteriormente; entonces es significativo solo evaluar la función objetivo con respecto a la minimización de los costos de transporte entre las facilidades, los flujos de transporte entre las dependencias y las distancias entre departamentos. Finalmente, la función objetivo pertinente para la comparación de resultados es la siguiente:

$$\text{MIN.} \quad \sum_{i=1}^{n-1} \sum_{j=2}^n c_{ij} f_{ij} d_{ij} \quad (9)$$

Esta función objetivo será evaluada bajo las restricciones (5) y (7) del modelo original y la metodología usada para la búsqueda de solución será el algoritmo genético. Los resultados obtenidos a través del software desarrollado por García (2001), generan una base de datos, que permitirán la construcción de un modelo de diseño de experimentos 2³. Obteniendo valores altamente confiables, dado

que el AG, localiza soluciones dentro del área de factibilidad y de forma totalmente aleatoria. Entonces, estos modelos estadísticos determinan cuál es la combinación indicada de factores, para generar mejores soluciones, frente al modelo (9). Después se realizará un benchmarking con literatura disponible de aplicaciones heurísticas, como la Búsqueda Tabú aplicada a configuraciones de planta.

4. APLICACIÓN

4.1 Condiciones iniciales de entrada para el problema

Para las comparaciones frente a los resultados, se utilizará un caso real reportado en la literatura, en el cual se aplicó la Búsqueda Tabú, en la cual se desarrolla la configuración de una planta, conformada por 7 departamentos cuyas áreas y flujos se muestran a continuación:

Tabla 1. Áreas disponibles para los departamentos

Departamentos	Áreas (Unidades cuadradas)
1	12000
2	8000
3	6000
4	12000
5	8000
6	12000
7	12000

Tabla 2. Matriz de flujos entre departamentos por unidad de tiempo (Desde - Hacia)

	1	2	3	4	5	6	7
1		45	15	25	10	5	
2				30	25	15	
3					5	10	
4		20			35		
5						65	35
6		5					65
7							

Para ejecutar el algoritmo, se supuso un elemento mínimo cuadrado, con un área de 400 unidades cuadradas. Igualmente, se asumió el ancho de la banda vertical en dos unidades cuadradas, y el de la banda horizontal en dos unidades cuadradas. El área total para distribuir los departamentos tiene 10 filas y 18 columnas de elementos mínimos cuadrados. La matriz de costos, se tomaron consideraciones como un costo unitario de un peso por unidad de carga transportada por una unidad de distancia⁸.

4.2 Estructura del cromosoma por aplicar


Para las condiciones del problema descrito anteriormente, se evaluará el siguiente cromosoma:

Figura 1. Estructura del cromosoma inicial



Los resultados deben estar acorde con las soluciones reportadas en el artículo; para esto se construye un nuevo cromosoma basado en las condiciones iniciales del problema:

Figura 2. Estructura cromosoma inicial modificado



Los genes que componen al cromosoma se identifican como:

G1: Gen 1. Representa la secuencia de los departamentos; en este caso se precisan a través de números.

G2: Gen 2. Describe el área de los departamentos, que también se ubican bajo la misma secuencia de G1.

⁸ Domínguez Carlos Andrés, De Los Ríos Giovanni, Velásquez Juan David. Distribución de espacios industriales usando Búsqueda Tabú, Universidad Nacional de Colombia.

G3: Gen 3. Representa el ancho de cada una de las bandas de la grilla completa

5. RESULTADOS OBTENIDOS

5.1 Resultados reportados por el artículo

Los resultados reportados por el artículo son los siguientes:

Tabla 3. Costos obtenidos para las diferentes configuraciones reportadas.

Método	Costo
ALDEP	3199.95
CRAFT	2833.5
BT	2024.78

Figura 3. Solución encontrada usando el Programa ALDEP

```
00000000000000000000000000000000
01122224455666677770
01122224455666677770
01122224455666677770
01122224455666677770
01122224455666677770
01122224455666677770
011114444556663377770
011114444556663377770
011114444556663337070
011114444556663333000
011114444556663333000
00000000000000000000000000000000
```

Figura 4. Solución encontrada usando el programa CRAFT

```
111111111177777777
111111111177777777
111111111177777777
333222222266777777
333322222266666666
333322222266666666
333324444555555666
444444444555555666
444444444555555666
444444440000055666
```

Figura 5. Solución encontrada usando BT

```
1133334444466667777
1133334444466667777
1133324444465667777
1133224444455667777
1133224444455667777
1111224444455667777
1111224444455667777
111122245455666707
111122225555666600
111122225555666600
```

5.2 Resultados obtenidos a partir de algoritmo genético

La herramienta computacional que se trabajó para la comparación de resultados fue Visual Basic a través de las macros de Excel desarrollada por García (2001). Los resultados que se obtuvieron fueron validados a partir del diseño factorial general 2^k , para determinar si los factores tienen efecto importante sobre la respuesta (función objetivo) y así lograr una solución de mayor calidad. El modelo matemático del diseño de experimentos es el siguiente:

$$y_{ijl} = \mu + \tau_i + \beta_j + \gamma_k + (\tau\beta)_{ik} + (\tau\gamma)_{jk} + (\beta\gamma)_{ij} + (\tau\beta\gamma)_{ijk} + \epsilon_{ijl} \quad (10)$$

donde:

μ = Media general

τ = Efecto del factor fracción mejores padres

β = Efecto del factor fracción de hijos generados por mejores padres

γ = Efecto del factor de probabilidad de mutación

ϵ = Componente aleatorio del error

$i = 1, 2$

$j = 1, 2$

$k = 1, 2$

$l = 1, \dots, 5$

El número de réplicas escogidas para el diseño factorial 2^3 es 5, pues es una muestra suficiente para la estimación de los errores experimentales.

Hipótesis por probar:

1. $H_0: \tau_1 = \tau_2 = \tau_3 = 0$

H_a : al menos τ sea diferente de cero

2. $H_0: \beta_1 = \beta_2 = \beta_3 = 0$

H_a : al menos β sea diferente de cero

3. $H_0: \gamma_1 = \gamma_2 = \gamma_3 = 0$

H_a : Al menos una γ sea diferente de cero

4. Hipótesis para las interacciones que se presentan en el modelo.

Criterio de rechazo:

El criterio de rechazo se evaluará bajo un nivel de confianza del 95%.

Los niveles y factores utilizados para el desarrollo del Análisis de Variancia se muestran en la siguiente tabla:

Tabla 4: Niveles y factores por evaluar dentro del modelo

Factor	Nivel superior	Nivel inferior
Fracción de mejores padres	70%	20%
Fracción de mejores hijos generados por mejores padres	70%	20%
Probabilidad de mutación	0.07	0.005

El diseño fue satisfactorio en las pruebas de normalidad, de lo cual podemos decir que se satisface la condición, de que los errores se distribuyen independiente y normalmente con media cero y variancia constante, pero desconocida. Con estos supuestos el modelo describe, adecuadamente, las

Tabla 5. ANOVA para el diseño factorial 2³⁽³⁾

ANOVA For Y1					
Master Model					
Source	DF	SS	MS	F	Pr > F
FRACCIÓN	1	0.697427	0.697427	0.047325	0.362991
FRACCIÓN	1	2.805119	2.805119	1.408096	0.073864
MUTACIÓN	1	0.378387	0.378387	0.459721	0.502483
FRACCIÓN*FRACCIÓN	1	0.015421	0.015421	0.062333	0.796872
FRACCIÓN*MUTACIÓN	1	0.365493	0.365493	0.444054	0.509804
FRACCIÓN*MUTACIÓN	1	1.17012	1.17012	1.421674	0.241638
Model	6	5.471977	0.911996	1.108027	0.378737
Error	33	27.15167	0.823081		
(Lack of Fit)	1	0.063869	0.063869	0.074476	0.786661
(Pure Error)	32	27.0884	0.846513		
Total	39	32.63365			

observaciones y genera validez al procedimiento de análisis de variancia constituyendo una prueba exacta para las hipótesis de igualdad de medias de los tratamientos.

El ANOVA muestra claramente que los factores no tienen efecto importante sobre la variable respuesta, confirmando así la aceptación de la hipótesis nula con una confiabilidad del 95%.

Finalmente los resultados optimizados para obtener el mínimo valor en la función objetivo son:

Tabla 6. Optimización de las observaciones

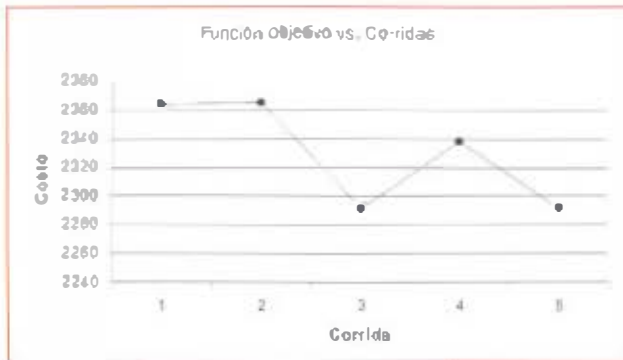
	fracción mejores padre	fracción de hijos	mutación	Y1
1	0.7	0.7	0.07	-0.374196737
2	0.7	0.7	0.05375	-0.363289165
3	0.7	0.7	0.0375	-0.352381593
4	0.7	0.7	0.02125	-0.34147402
5	0.7	0.7	0.005	-0.330566449
6	0.7	0.575	0.07	-0.308694136
7	0.575	0.7	0.005	-0.293728221
8	0.575	0.7	0.02125	-0.280739409
9	0.575	0.7	0.0375	-0.267748704
10	0.45	0.7	0.005	-0.258888835
11	0.7	0.575	0.05375	-0.25127792
12	0.575	0.7	0.05375	-0.254798945
13	0.7	0.45	0.07	-0.243191536
14	0.575	0.7	0.07	-0.241769186
15	0.325	0.7	0.005	-0.228651788
16	0.45	0.7	0.02125	-0.223102905
17	0.7	0.575	0.0375	-0.201361447
18	0.575	0.575	0.07	-0.185572207
19	0.2	0.7	0.005	-0.183213543
20	0.45	0.7	0.0375	-0.183115815
21	0.7	0.325	0.07	-0.177688334
22	0.325	0.7	0.02125	-0.159267348
23	0.575	0.575	0.05375	-0.159303194
24	0.7	0.575	0.02125	-0.147635103
25	0.7	0.4	0.05375	-0.146706419

Resultados obtenidos con el software SAS.

En esta tabla se puede observar que para obtener el mínimo valor de costos, para la función objetivo se debe utilizar 70% de fracción de mejores padres, 70% de mejores hijos generados por mejores padres y una probabilidad de mutación de 0.07; la variable respuesta que se observa en la tabla se encuentra ajustada.

Nuevamente se hace una corrida con 5 réplicas y los resultados que se obtienen son los siguientes:

Figura 6. Resultados obtenidos en las diferentes corridas



El menor costo que se obtuvo frente a la aplicación de algoritmo genético es de 2291.11366 bastante superior al encontrado en la literatura para el mismo caso bajo la metodología de Búsqueda Tabú (BT), el tiempo de ejecución del software a partir de algoritmo genético, para la localización de la solución es de 13.546 segundos, parámetro interesante de comparación, pero se desconoce el tiempo de ejecución de Búsqueda Tabú.

La configuración que se obtuvo fue la siguiente:

Figura 7. Configuración en planta con Algoritmo Genético

4	4	4	4	4	4	4	4	4	4	4	4	4	4	5	5	5	5
4	4	4	4	4	4	4	4	4	4	5	5	5	5	5	5	5	5
4	4	4	4	4	4	2	2	2	5	5	5	5	5	5	5	6	6
2	2	2	2	2	2	2	2	2	6	6	6	6	6	6	6	6	6
2	2	2	2	2	2	2	2	1	6	6	6	6	6	6	6	6	6
1	1	1	1	1	1	1	1	1	6	6	6	6	6	6	6	6	6
1	1	1	1	1	1	1	1	1	7	7	7	7	7	7	7	7	7
1	1	1	1	1	1	1	1	1	7	7	7	7	7	7	7	7	7
1	1	3	3	3	3	3	3	3	7	7	7	7	7	7	7	7	7
3	3	3	3	3	3	3	3	3	0	0	0	0	0	0	0	7	7



CONCLUSIONES

La solución obtenida bajo la heurística de Algoritmo Genético fue superior a la obtenida con BT, pero bajo ALDEP el costo que se obtuvo representa 71% respecto a la solución que se obtuvo frente a GA, y 80 % para el CRAFT. A pesar de que la mejor solución encontrada para este caso es la que reporta BT, se debe establecer una comparación más rigurosa, en cuanto al tiempo de ejecución de cada uno de los software y además cabe anotar

que es importante tener en cuenta la funcionalidad de la configuración en planta encontrada, aplicada a los procesos de la compañía, debido a que los costos no es suficiente herramienta para la toma de una decisión definitiva, en cuanto a distribución en planta se refiere. Se recomienda medir la eficiencia del software en diferentes estancias del problema, para obtener unas conclusiones más objetivas.

BIBLIOGRAFÍA

ARMOUR G. y BUFFA E. A heuristic algorithm and simulation approach to relative locations facilities. En: Management Science, Vol. 9. 1963. 294-309 pp.

DOMÍNGUEZ Carlos Andrés, De Los Ríos Giovanni, Velásquez Juan David. Distribución de espacios industriales usando Búsqueda Tabú, Universidad Nacional de Colombia.

GARCÍA Diana. Algoritmos genéticos para distribución en planta, Tesis de Maestría, Universidad de Los Andes, 2001.

GOLBERG, D.E. Genetic Algorithms in search, optimization, and machine learning, Addison Wesley, Boston, 1989.

ISLIER A.A. A genetic algorithm approach for multiple criteria facility layout design. En: International Journal of Production Research, Vol. 36, número 6, 1998, 1549-1569 pp.

MONTGOMERY. Douglas. Diseño y análisis de experimentos. Segunda Edición, México D.F. Limusa. 2005.

TOMPKINS, James. Planeación de instalaciones, Tercera edición, México D.F., Thomson, 2006. Pág. 356-357.

