

Optimización con múltiples objetivos utilizando Tabú Search*

Yezid Donoso**, Pedro Albor*** y Alex Benavides****

Departamento de Ingeniería de Sistemas y Computación, Universidad del Norte

Resumen

En este artículo se muestra el uso de una meta-heurística usando la teoría de optimización multiobjetivo para encontrar árboles óptimos para transmisiones multicast teniendo en cuenta 4 objetivos, como lo son la minimización de la utilización máxima de enlaces (MLU), el número de saltos (HC), el consumo total de ancho de banda (BW), y el retardo destino-a-destino (DL).

Esta técnica es Tabú Search, la cual es una heurística y se caracteriza por hacer uso de memoria para realizar una búsqueda inteligente. Tabú Search obtiene su nombre al hacer que ciertas soluciones no sean aceptadas por ser Tabú (prohibidas), esto es para evitar que soluciones que ya han sido visitadas sean seleccionadas nuevamente. Tabú Search usa la premisa de que para que un método califique de inteligente debe hacer uso de memoria para guiar la búsqueda y evitar caer en la optimalidad local.

Palabras claves: Optimización, multiobjetivo, multicast, Tabú Search.

Abstract

This article shows the use of a heuristic procedure using the Multi-Objective theory to find optimal trees for multicast transmissions having in consideration 4 objectives, which are the minimization of the maximum utilization of the links, the Hop count (HC), the Bandwidth (BW) and the Delay.

This technique is Tabu Search which is a heuristic that characterizes for making use of memory to realize an intelligent search. Tabu Search gets its name by making some solutions unavailable for being Tabu (forbidden), this in order to avoid solutions that have been visited in the past to be selected again. Tabu Search uses the premise that in order for a method to be labelled as intelligent it must incorporate the use of memory. Tabu Search uses this memory to guide the search and avoid falling in local optimality.

Key words: Optimization, multi-objective, multicast, Tabu Search.

Fecha de recepción: 7 de diciembre de 2004
Fecha de aceptación: 26 de octubre de 2005

* Este artículo forma parte de los resultados de la investigación "Aplicación de ingeniería de tráfico en redes multicast".

** Ingeniero de Sistemas y Minor en gestión de proyectos de Ingeniería, Universidad del Norte. Magíster en Ingeniería de sistemas y computación, Universidad de los Andes. D.E.A. y candidato a grado de Ph.D. en Redes Telemáticas, Universidad de Girona (España). Profesor del Departamento de Ingeniería de Sistemas de la Universidad del Norte. ydonoso@uninorte.edu.co

Dirección: Km. 5 vía Puerto Colombia, Barranquilla (Colombia).

*** Ingeniero de Sistemas, Universidad del Norte. pedroalbor@hotmail.com

**** Ingeniero de Sistemas, Universidad del Norte. ingenierobj@hotmail.com

INTRODUCCIÓN

El hombre sin la posibilidad de comunicación sería un ser insatisfecho de su naturaleza como tal; esta situación es la que estimula al ser humano a buscar formas de explorar e investigar su alrededor. Para ello existen la prioridad y los objetivos. Estos últimos pueden variar dependiendo de las circunstancias y de su posible evaluación, y es por ello que la teoría de optimización multiobjetivo es la más adecuada para solucionar y a veces entablar relaciones entre los problemas y sus solvencias. De aquí partiremos para optimizar distintos objetivos a la vez, sobre redes multicast, ya que éstas facilitan el envío de datos de aplicaciones que se consideran críticas.

Grandes conflictos presentan estas clases de redes, debido a que para retardos sensibles al ancho de banda o pérdida de paquetes se necesita usar una técnica no convencional en la que se optimiza la transmisión de estas aplicaciones, como por ejemplo videoconferencias, radio sobre IP o TV sobre IP. Y es aquí donde entra nuestra propuesta al optimizar múltiples objetivos para las transmisiones multicast usando la técnica heurística Tabu Search.

1. TABÚ SEARCH

Tabú Search se basa en el uso de memoria y de diferentes estrategias para guiar la búsqueda más allá de la optimalidad local. Tabú Search es un método iterativo que comienza con una solución inicial X_0 , de la cual busca una solución X' realizando algo llamado movimiento. Un movimiento consiste en realizar el mejor cambio posible, aunque este cambio lleve a una disminución de la calidad de la respuesta. Tabú Search usa el concepto de vecinos y vecindario. Un vecino es un posible movimiento, el cual consiste en cambiar un atributo de la solución actual por otro, y el vecindario consiste en los vecinos que se pueden acceder desde una solución X en particular. Para prevenir el ciclado de soluciones, Tabú Search hace uso de una lista Tabú en la cual se almacenan las soluciones que han sido visitadas en un pasado reciente y que no se pueden acceder por un número determinado de iteraciones al ser etiquetadas como Tabú o prohibidas, ya que se podría regresar a soluciones anteriores. En ciertos casos se puede acceder a un movimiento clasificado como Tabú al llevar a cabo una técnica de Tabú Search llamada aspiración, la cual, si es satisfecha, permite la aceptación del movimiento. Tabú Search emplea diferentes tipos de aspiración dependiendo del problema.

2. OPTIMIZACIÓN MULTIOBJETIVO

Un *MOP* general incluye un conjunto de n parámetros (variables de decisión), un conjunto de k funciones objetivo y un conjunto de m restricciones. Las funciones objetivo y las restricciones son funciones de las variables de decisión. Luego, el *MOP* puede expresarse como:

$$\begin{array}{ll}
 \text{Optimizar} & \mathbf{y} = \mathbf{f}(\mathbf{x}) = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x})) \\
 \text{sujeto a} & \mathbf{e}(\mathbf{x}) = (e_1(\mathbf{x}), e_2(\mathbf{x}), \dots, e_m(\mathbf{x})) \geq \mathbf{0} \\
 \text{donde} & \mathbf{x} = (x_1, x_2, \dots, x_n) \in \mathbf{X} \\
 & \mathbf{y} = (y_1, y_2, \dots, y_k) \in \mathbf{Y}
 \end{array} \tag{1}$$

Siendo x el vector de decisión e y el vector objetivo. El espacio de decisión se denota por X y el espacio objetivo por Y . Optimizar, dependiendo del problema, puede significar, igualmente, minimizar o maximizar.

El conjunto de restricciones $e(x) \geq \mathbf{0}$ determina el conjunto de soluciones factibles X_f y su correspondiente conjunto de vectores objetivo factibles Y_f .

El conjunto de soluciones factibles X_f se define como el conjunto de vectores de decisión x que satisface los requerimientos $e(x)$:

$$X_f = \{x \in X \mid e(x) \geq \mathbf{0}\} \tag{2}$$

La imagen de X_f , es decir, la región factible del espacio objetivo, se denota por

$$Y_f = f(X_f) = U_{x \in X_f} \{y = f(x)\} \tag{3}$$

De estas definiciones se tiene que cada solución del *MOP* en cuestión consiste de una n -tupla $x = (x_1, x_2, \dots, x_n)$, que conduce a un vector objetivo $y = (f_1(x), f_2(x), \dots, f_k(x))$, donde cada x debe cumplir con el conjunto de restricciones $e(x) \geq \mathbf{0}$. El problema de optimización consiste en hallar la x que tenga el "mejor valor" de $f(x)$. En general, y según ya se ha introducido, no existe un único "mejor valor", sino un conjunto de soluciones. Entre éstas, ninguna se puede considerar mejor a las demás si se tienen en cuenta todos los objetivos al mismo tiempo. Este hecho deriva de que puede existir y generalmente existe conflicto entre los diferentes objetivos que componen el problema. Por ende, al tratar con *MOPS* se precisa de un nuevo concepto de "óptimo".

Dominancia Pareto en un contexto de Maximización. Para dos vectores objetivos a y b ,

$$\begin{aligned} a \{\ll b \text{ (} a \text{ domina a } b)\} & \quad \text{si y sólo si } a > b \\ b \{\ll a \text{ (} b \text{ domina a } a)\} & \quad \text{si y sólo si } b > a \\ a \ll b \text{ (} a \text{ y } b \text{ no son comparables)} & \quad \text{si y sólo si } a \gg b \wedge b \gg a \end{aligned}$$

Dominancia Pareto en un contexto de Minimización. Para dos vectores objetivos a y b ,

$$\begin{aligned} a \{\ll b \text{ (} a \text{ domina a } b)\} & \quad \text{si y sólo si } a < b \\ b \{\ll a \text{ (} b \text{ domina a } a)\} & \quad \text{si y sólo si } b < a \\ a \ll b \text{ (} a \text{ y } b \text{ no son comparables)} & \quad \text{si y sólo si } a \gg b \wedge b \gg a \end{aligned}$$

Optimalidad Pareto. Dado un vector de decisión $x \in X_f$ y su correspondiente vector objetivo $y = f(x) \in Y_f$, se dice que x es no dominado respecto a un conjunto $A \subseteq X_f$ si y sólo si

$$\forall a \in A : (x \{\ll a \vee x \ll a\})$$

En caso que x sea no dominado respecto a todo el conjunto X_f y sólo en ese caso, se dice que x es una **solución Pareto óptima** ($x \in X_{true}$ –el conjunto Pareto óptimo real–). Mientras que la y correspondiente es parte del **frente Pareto óptimo real** Y_{true} . Esto se define a continuación.

Conjunto Pareto óptimo y frente Pareto óptimo. Dado el conjunto de vectores de decisión factibles X_f . Se denomina X_{true} al conjunto de vectores de decisión no dominados que pertenecen a X_f es decir:

$$X_{true} = \{x \in X_f \mid x \text{ es no dominado con respecto a } X_f\}$$

El conjunto X_{true} también es conocido como el conjunto Pareto óptimo, mientras que el conjunto correspondiente de vectores objetivo $Y_{true} = f(X_{true})$ constituye el frente Pareto óptimo.

3. MODELO ANALÍTICO

A continuación se muestra el modelo analítico para el problema planteado. Debido a que aplicar este modelo para ciertas topologías puede resultar complicado, se hace uso de la heurística para calcular estos valores.

La red es modelada en un grafo directo $G=(N,E)$, donde N es el conjunto de nodos y E es el conjunto de enlaces. Se denotará al número de nodos con la letra n , y la s como las fuentes (ingreso de nodos), siendo que $s \in N$, y algunos destinos T (conjunto de nodos sumideros), donde $t \in T$ es cualquier nodo destino. Se tendrá $(i, j) \in E$ que representa el enlace desde el nodo i hasta el nodo j . También se tiene una variable $f \in F$, que es cualquier nodo donde haya fluido multicast, donde F es el conjunto de nodos donde hay fluido y Tf es el nodo destino en el fluido en una transmisión multicast f . Se denota por $|F|$ el número de transmisiones.

Se obtiene, $T = \bigcup_{f \in F} Tf$

El X_{ij}^{tf} es la fracción de f a los nodos destinos t utilizando un enlace (i,j) . Hay que notar que se incluye el nodo de destino t , que no había sido considerado en trabajos previos. El incluir el nodo destino permite controlar el ancho de banda consumido en cada enlace con destino al conjunto de nodos destinos.

En la solución del problema, la variable X_{ij}^{tf} provee valores óptimos en el flujo de información en la red.

La variable c_{ij} es la capacidad en cada enlace (i, j) , y bw es la demanda de fluido f por los nodos fuente s a Tf .

La variable binaria Y_{ij}^{tf} representa cuando el enlace (i, j) es usado (1) o no (0) por el árbol multicast enrutado por el nodo fuente s y los enlaces involucrados con el conjunto de nodos fuente Tf .

La variable v_{ij} representa el retraso en el enlace (i, j) , y m es el número de variables en la función multiobjetivo. La variable *connection* _{ij} indica si ahí hay un enlace entre un nodo i y otro j .

El problema de minimización $|F|$ en transmisiones multicast desde nodos fuentes s a los nodos destinos en cada subconjunto Tf es formulado a continuación.

Minimizar

$$r_1 \cdot \alpha + r_2 \sum_{f \in F} \sum_{t \in Tf} \sum_{(i,j) \in E} Y_{ij}^{tf} + r_3 \sum_{f \in F} \sum_{(i,j) \in E} bw \quad \max_{t \in Tf} (X_{ij}^{tf}) + r_4 \sum_{f \in F} \sum_{t \in Tf} \sum_{(i,j) \in E} v_{ij} Y_{ij}^{tf}$$

(MHDB model) (4)

Sujeto a:

$$\sum_{(i,j) \in E} X_{ij}^{tf} - \sum_{(i,j) \in E} X_{ji}^{tf} = 1, \quad t \in T_f, f \in F, i = s \quad (5)$$

$$\sum_{(i,j) \in E} X_{ij}^{tf} - \sum_{(i,j) \in E} X_{ji}^{tf} = -1, \quad i, t \in T_f, f \in F \quad (6)$$

$$\sum_{(i,j) \in E} X_{ij}^{tf} - \sum_{(i,j) \in E} X_{ji}^{tf} = 0, \quad t \in T_f, f \in F, i \neq s, i \notin T_f \quad (7)$$

$$\sum_{f \in F} bwf \cdot \max(X_{ij}^{tf}) \leq c_{ij} \cdot \alpha, \quad \alpha \geq 0, (i, j) \in E \quad (8)$$

$$\sum_{\substack{j \in N \\ t \in T_f}} Y_{ij}^{tf} \leq \left[\begin{array}{c} bw_f \\ \hline \sum_{j \in N} c_{ij} \\ \hline \sum_{j \in N} connection_{ij} \end{array} \right], \quad i \in N, f \in F \quad (9)$$

donde

$$X_{ij}^{tf} \in \mathfrak{R}, 0 \leq X_{ij}^{tf} \leq 1 \quad (10)$$

$$Y_{ij}^{tf} = [X_{ij}^{tf}] = \begin{cases} 0, & X_{ij}^{tf} = 0 \\ 1, & 0 < X_{ij}^{tf} \leq 1 \end{cases} \quad (11)$$

$$\sum_{i=1}^m r_i = 1, r_i \in \mathfrak{R}, r_i \geq 0, m > 0 \quad (12)$$

La función multiobjetivo (MHDB model) (4) define la función y genera un solo métrico agregado por una combinación de objetivos.

El objetivo principal consiste en minimizar el máximo utilización de enlaces (MLU), el cual es representado con α en (4). En este caso, la solución obtenida

puede obtener rutas largas. El siguiente es la minimización de saltos (HC), el término $\sum_{f \in F} \sum_{t \in T} \sum_{f(i,j) \in E} Y_j^f$ es agregado. Esto es útil porque en la función objetivo puede mostrar sólo el link más congestionado y una solución óptima puede ser incluirlo en un camino innecesariamente largo con la finalidad de evitar el cuello de botella.

El siguiente objetivo es minimizar el consumo de ancho de banda (BC) sobre los enlaces; el término $\sum_{f \in F} \sum_{t \in T} \sum_{f(i,j) \in E} \max_{i \in T} (X_j^f)$ es también incluido.

Este término es incluido, ya que si se obtiene más de una solución como la mejor utilización máxima de enlaces, la solución escogida es la que tiene el mínimo uso de los recursos.

Además, se debe minimizar el retraso entre el total de todos los enlaces; el término $\sum_{f \in F} \sum_{t \in T} \sum_{f(i,j) \in E} v_j Y_j^f$ es incluido.

En (5),(6) y (7) se conserva el flujo. El (5) es el total de flujo para emerger de los nodos fuentes a los nodos destinos t , con un flujo f que puede ser 1. El (6) es el flujo total comenzando desde los nodos destinos t , en el flujo puede ser 1.

En el (7) se asegura que por los diferentes nodos intermedios de las fuentes ($i \neq s$) y los nodos destinos ($i \notin T$), la suma de las salidas de flujo a los nodos destinos t menos la entrada de flujo de los nodos destinos t debe dar como resultado 0.

El (8) el máximo uso de los link. En una conexión Unicast, el monto total de ancho de banda consumida por todos los flujos con destino a los nodos t puede no exceder la máxima utilización (α) por capacidad del enlace c_{ij} que es $\sum_{f \in F} b_w f \sum_{t \in T} X_j^f \leq c_{ij}, \alpha, (i, j) \in E$.

Hay que tener en cuenta que en (8) sólo el máximo valor de X_j^f para $t \in T_f$ debe ser considerado. Varios subflujos del flujo f en el enlace (i, j) son enviados a diferentes nodos destinos.

El (9) limita el máximo número de subflujos a cada nodo dependiendo de la capacidad de cada enlace y el tráfico por la demanda. Esta formulación representa el uso necesario de enlaces con la demanda del tráfico; sin este ítem, el modelo puede sufrir problemas de escalabilidad.

En (10) se muestra que la variable X_j^f puede ser un número real entre 0 y 1. Estas variables son para árboles múltiples para transportar flujo en multicast.

La demanda entre los nodos fuentes y los nodos destinos t puede ser por múltiples rutas. Cuando el problema es resuelto sin el balanceo de carga, esta variable puede tomar valores de 0 y 1, lo que demuestra si un enlace (i,j) es utilizado o no.

En (11) se calcula Y_j^f como una función de X_j^f .

Finalmente, en la expresión (12) se muestra que el peso de los coeficientes, r_i , es asignado cuando el objetivo es normalizado. Estos valores son calculados durante la solución del problema de optimización.

El problema presentado es NP-hard porque el problema de computación del costo mínimo en el árbol para un grupo multicast es conocido como un NP-Completo, y este modelo incluye variables reales y constantes enteros.

4. SOLUCIÓN ALGORÍTMICA A TRAVES DE TABÚ SEARCH

En nuestro caso en particular, una solución x es un conjunto de árboles, y un movimiento sería cambiar un árbol de la solución actual y obtener así un nuevo conjunto de árboles.

Dado que la cantidad de vecinos puede ser muy grande y elegir el mejor movimiento posible puede ser muy demorado, se toman 10 vecinos al azar, que luego pasan a ser evaluados, y aplicando la teoría de Optimización Multiobjetivo se selecciona el mejor árbol o un árbol que sea no dominado. El árbol que será escogido para ser cambiado por el vecino encontrado es un árbol dominado, el cual se selecciona antes de realizar la búsqueda del vecino.

Es posible que se presente el caso en que los movimientos disponibles sean todos Tabú, por lo que en este caso se hace uso del criterio de aspiración, en el cual, en nuestro caso, no se selecciona el mejor movimiento sino aquel que se encuentra penalizado por un menor número de iteraciones. Este tipo de criterio de aspiración se conoce como aspiración por defecto. Una vez seleccionado el movimiento se le agrega una penalización a éste y se actualiza los datos de la lista Tabú y se procede a seguir a otra iteración. Como se mencionó con anterioridad, un movimiento puede no llevar a una mejor solución, por lo que la mejor solución es guardada aparte y cada vez que se encuentra una solución mejor a ésta es actualizada. Una vez que se han examinado un número suficiente de movimientos, la solución procede a identificar los árboles que son dominados. La solución lo que busca es arrojar árboles Pareto Óptimos, y es posible que la mejor solución tenga árboles que no son Pareto Óptimos,

por esto se identifican estos árboles para retirarlos de la mejor solución encontrada, dejando solo así aquellos árboles que no son dominados y que serán la solución final.

5. SIMULACIÓN DE LA OPTIMIZACION MULTIOBJETIVO EN REDES MULTICAST

- GRÁFICAS DE VALORES PROMEDIO

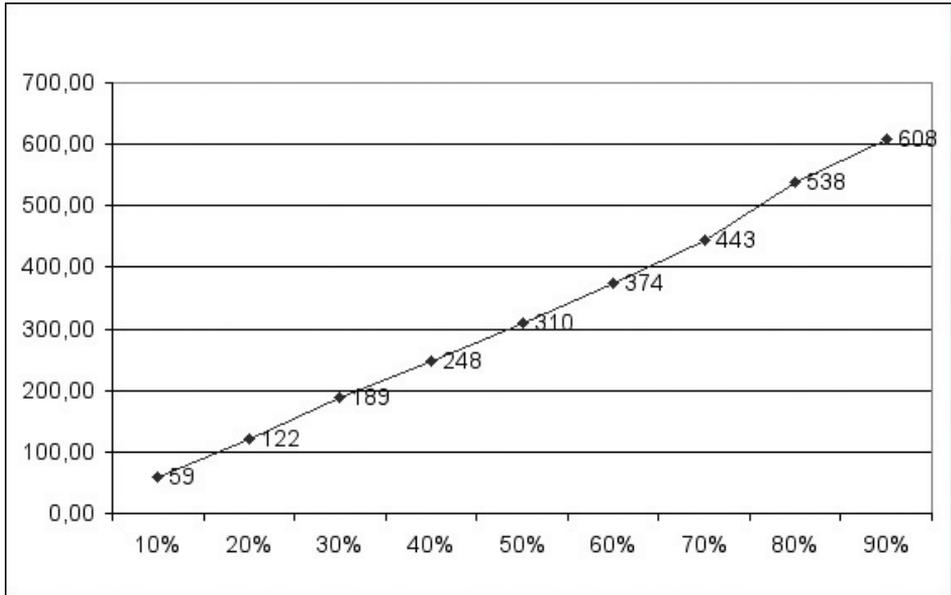
En la tabla 1 se muestran los valores promedios obtenidos para la topología de 50 nodos con diferentes destinos y los promedios encontrados para cada cantidad de destinos. La columna *Destinos* nos indica con cuántos nodos destinos se llevaron a cabo las pruebas. La columna *Porcentaje* nos indica qué porcentaje de la topología son nodos destinos, tomando como ejemplo la primera fila, en la que 5 es el 10% de 50. Las pruebas se hicieron hasta un porcentaje del 90%, o lo que es lo mismo, 45 destinos. La columna de *Hop Count* muestra el número promedio de saltos desde el nodo emisor, que es el nodo 0, hasta los nodos destinos; en la columna *Delay* se muestra el retardo promedio; en la columna *Bandwidth* se muestra el ancho de banda promedio.

Los caminos que fueron creados desde el nodo emisor hasta cada destino no superan los 15 saltos, y el Delay y el Bandwidth se crearon con valores entre un rango de 0-25 y 64-256 respectivamente.

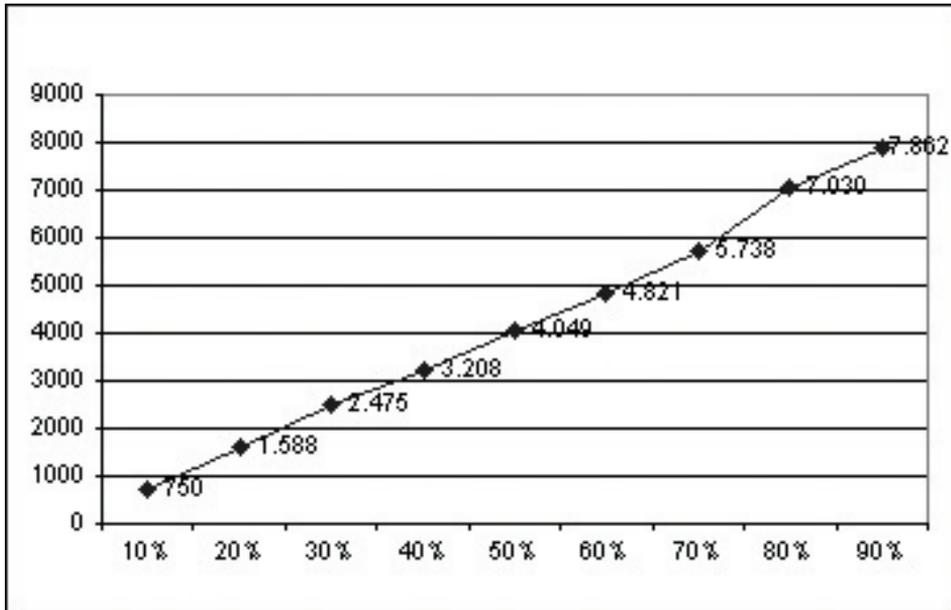
En las gráficas 1, 2 y 3 se coloca en el eje x el porcentaje de nodos destinos de la topología desde 10 hasta 90%, con incrementos de 10%. En el eje y se colocan los valores promedio obtenidos para Hop count, Delay y Bandwidth para cada porcentaje.

Tabla 1

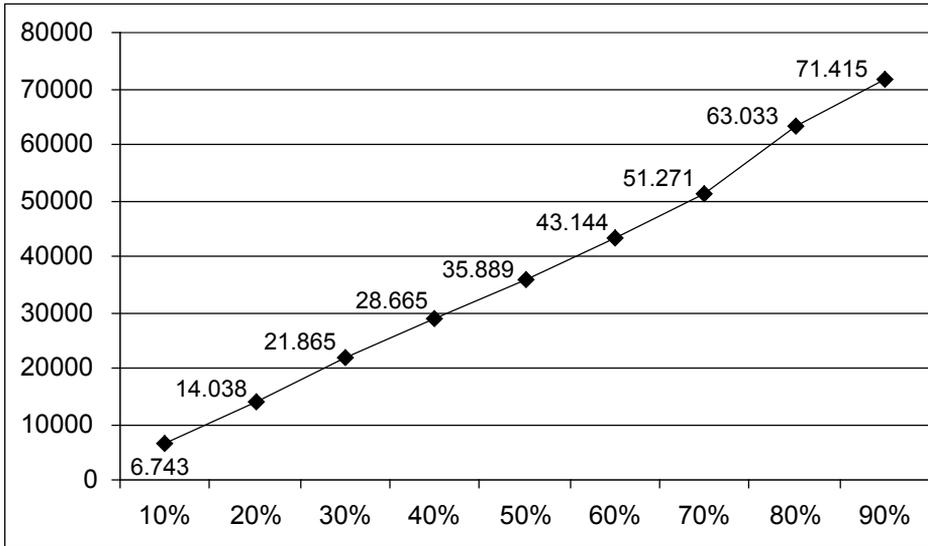
Destinos	Porcent.	Hop count	Delay	Bandwidth	Alpha
5	10%	58,75	749,5833333	6742,833333	0,509161
10	20%	122,08	1587,75	14037,91667	0,509161
15	30%	188,53	2474,866667	21865,2	0,509161
20	40%	248,33	3208,083333	28665	0,509161
25	50%	310,40	4048,8	35889	0,509161
30	60%	374,00	4821,166667	43144	0,509161
35	70%	442,93	5737,733333	51270,86667	0,509161
40	80%	537,69	7030,153846	63032,61538	0,509161
45	90%	608,44	7862,444444	71415,11111	0,509161



Gráfica 1. Red 50 Hop count



Gráfica 2. Red 50 Delay



Gráfica 3. Red 50 Bandwidth

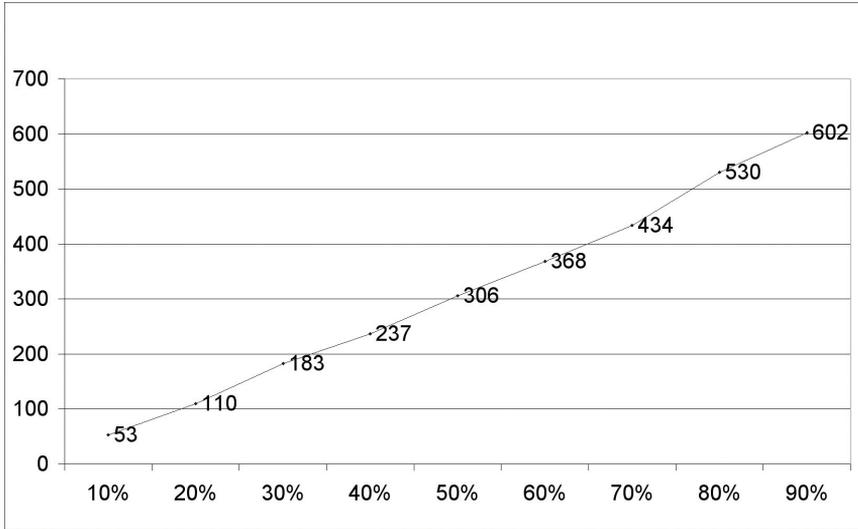
- GRÁFICAS DE VALORES MÍNIMOS

La tabla 2 muestra los valores mínimos encontrados por la solución simulada luego de 5 intentos para las diferentes cantidades de destinos. La primera columna indica el número de destinos, y las columnas 2, 3 y 4 indican el Hop count, el Delay y el Bandwidth respectivamente.

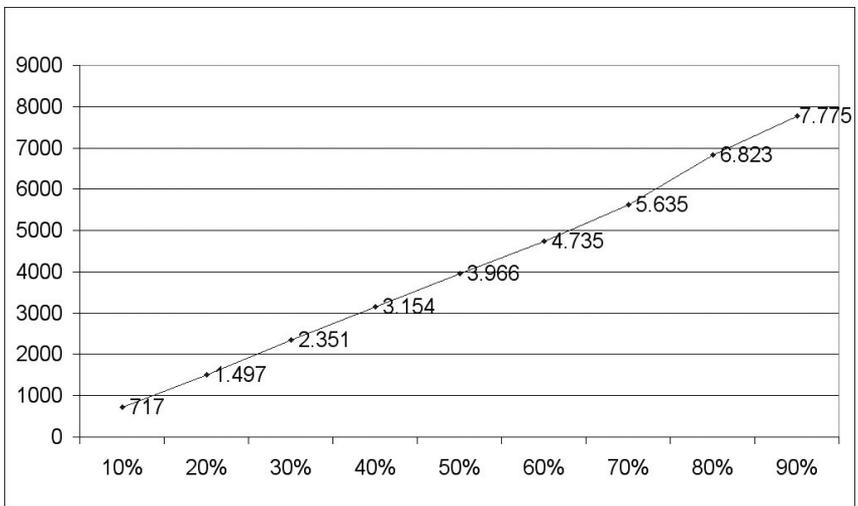
Tabla 2

Destinos	Porcent.	Hop count	Delay	Bandwidth	Alpha
5	10%	53	717	6134	0,509161
10	20%	110	1497	12830	0,509161
15	30%	183	2351	21204	0,509161
20	40%	237	3154	27531	0,509161
25	50%	306	3966	35444	0,509161
30	60%	368	4735	42713	0,509161
35	70%	434	5635	50164	0,509161
40	80%	530	6823	62235	0,509161
45	90%	602	7775	70503	0,509161

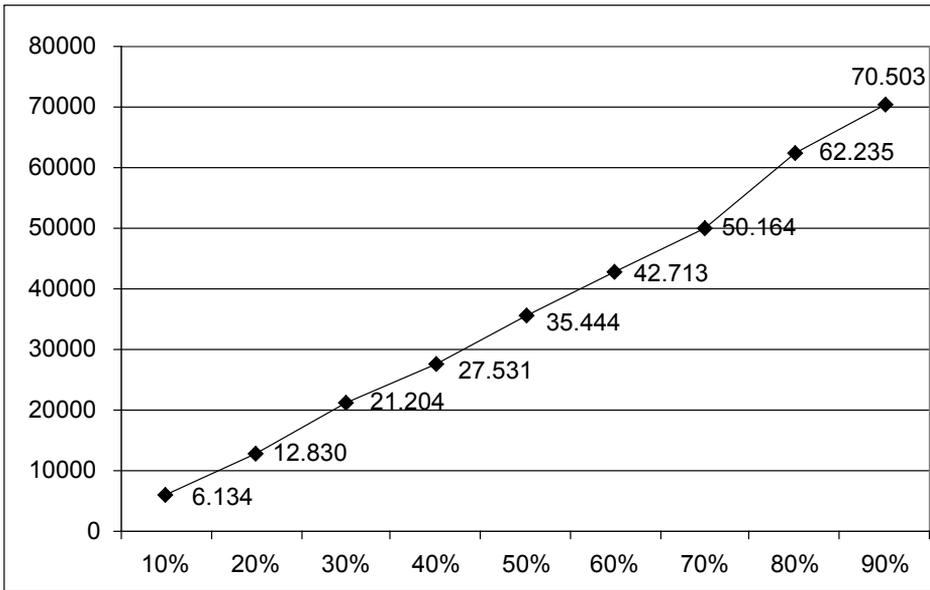
Las gráficas 4, 5 y 6 muestran los valores de la tabla 2 y su comportamiento. En el eje x se encuentra la cantidad de nodos en porcentaje, y en el eje y los valores mínimos encontrados por la solución que se encuentran en la tabla. Al igual que las gráficas de valores promedios, las gráficas de valores mínimos aumentan proporcionalmente al número de destinos, y describen un crecimiento lineal.



Gráfica 4. Red 50 Hop count



Gráfica 5. Red 50 Delay



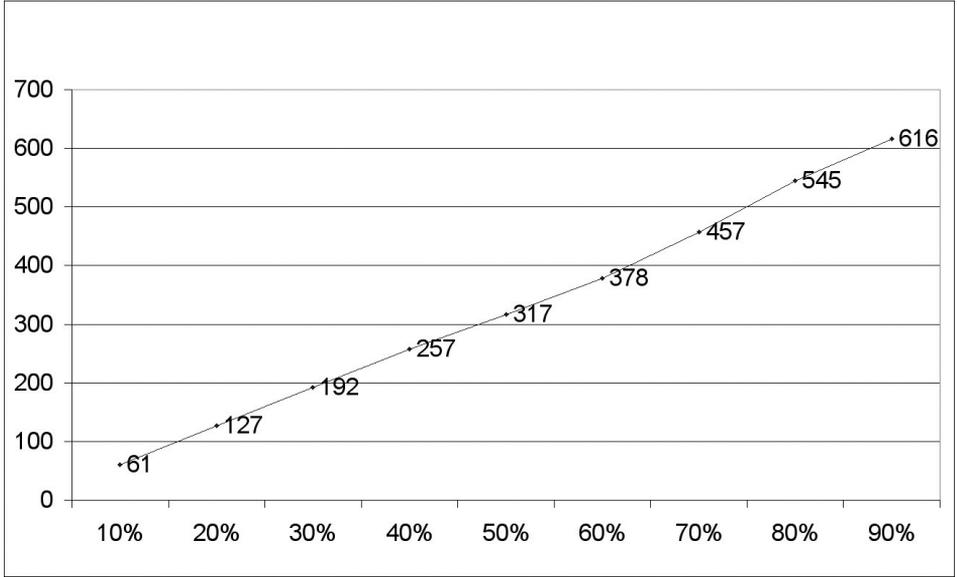
Gráfica 6. Red 50 Bandwidth

- GRÁFICAS DE VALORES MÁXIMOS

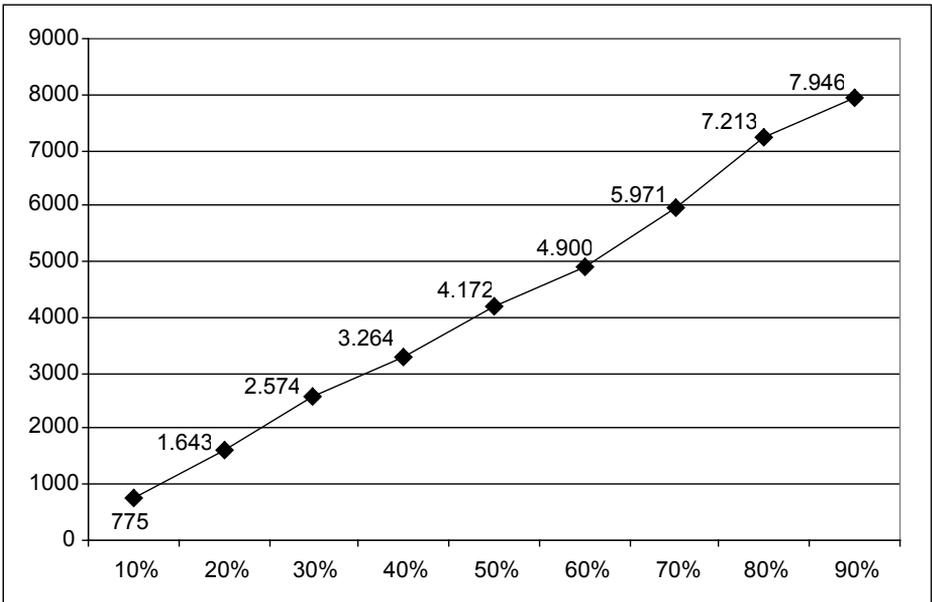
La tabla 3 contiene los valores máximos encontrados durante las pruebas para los diferentes números de destinos. En la primera columna se muestra el número de destinos, y en las columnas 3, 4 y 5 se muestran los valores mínimos para el Hop count, el Delay y el Bandwidth respectivamente.

Tabla 3

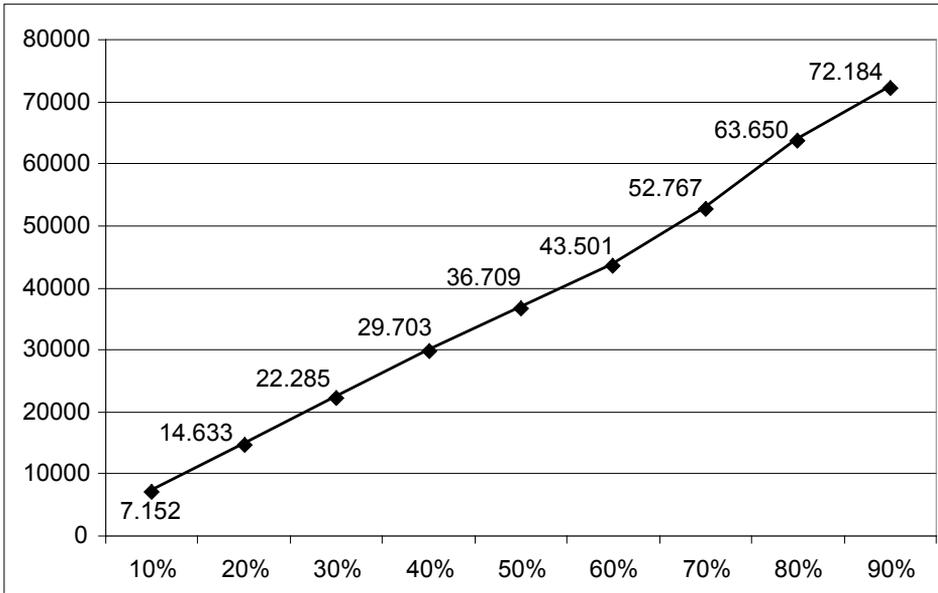
Destinos	Porcent.	Hop count	Delay	Bandwidth	Alpha
5	10%	61	775	7152	0,509161
10	20%	127	1643	14633	0,509161
15	30%	192	2574	22285	0,509161
20	40%	257	3264	29703	0,509161
25	50%	317	4172	36709	0,509161
30	60%	378	4900	43501	0,509161
35	70%	457	5971	52767	0,509161
40	80%	545	7213	63650	0,509161
45	90%	616	7946	72184	0,509161



Gráfica 7. Red 50 Hop count



Gráfica 8. Red 50 Delay



Gráfica 9. Red 50 Bandwidth

El eje x de las gráficas 7, 8 y 9 representa el número de destinos como porcentaje del número de nodos en la topología, el eje y representa los valores del Hop count, el Delay y el Bandwidth. Al igual que los dos grupos de gráficas anteriores, éstas también tienen un comportamiento lineal.

CONCLUSIONES

En este artículo se presentó una meta-heurística (Tabú Search) para resolver un problema NP-Hard como es el de la optimización de múltiples objetivos en la transmisión de información a múltiples destinos y con múltiples flujos. Al comparar los valores arrojados por la solución simulada de Tabú Search con los resultados de la solución analítica, nos podemos dar cuenta de que Tabú Search obtiene valores cercanos que los calculados por la solución analítica. El método propuesto logró resolver un problema por naturaleza NP-Hard en tiempo polinomial debido a su comportamiento probabilístico. Finalmente se menciona como conclusión que este tipo de meta-heurísticas da solución a problemas lineales y no lineales, pero además a problemas cuyo conjunto de soluciones factibles sea convexo o no convexo.

REFERENCIAS

- BARÁN, B. & DUARTE, S. (2000). Multiobjective network design optimization using parallel evolutionary algorithms. Centro Nacional de Computación, Universidad de Asunción.
- COELLO, C.A. (2003). *Evolutionary Algorithms for solving Multi-Objective Problems*. Kap.
- DEB, K. (2002). *Multi-Objective Optimization using Evolutionary Algorithms*. Wiley.
- GLOVER, F.W. (2000). *Tabu Search*. Wiley.
- KOSIUR, D. (1998). *IP Multicasting: The Complete Guide to interactive Corporate Network*. Wiley.
- WITTMAN, R. & ZITTERBART, M. (2002). *Multicast Communication Protocols and Applications*. Wiley.