

COMPARACIÓN DE ESTRATEGIAS PARA EL DISEÑO ÓPTIMO MULTIOBJETIVO DE REDES INALÁMBRICAS

Ivana P. Cruz^a, Silvia B. Simón^b, José Luis Hernández^{a,b}, Mercedes Carnero^b

^a*Grupo de Investigación y Desarrollo Aplicado a las Telecomunicaciones, Universidad Nacional de Río Cuarto, Campus Universitario, 5800 Río Cuarto, Argentina, icruz@ing.unrc.edu.ar*

^b*Grupo de Optimización, Departamento de Ciencias Básicas, Universidad Nacional de Río Cuarto, Campus Universitario, 5800 Río Cuarto, Argentina, jlh@ing.unrc.edu.ar*

Palabras claves: Redes inalámbricas, Optimización combinatoria, Optimización multiobjetivo

Resumen. La determinación de la infraestructura de redes inalámbricas involucra como tarea principal la ubicación de las antenas. Esto es especialmente importante en las redes de tipo celular, ya que el emplazamiento de una antena determina la celda que cubre y en definitiva la cobertura que ofrecerá la red. El problema de diseño óptimo que se plantea entonces, es encontrar aquellas localizaciones candidatas que permitan cubrir la mayor área posible, considerando las diferentes demandas de cada una de las áreas involucradas, al tiempo que se minimiza el número de antenas que deben instalarse y la interferencia resultante entre ellas. Uno de los rasgos distintivos de dicho problema de diseño es su carácter multiobjetivo, ya que deben atenderse simultáneamente criterios de desempeño en conflicto.

El objetivo de este trabajo es resolver este problema a través de la utilización de dos enfoques metaheurísticos diferentes. En el primero de ellos, basado en búsqueda tabú, los objetivos del problema son combinados en una sola función objetivo, parametrizada, que puede incluir implícitamente información adicional sobre la preferencia o peso dado a cada objetivo.

El segundo enfoque utiliza técnicas de optimización multiobjetivo basadas en algoritmos evolutivos, en este caso la optimización se lleva a cabo sin ninguna información de preferencia dada, El resultado es un conjunto de soluciones, que son idealmente Pareto-óptimas, a partir del cual se realiza la selección final

Se presenta un ejemplo de aplicación del problema y se analizan los resultados obtenidos para comparar la eficiencia y desempeño de los métodos propuestos, como herramientas válidas en la toma de decisiones en la etapa de diseño de redes inalámbricas.

1 INTRODUCCIÓN

El dimensionamiento de las redes inalámbricas celulares implica la toma de decisiones en función de distintas características y parámetros. Uno de los más importantes objetivos de la planificación de sistemas de telecomunicaciones móviles es el diseño de la configuración necesaria para prestar un servicio de manera óptima respecto de algún criterio de desempeño, a la vez que se satisface un conjunto de restricciones. Los criterios de desempeño pueden ser, por ejemplo el costo asociado a la topología o la calidad del servicio ofrecido.

Existen distintos factores a tener en cuenta cuando se desea estructurar un sistema de telefonía celular, tales como: cantidad de Radio Bases (RB) a utilizar, ubicación de las mismas, potencia de irradiación de la señal, área de cobertura, características del terreno, transceptores móviles de potencia más reducida, reglamentaciones vigentes, solapamiento de cobertura e interferencia entre las frecuencias de las RB, entre otras.

El problema fundamental se denomina Localización de Radio Bases (LRB) y es parte de la etapa de planificación de los sistemas de celular. El planteo anterior se puede asimilar al problema del Conjunto Mínimo Dominante (*Minimum Dominating Set*, MDS), el cual ha sido catalogado como NP-Completo, (Garey, M. y Johnson, D. 1999) y es de gran importancia en el diseño de redes eficientes y de bajo costo. Los problemas de tipo NP-Completo o NP-*Hard*, son aquellos para los cuales no se conoce, hasta la fecha, la forma de resolver cualquier instancia de los mismos en tiempos acotados polinomialmente.

Esta clase de problemas son de gran relevancia, no sólo por su interés teórico, sino también porque pueden asimilarse a una gran cantidad de problemas de optimización topológica de redes, que son problemas clásicos de investigación operativa, con aplicabilidad práctica en diversos campos de las telecomunicaciones, diseño de redes de computadoras, etc.

2 PLANTEAMIENTO DEL PROBLEMA

Existen diferentes modelos para el LRB los cuales difieren principalmente en la definición de los elementos del problema: el área de trabajo, el conjunto de localizaciones candidatas y el criterio de desempeño elegido (Touhami, S. 2004).

El área de trabajo o de servicio puede ser modelada introduciendo el concepto de “nodos de demanda” propuesto en (Tutschku, K., Gerlich, N., Tran-Gia, P. 1996), el cual permite discretizar la misma y considerar que la demanda está uniformemente distribuida en toda el área a cubrir.

Es posible entonces dividir el área total de servicio en una grilla de $m \times n$ cuadros, algunos de los cuales albergan a las posiciones candidatas a colocar RB. De esta manera el área de cobertura total puede ser representada por una matriz \mathbf{A} de dimensión $m \times n$ donde cada elemento a_{ij} representa un nodo de demanda.

Las localizaciones en las que es posible instalar RBs para dar servicio a un área se denominan “Localizaciones Candidatas”. Las mismas se determinan por diversas restricciones, siendo las geográficas y las económicas las principales.

Posteriormente al proceso de obtener las localizaciones candidatas, se lleva a cabo el proceso de optimización para determinar en cuales de ellas se colocará una RB para dar el servicio requerido.

El problema de optimización combinatoria planteado, en este trabajo, es encontrar una topología para la ubicación del conjunto de RB candidatas de tal manera de maximizar el área de cobertura total y minimizar la cantidad de RB utilizadas a la vez que se satisface la restricción de no superar un umbral prefijado para el solapamiento de la cobertura individual de cada RB.

Para computar el área cubierta por una RB se calcula la pérdida de potencia de la señal P_p , respecto de cada nodo en función de su distancia a la antena a través de la siguiente expresión:

$$P_p = a + b * \log(d) + N(\mu, \sigma) \quad (1)$$

Donde a y b son constantes, d es la distancia euclidiana de la antena a cada nodo, $N(\mu, \sigma)$ es una variable aleatoria gaussiana con media μ y varianza σ^2 . La P_p es calculada para cada radio base y cada nodo de demanda. Si P_p es menor que cierto umbral δ en un nodo dado, entonces el nodo es cubierto por la radio base y se considera como atendido.

Si un nodo de demanda es atendido por dos o más RB se considera que existe solapamiento en la cobertura. El grado de solapamiento (g_s) exhibido es igual a la cantidad de RB que dan servicio a un mismo nodo. En función del valor de g_s se define el umbral de solapamiento u_s como una cota máxima de solapamiento permitida.

Sea $S = \{S_1, S_2, \dots, S_k\}$ el conjunto de localizaciones candidatas de RB, se define a \mathbf{x} como un vector binario de dimensión k que representa la topología de RB propuesta, tal que $x_i=1$ si S_i del conjunto S es utilizado y $x_i=0$ caso contrario.

Dada $A^{m \times n}$, matriz que representa el área a cubrir de tal manera que $a_{ij}=1$ si el nodo de demanda ij es cubierto por una RB, $a_{ij} \geq 2$ si es cubierto por 2 ó más RB, respectivamente, y $a_{ij}=0$ si el nodo de demanda no recibe cobertura.

Sea C_m la cobertura máxima inicial del problema, calculada como sigue:

$$C_m = \sum_{i=1}^m \sum_{j=1}^n a_{ij} \quad \text{dado que } \sum_{i=1}^k x_i = k$$

donde

$$\begin{cases} a_{ij} = 1 & ; \text{si es cubierta por al menos una RB} \\ a_{ij} = 0 & ; \text{caso contrario.} \end{cases} \quad (2)$$

Por lo tanto, C_m es el área cubierta por el sistema cuando son utilizadas todas las RB candidatas.

Formalmente, el problema a resolver en este trabajo puede ser expresado como sigue:

$$\begin{aligned} f_1 &= \min \sum_{i=1}^k x_i \\ f_2 &= \max \sum_{i=1}^m \sum_{j=1}^n a_{ij} \\ \vec{f} &= (f_1, f_2) \end{aligned} \quad (3)$$

Sujeto a

$$a_{ij} \leq u_s$$

Es decir, el objetivo es, optimizar la función vectorial \vec{f} que tiene incorporada las funciones en conflicto f_1 y f_2 donde respectivamente se pretende minimizar la cantidad de RB utilizadas y maximizar el área de cobertura, todo esto contemplando que la cobertura de los nodos de demanda no supere el umbral de solapamiento u_s .

3 METODOLOGÍAS UTILIZADAS

El problema de optimización combinatoria planteado, dada su categoría NP-Hard necesita ser abordado mediante métodos de resolución que posibiliten la entrega de soluciones en tiempos razonables. Las técnicas metaheurísticas han probado ser una alternativa válida en el tratamiento de este tipo de problemas.

En este trabajo se pretende, en primera instancia, resolver el problema planteado implementando Algoritmos Evolutivos Multiobjetivo (MOEA).

Los resultados serán comparados con los arrojados utilizando una metodología basada en la heurística de búsqueda tabú (TS) enriquecida con una técnica de oscilación estratégica (SO).

En las secciones siguientes se describen los aspectos relevantes de ambos enfoques.

4 ALGORITMOS EVOLUTIVOS MULTI OBJETIVO

La optimización Multiobjetivo tiene en cuenta el análisis de un conjunto de funciones objetivo que se encuentran en conflicto. Por consiguiente la optimización hará que la mejora de uno de ellos dé lugar a un empeoramiento de algún otro. En la optimización multiobjetivo se espera encontrar un conjunto de soluciones que son superiores a las restantes cuando se consideran simultáneamente todos los objetivos, pero que son inferiores a otras soluciones en el espacio de búsqueda de uno o más criterios de optimización. Los problemas de optimización multiobjetivo con funciones objetivos en conflicto dan lugar a un conjunto de soluciones óptimas, en lugar de una única solución, a las cuales se las denomina soluciones Pareto Óptimas. El concepto de eficiencia de Pareto es aquella situación en la cual se cumple que no es posible beneficiar a más elementos de un sistema sin perjudicar a otros. Definido como:

Se dice que una solución \mathbf{q} domina a otra solución \mathbf{p} si se verifican simultáneamente las siguientes condiciones:

- a) La solución \mathbf{q} no es peor (el operador \prec denota peor y el operador \succ denota mejor) que \mathbf{p} en todos los objetivos, esto es $f_a(\mathbf{q}) \not\prec f_a(\mathbf{p}) \quad \forall a=1,2,\dots,nof$,
- b) La solución \mathbf{q} es estrictamente mejor que \mathbf{p} por lo menos en un objetivo, esto es $f_a(\mathbf{q}) \succ f_a(\mathbf{p})$ para algún $a \in \{1,2,\dots,nof\}$.

Todas las soluciones no dominadas forman el conjunto P de soluciones Pareto Óptimas; los correspondientes vectores objetivo forman la superficie o el frente Pareto óptimo.

En la resolución del problema multiobjetivo planteado se pretende muestrear el conjunto factible y obtener el conjunto de soluciones Pareto para luego indagar en la toma de decisiones abocada a la selección de una solución de compromiso adecuada.

Los Algoritmos Evolutivos Multiobjetivo permiten manejar espacios de búsqueda grandes, generar múltiples soluciones Pareto en una única corrida y evitar, mediante una implementación adecuada, la sensibilidad hacia regiones Pareto convexas.

Las dos principales cuestiones a tener en cuenta cuando se aplica un MOEA a la resolución de este tipo de problemas son:

- a) Como llevar a cabo la asignación de fitness y por consiguiente la selección, con el propósito de dirigir la búsqueda hacia el conjunto Pareto-óptimo.
- b) Mantener cierta diversidad en la población en el frente Pareto óptimo, con el fin de obtener un conjunto de soluciones no dominadas con una distribución uniforme y extendida.

La forma de resolver las dificultades previamente mencionadas ha dado origen a un número considerable de diferentes métodos durante la última década. Una muy completa revisión de estas metodologías pueden encontrarse en el libro de Coello Coello (2002).

En este trabajo se implementa una metodología basada en el enfoque original propuesto por Deb y colaboradores, (2002) donde se incorpora elitismo. Esta metodología ha sido utilizada con buenos resultados en la resolución de problemas de optimización combinatoria multiobjetivo (Carnero y co., 2001a y b).

En este procedimiento se utiliza el concepto de Pareto dominancia para la asignación de fitness. Primero se le asigna rango uno a todos los individuos no dominados y se los elimina temporalmente de la población. Este conjunto constituye, lo que se denomina el primer frente. A los siguientes individuos no dominados se les asigna rango dos, y así sucesivamente, de

modo tal que al final de este procedimiento, la población se ha dividido en b frentes.

Finalmente, se determina un mismo valor de fitness ficticio, F'_k ($k = 1, \dots, b$), para todos los individuos pertenecientes al k -ésimo frente, con el fin de otorgarle un mismo potencial de reproducción.

Para mantener la diversidad de la población se utiliza una técnica de distribución (sharing) del fitness ficticio. Esta técnica intenta promover la formación y mantenimiento de subpoblaciones estables, llamadas nichos. Se basa en la idea que los individuos pertenecientes a un nicho particular tienen que compartir los recursos disponibles. Cuantos más individuos estén localizados en la vecindad de un individuo particular, su valor de fitness se degrada más en relación con el fitness ficticio del frente al que pertenece.

El término vecindad se define en relación a alguna medida de distancia o norma, especificada por el denominado radio de nicho, r_n . En cuanto a la degradación del fitness, para cada individuo \mathbf{q} perteneciente a un frente dado $\overline{\mathbf{P}}_k$, el valor de fitness ficticio del frente se divide por una cantidad proporcional al número de individuos que lo rodean, tal como indica la siguiente expresión:

$$F(\mathbf{q}) = \frac{F'_k}{\sum_{\mathbf{p} \in \overline{\mathbf{P}}_k} Sh(d(\mathbf{q}, \mathbf{p}))} \quad (4)$$

donde

$$Sh(d(\mathbf{q}, \mathbf{p})) = \begin{cases} 1 - \left(\frac{d(\mathbf{p}, \mathbf{q})}{r_n} \right)^2 & \text{si } d(\mathbf{q}, \mathbf{p}) \leq r_n \\ 0 & \text{en caso contrario} \end{cases} \quad (5)$$

siendo $d(\mathbf{q}, \mathbf{p})$ la distancia entre la solución \mathbf{p} y la solución \mathbf{q} .

Este nuevo valor de *fitness* degradado se emplea para llevar a cabo el proceso de selección.

A continuación se describen las etapas de la estrategia propuesta:

- a) **Inicialización:** generación de la población inicial \mathbf{P}_0 , aleatoriamente y creación de un conjunto de elite externo $\mathbf{P}_{\text{elite}} = \mathbf{0}$
- b) **Construcción de los diferentes frentes y asignación de fitness:**
 - i) Asignar $\mathbf{P}_{\text{auxiliar}} = \mathbf{P}(t)$; e inicializar el valor de fitness ficticio en $F' = 1$ y $k = 1$
 - ii) Determinar el conjunto $\overline{\mathbf{P}}_k$ de individuos en $\mathbf{P}_{\text{auxiliar}}$ que no son dominados. Este conjunto constituye el frente k . Ignorar este frente en las futuras clasificaciones, ésto es $\mathbf{P}_{\text{auxiliar}} = \mathbf{P}_{\text{auxiliar}} - \overline{\mathbf{P}}_k$
 - iii) Si $k=1$ copiar en $\mathbf{P}_{\text{elite}}$ aquellos individuos que pertenecen al primer frente, $\mathbf{P}_{\text{elite}} = \overline{\mathbf{P}}_1$
 - iv) Hacer $k=k+1$
 - v) Realizar la distribución de fitness sobre el conjunto $\overline{\mathbf{P}}_k$ de acuerdo a la ecuación (4) y asignar el fitness F . La distancia entre dos individuos cualesquiera se define como la distancia de Hamming
 - vi) Incrementar el fitness ficticio de tal forma que sea el mayor de los fitness en $\overline{\mathbf{P}}_k$:

$$F' = \max \{ F(i) / i \in \overline{\mathbf{P}}_k \}$$

- vii) Si $P_{\text{auxiliar}} \neq \emptyset$ volver al paso ii), sino parar.
- b) **Elitismo:** éste consiste en la creación y actualización de un conjunto de elite que almacena en cada generación los mejores individuos, es decir aquellas soluciones que pertenecen al primer frente, junto con un mecanismo de decisión que contempla cuales individuos son reinsertados en la población. Los criterios utilizados son los siguientes:
- i) Actualización del conjunto externo: una vez que son incorporados los elementos del primer frente en cada generación, los individuos del conjunto de elite son a su vez clasificados de acuerdo a su dominancia
 - ii) Los individuos no dominados del conjunto de elite pasan a la generación siguiente.
- d) **Selección, cruzamiento y mutación:** se utiliza una selección por torneo binario, cruzamiento uniforme y mutación estándar.

5 BÚSQUEDA TABÚ

Se propone en este punto resolver el problema planteado en la sección 2 utilizando una heurística basada en Búsqueda Tabú. Para ello los objetivos a optimizar son combinados en una sola función objetivo, parametrizada, que incluye la preferencia o peso de cada objetivo. Dichos parámetros son sistemáticamente variados por el optimizador de modo tal de obtener diferentes soluciones Pareto. La metodología de TS utiliza un procedimiento de búsqueda local para explorar el espacio de soluciones, junto con mecanismos de memoria adaptiva diseñados para evitar el estancamiento en mínimos locales y la visita cíclica de las mismas soluciones. La información histórica acerca del proceso de búsqueda de soluciones es almacenada en las llamadas listas tabú. A continuación se describen los aspectos más relevantes del método planteado.

5.1 Definición de vecindades

Dada una solución \mathbf{x} , su vecindad $N(\mathbf{x})$ está definida como el conjunto de soluciones \mathbf{x}' obtenidas por el agregado (fase constructiva) o la eliminación (fase destructiva) de una estación de RB. El conjunto de soluciones \mathbf{x}' comprende soluciones que están a una distancia de Hamming de uno respecto a \mathbf{x} , esto es:

$$N(\mathbf{x}) = \{\mathbf{x}' / x'_i \neq x_i \text{ y } x'_j = x_j \forall j \neq i\} \quad (6)$$

5.2 Memorias de corto y largo plazo

La lista tabú basada en lo reciente está representada por un vector de dimensión k . Una componente distinta de cero en dicho vector indica que el movimiento de dicha variable está prohibido ya que ha sido modificada recientemente. Su valor es precisamente el número de iteraciones restantes hasta que el periodo tabú de este movimiento haya transcurrido.

La lista tabú basada en la frecuencia también se representa mediante un vector \mathbf{h} de dimensión k , sólo que a diferencia del caso anterior la i -ésima componente de \mathbf{h} reporta el número de movimientos de la variable i usado para generar la próxima solución durante las ph iteraciones. Esto permite dirigir la búsqueda hacia regiones no visitadas o exploradas con menor frecuencia. Como consecuencia la función de evaluación correspondiente al i -ésimo movimiento permitido se penaliza en proporción a hi . Luego de ph iteraciones el vector \mathbf{h} es reiniciado.

5.3 Criterios de aspiración y terminación

El estado tabú de una solución puede ser revocado si esta tiene asociado un mejor valor

de función de evaluación que la mejor solución \mathbf{x}^* encontrada hasta el momento.

El criterio de finalización para el algoritmo fue el de terminación por convergencia: si la mejora en las soluciones obtenidas, luego de T iteraciones, no es mayor que cierto límite, la búsqueda es detenida.

5.4 Función de evaluación

El problema a resolver planteado en la ecuación (3), constituye un problema multiobjetivo, con dos criterios de desempeño en conflicto. Se propone transformarlo en un problema de optimización escalar, donde la nueva función objetivo era una combinación lineal de ambos criterios. La función de evaluación considera esta formulación, incluyendo un escalamiento adecuado.

Además, dado que un movimiento puede originar una solución no factible, cada elemento de una vecindad es evaluado utilizando la función $\Psi(\mathbf{x})$, que considera la restricción del problema, como sigue:

$$\Psi(\mathbf{x}) = \begin{cases} f(\mathbf{x}) & \text{si } \mathbf{x} \text{ está en la zona factible} \\ f(\mathbf{x}) + P(\mathbf{x}) & \text{si } \mathbf{x} \text{ no es factible} \end{cases}$$

donde

$$f(\mathbf{x}) = \alpha \frac{1}{k} \sum_{i=1}^k x_i + \beta \frac{1}{m \times n} \left(Cm - \sum_{i=1}^m \sum_{j=1}^n a_{ij} \right)$$

Siendo:

α y β los pesos de la combinación lineal de las funciones a optimizar. $1/k$ y $1/(m*n)$ se consideran como factores de escalamiento de cada una de las funciones. $P(x)$ es la función de penalización que tiene en cuenta el grado de violación de la restricción y esta dada por:

$$P(x) = (g_m - u_s)^2$$

donde g_m es el grado mayor de solapamiento para la solución corriente y u_s es el umbral de solapamiento permitido.

6 EXPERIMENTOS Y RESULTADOS

Los algoritmos propuestos se ejecutaron para un ejemplo de 841 nodos de demanda distribuidos en un área representado por una matriz $A^{29 \times 29}$. El conjunto de localizaciones candidatas, representado por el vector S , consta de 100 elementos, distribuidos según se muestra en la tabla 1. Además, en la misma se observan los datos correspondientes al área máxima cubierta C_m (medida en términos de cantidad de nodos de demanda atendidos) y el grado de solapamiento inicial g_{si} .

S	1 12 25 37 49 52 62 71 85 96 101 108 112 117 120 122 129 138 161 163 183 189 200 206 232 242 244 250 266 275 288 294 306 309 325 333 337 350 352 363 364 365 385 394 404 423 433 434 460 467 471 482 484 495 499 500 509 510 511 514 527 529 539 542 559 580 585 588 604 609 611 612 613 619 627 637 658 661 682 687 688 692 694 702 709 711 724 730 752 753 765 780 789 800 801 805 826 835 836 841
C_m	815
g_{si}	10

Tabla 1. Datos para el ejemplo propuesto.

Para el Algoritmo Evolutivo se diseñaron dos experiencias variando la cantidad de

iteraciones entre 500 y 1500, utilizando en ambas los valores para los parámetros que se muestran en la tabla 2.

Tamaño de la población	150
Probabilidad de cruzamiento	0.7
Probabilidad de mutación	0.01
r_n (radio de nicho)	0.4

Tabla 2: Parámetros utilizados por el MOEA

En el caso de TS se ejecutaron experiencias para 50 valores de los parámetros α y β , no observándose variaciones en el conjunto de resultados obtenidos al aumentar el número de valores de los parámetros de la combinación lineal.

Los conjuntos de soluciones no dominadas o frentes de aproximación que se obtuvieron para cada caso, se muestran en la figuras 1 y 2 respectivamente. El área cubierta se mide en cantidad de nodos de demanda atendidos por al menos una radio base.

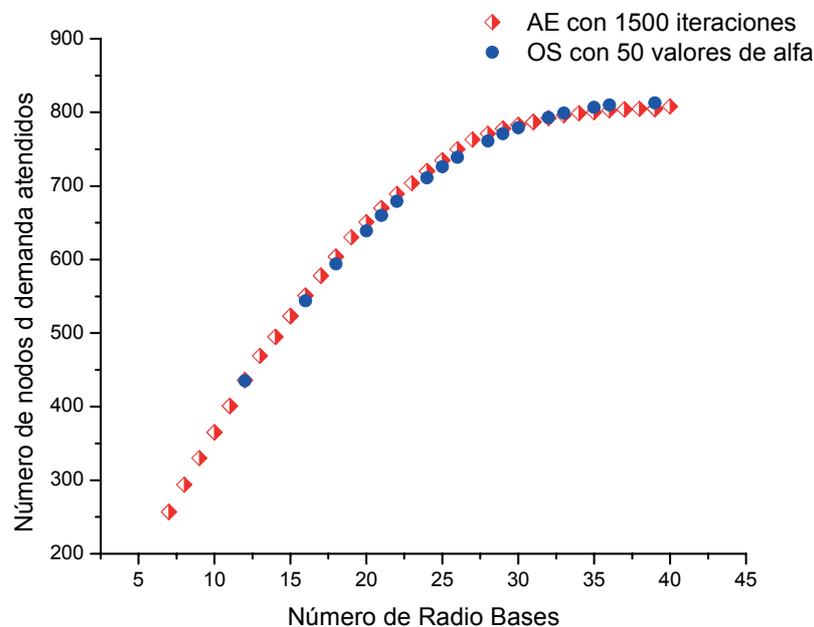


Figura 1: Frente de aproximación: RB utilizada y Área de cobertura. 1500 iteraciones del MOEA

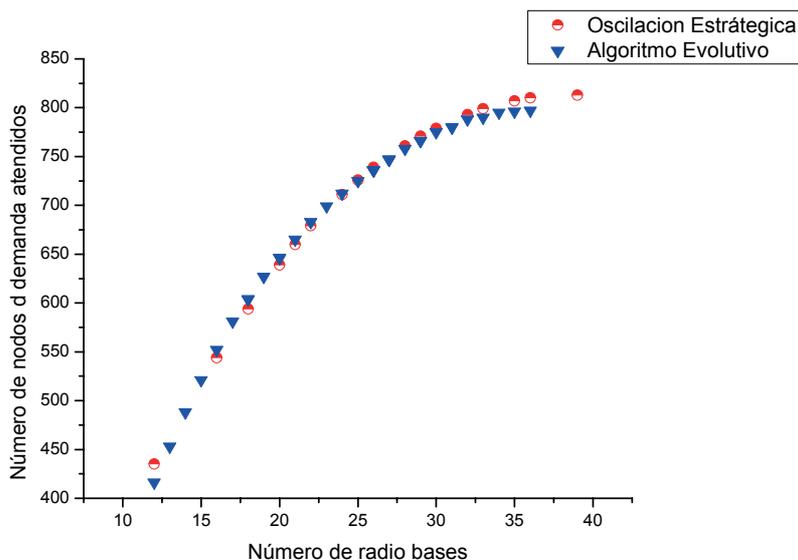


Figura 2: Frente de aproximación: RB utilizada y Área de cobertura. 500 iteraciones del MOEA

7 CONCLUSIONES

En este trabajo se propusieron dos enfoques metaheurísticos: el primero de ellos un Algoritmo Evolutivo Multiobjetivo y el segundo de ellos basado en el paradigma de búsqueda tabú para la resolución del dimensionamiento de una red de telefonía celular. El diseño óptimo tuvo en cuenta la minimización del costo de instalación (el número de RB a instalar) y la maximización del área de cobertura. Se obtuvieron con ambas metodologías curvas de soluciones no dominadas que brindan al prestador de servicio una herramienta para la toma de decisiones. La valoración del desempeño de ambos optimizadores multi-objetivo debería tomar en cuenta al menos los siguientes dos criterios: la distancia al frente óptimo de Pareto de las soluciones obtenidas y la distribución de dichas soluciones. En este problema particular el verdadero frente Pareto óptimo es desconocido y por lo tanto la valoración es sólo cualitativa. En este sentido, el MOEA ofrece curvas más extendidas, con mayor número de soluciones y con una mejor distribución de las mismas, cuando es ejecutado con un mayor número de iteraciones. Entre las desventajas de este método se encuentra el alto tiempo de cómputo que insume comparado con el TS.

REFERENCIAS

- Carnero, M.; J. Hernández, M. Sánchez and A. Bandoni, "Multiobjective Evolutionary Optimization in Sensor Network Design," Proc. of ENPROMER'01 – 3rd Congress on Process Engineering for the MERCOSUR, Santa Fé, Argentina, 325-330 (2001a).
- Carnero, M., J. Hernández, M. Sánchez and A. Bandoni, "An Evolutionary Approach for the Design of Non-Redundant Sensor Networks," Industrial and Engineering Chemistry Research, 40, 5578-5584 (2001b).
- Coello Coello, C, D. Van Veldhuizen, G. Lamont Evolutionary Algorithms for Solving Multiobjective Problems. Kluwer Academic Publishers, New York. (2002).
- Deb, K., A. Pratap, S. Agarwal, y T. Meyarivan, " A fast elitist multiobjective genetic algorithm: NSGA II", IEEE Transactions on Evolutionary Computation, 6(2), 182,197, (2002).
- Garey, M. y Johnson, D., Computers and Intractability. A guide to the theory of NP-Completeness, W.H. Freeman and Company, New York. 1999
- Glover, F. y Laguna, M., Tabu Search. Kluwer Academic Publishers, M.A (1997).

- Punnen, A. y Aneja, P. A Tabu Search Algorithm for the Resource-Constrained Assignment Problem. *The Journal of the Operational Research Society*, Vol. 46, No. 2, pp. 214-220 1995.
- Touhami, S. Optimization Problems in Cellular Networks. PhD thesis, Concordia University, Montreal, 2004.
- Tutschku, K., Gerlich, N., Tran-Gia, P. An integrated approach to cellular network planning. *Proceedings of the 7th International Network Planning Symposium (Networks 96)*, Sydney, 1996.