

Estrategias Evolutivas y Aprendizaje Competitivo Aplicadas a la Resolución del Problema de Asignación de Frecuencias

Luis O. Chávez

Universidad Nacional de Río Cuarto, Departamento de Computación,
Río Cuarto, Argentina, 5800
lchavez@dc.exa.unrc.edu.ar

Héctor E. Carranza

Universidad Nacional de Río Cuarto, Facultad de Ingeniería,
Río Cuarto, Argentina, 5800
hcarranza@ing.unrc.edu.ar

Mercedes C. Carnero

Universidad Nacional de Río Cuarto, Facultad de Ingeniería,
Río Cuarto, Argentina, 5800
mcarnero@ing.unrc.edu.ar

José L. Hernández

Universidad Nacional de Río Cuarto, Facultad de Ingeniería,
Río Cuarto, Argentina, 5800
jlh@ing.unrc.edu.ar

Abstract

In this paper we present different variations of a population algorithm based on incremental learning to solve a frequency assignment problem in cellular networks (FAP). This problem consists of the assignment of a number of available and limited frequencies to a collection of mobile devices that make the request, observing the restrictions established by one admissible interference matrix. The algorithm proposed, based on evolutionary strategies and competitive learning, is analyzed by means of the performance comparison with different variants of learning methods. We compare the influence of each variant implemented in the global performance using a problem taken from the specialized literature.

Keywords: Evolutionary Algorithms, Cellular networks, Competitive learning, Frequency assignment, Distribution Estimation Algorithms.

Resumen

En este trabajo se presentan diferentes variantes de un algoritmo poblacional basado en aprendizaje incremental para resolver un problema de asignación de frecuencias en redes celulares (FAP). Este problema implica la asignación de un número disponible y limitado de frecuencias a un conjunto de dispositivos móviles que realizan el requerimiento, sujeto a restricciones impuestas por una matriz de interferencias admisibles. El algoritmo propuesto, basado en una estrategia evolutiva y aprendizaje competitivo, se analiza desde la comparación de desempeño con distintas variantes de métodos de aprendizaje utilizados. Se compara la influencia de cada variante implementada en el desempeño global aplicado a un problema tomado de la literatura especializada.

Palabras claves: Algoritmos Evolutivos, Redes Celulares, Aprendizaje competitivo, Asignación de frecuencias, Algoritmos de estimación de distribuciones.

1-INTRODUCCIÓN

GSM es una de las tecnologías de comunicación móvil más exitosa en la actualidad. Los servicios GSM son usados por millones de suscriptores a lo largo de decenas de países y abarcan más del 70% del mercado de celulares a nivel mundial.

Tradicionalmente los sistemas de radio móvil estaban configurados con altas potencias y ubicados en puntos de elevada altura, por lo que tenían un área de cobertura grande. Los teléfonos móviles necesitaban contacto visual con la estación base a los fines de tener servicio; esto derivaba en altura de antenas elevadas. Estos radios de cobertura amplios hacían necesario reservar el uso de radio canales en un área grande para una cantidad relativamente pequeña de usuarios, [1], [2].

La tecnología celular abordó el problema de la cobertura de una manera diferente: utilizar un gran número de transmisores de baja potencia y con áreas de cobertura pequeñas. Las grandes áreas, antes cubiertas con un sólo transmisor, fueron divididas en pequeñas áreas a cubrir con transmisores de baja potencia. A estas pequeñas áreas se las denominó celdas.

Debido a la baja cobertura y baja potencia de los transmisores es posible reutilizar la misma frecuencia (canales) en otras celdas. Sin embargo usuarios de otras celdas se convierten en emisores de interferencia electromagnética para una celda dada, afectando la calidad del enlace. Los cálculos de calidad de enlace se establecen observando la relación señal útil vs. interferencia.

Dado que para el servicio de comunicaciones móviles el número de canales resulta fijo, es necesario hacer el mejor uso de ellos puesto que constituyen un recurso limitado. Esto significa asignar canales a llamadas en las celdas del sistema de tal manera de minimizar las interferencias y asegurar una calidad aceptable del enlace.

En un escenario simplificado es posible plantear un esquema en el cual las interferencias se modelen en función de la cantidad de violaciones a la compatibilidad electromagnética. Si bien es claro que evaluar las interferencias a partir de la cuenta del número de violaciones mencionado no cuantifica la contribución al monto total de interferencia de cada una de estas violaciones, este modelo es aceptable para la estimación de la calidad del enlace.

El problema que resulta es encontrar un esquema de asignación de frecuencias que optimice la calidad de los enlaces a la vez que cumpla la restricción de satisfacción de la demanda de tráfico impuesta.

El problema de optimización planteado es NP-hard, de modo que su resolución utilizando técnicas clásicas resulta en muchos casos ineficiente cuando no imposible. Las estrategias basadas en meta-heurísticas han mostrado ser una alternativa válida para la resolución de este tipo de problemas de optimización combinatoria.

Se han propuesto varios métodos de resolución algunos de los cuales están basados en técnicas de búsqueda locales. Esto incluye aproximaciones heurísticas en donde se observan ciertas dificultades al querer atender las restricciones provenientes de la compatibilidad electromagnética [3]. Posteriormente, han sido presentados algunos algoritmos basados en redes neuronales y recocido simulado (Simulated Annealing, SA) [4]. En el trabajo de Da Silva et al. [5] se propone la aplicación de un algoritmo evolutivo diferencial para resolver un problema de asignación de frecuencias (FAP). Gupta [6] ha realizado un estudio comparativo utilizando la técnicas de búsqueda tabú y recocido simulado ambas para resolver un FAP.

Dentro del conjunto de los algoritmos evolutivos se encuentran los Algoritmos de Estimación de Distribuciones (AED). Éstos trabajan con una población de soluciones candidatas. Después de una generación de una población inicial y posterior evaluación de todos sus miembros, se procede a seleccionar los mejores individuos para construir un modelo probabilístico de la población. A partir de él se realiza un muestreo para generar un nuevo conjunto de individuos. Este proceso se repite hasta que se alcanza algún criterio de detención. De esta manera el enfoque AED está basado en la evolución del modelo probabilístico del espacio de soluciones.

En particular un AED llamado PBIL (Population-Based Incremental Learning) fue propuesto por Baluja [7] quien introduce el concepto de aprendizaje competitivo (típico de redes neuronales) para guiar la búsqueda.

El objetivo de este trabajo es presentar un estudio comparativo acerca de diferentes variantes del algoritmo PBIL para resolver el problema de asignación de frecuencias en redes celulares.

La organización del mismo es la siguiente: en la sección 2 se presenta la formulación del problema. La Sección 3 describe el enfoque basado en la estimación de probabilidades. La Sección 4 detalla los experimentos ejecutados y los resultados obtenidos. Finalmente, en la última sección se establecen las conclusiones.

2-FORMULACIÓN DEL PROBLEMA

En este trabajo, se utiliza la siguiente notación para modelar el problema.

N : número de celdas

NF : número de frecuencias, o canales, disponibles en el espectro.

D : vector de demanda de tráfico de dimensión N ; d_i representa la cantidad de llamadas solicitadas en la celda i

M : matriz de compatibilidad electromagnética de dimensión $N \times N$, tal que m_{ij} representa la separación, en cantidad de canales, que debe existir entre las celdas i y j .

F : matriz binaria de asignaciones de dimensión $N \times NF$ tal que $f_{ij}=1$ si en la celda i se asignó el canal j .

CE : vector de dimensión $\sum_{i=1}^N d_i$ que almacena las filas de F en las que $f_{ij}=1$.

CH: vector de dimensión $\sum_{i=1}^N d_i$ que almacena las columnas de **F** en las que $f_{ij}=1$.

Dado un escenario de demanda de tráfico representado por **D**, una propuesta de asignación factible está representada por la matriz **F**, siempre y cuando la cantidad de elementos no nulos, en cada columna de **F**, coincida con la componente homóloga en **D**. La bondad de la solución propuesta depende del grado de cumplimiento de las condiciones que impone la matriz de compatibilidad electromagnética **M**. En otras palabras, mientras menor sea el grado de interferencia en la asignación propuesta, mayor será su calidad.

El problema de optimización a resolver consiste en encontrar una matriz de asignación **F** que minimice el grado de interferencias sujeto a satisfacer la demanda de tráfico **D**. Matemáticamente esto puede ser expresado como sigue:

$$\begin{aligned} \min z(\mathbf{F}) &= \sum_{i=1}^{NF} \sum_{j=i+1}^{NF} (|ch_i - ch_j| < M_{ce, ce_j}) \\ \text{sa } \sum_{j=1}^N f_{ij} &= d_i \quad \forall i = 1, \dots, N \end{aligned} \quad (1)$$

donde

$$\left. \begin{aligned} ce_k &= i \\ ch_k &= j \end{aligned} \right\} \text{si } f_{ij} = 1 \quad \forall i = 1, \dots, NF; \quad j = 1, \dots, N; \quad k = 1, \dots, \sum_{i=1}^N d_i \quad (2)$$

z cuenta la cantidad de violaciones a las condiciones impuestas por la matriz **M** dado que la expresión lógica $|ch_i - ch_j| < M_{ce, ce_j}$ vale 1 cuando se produce una violación de compatibilidad electromagnética o 0 en caso contrario.

La ecuación de restricción asegura que la matriz de asignación cumpla con la demanda de tráfico.

3-ENFOQUE BASADO EN ESTIMACIÓN DE DISTRIBUCIONES

Los Algoritmos de Estimación de Distribuciones (AEDs) pueden ser clasificados dentro de la familia de algoritmos evolutivos [8]. Al igual que los algoritmos genéticos (AGs) los AEDs están basados en poblaciones. Sin embargo, a diferencia de los AGs, en los AEDs no se utilizan operadores de cruzamiento ni de mutación entre los individuos. En cada generación, la nueva población representa una muestra de cierta distribución de probabilidades, que es estimada a partir de un conjunto formado por individuos de generaciones anteriores. Mientras que en los algoritmos genéticos las interrelaciones entre las distintas variables involucradas en la representación de los individuos no son, en general, consideradas, en los AEDs dichas interrelaciones se expresan de forma implícita en la distribución de probabilidad conjunta asociada a los individuos seleccionados en cada iteración.

Uno de los primeros trabajos en el campo de los AEDs fue el algoritmo *Population Based Incremental Learning* (PBIL) propuesto en [7]. PBIL fue motivado por la idea de combinar AGs con Aprendizaje Competitivo lo cual es frecuentemente usado para entrenar redes neuronales artificiales. PBIL considera representación binaria de un individuo. Comienza con la inicialización de una matriz, de probabilidades y la mantiene y actualiza durante el proceso computacional completo.

Un algoritmo PBIL general para el FAP propuesto involucra las siguientes fases:

1. Inicializar la matriz de probabilidad $\mathbf{P} = \{p_{ij}\}$ con 0,5 en cada posición. Cada variable representa la probabilidad de que el valor 1 esté presente en la misma posición en los cromosomas hijos.
2. Muestrear $M > 0$ individuos según las probabilidades en \mathbf{P} y evaluarlos.
3. Actualizar la matriz de probabilidad de acuerdo con el individuo de mejor desempeño $\mathbf{S} = \{s_{ij}\}$ usando la siguiente regla:

$$p_{i,j} = p_{i,j} * (1,0 - LR) + s_{i,j} * LR$$
donde LR es el valor de la velocidad de aprendizaje.
4. Si condición de mutación se cumple, mutar matriz de probabilidad usando la siguiente regla:

$$p_{ij} = p_{ij} * (1,0 - M_{MUT}) + \text{random}(0 \text{ o } 1) * M_{MUT}$$
donde M_{MUT} es la magnitud de la mutación que se aplica a la matriz de probabilidad.
5. Volver al paso 2 hasta que se cumpla el criterio de terminación.

Un Algoritmo de Estimación de distribuciones con aprendizaje competitivo presenta dos aspectos esenciales: el modelo utilizado para estimar la distribución conjunta de probabilidades y la estrategia de determinación de valores de la tasa de aprendizaje que garanticen un buen desempeño. Una característica de PBIL es que es univariado por lo que el último aspecto citado es de fundamental importancia aquí. En definitiva las diferentes alternativas consideradas conducen a extensiones sobre el PBIL básico que tienen como objetivo la actualización de la matriz de probabilidades de una manera determinada. Por ejemplo, una de las alternativas consiste en utilizar los mejores μ individuos y no sólo el mejor. Otra posibilidad es actualizar \mathbf{P} utilizando los peores individuos. Sobre la base de estas ideas, en este trabajo se evalúan las variantes denominadas *PBIL-LR-Negativo*, *PBIL- μ -frecuencia relativa* *PBIL- μ -Equitativo* y *PBIL- μ -Consenso* cuyas características se definen en la siguiente sección.

3-EXPERIMENTOS Y RESULTADOS

En esta sección se explican los experimentos realizados para ajustar los valores de los parámetros para las diferentes variantes del algoritmo PBIL. Luego, se analizan los resultados obtenidos y se obtienen conclusiones sobre si las variantes del algoritmo PBIL mejoran o no el desempeño del algoritmo estándar. Se comparan los resultados obtenidos en los diferentes experimentos con los producidos por la versión estándar y se realizan experimentos para obtener los mejores valores de parámetros de la versión estándar.

Se realizaron experimentos para obtener la mejor combinación de valores para los parámetros LR , P_{MUT} y M_{MUT} . Se tomaron las dos mejores combinaciones y se usaron para probar las variantes de PBIL.

Para la realización de las experiencias se tomó un ejemplo de la literatura que consta de 7 celdas y 50 canales, con un vector de demandas $\mathbf{D} = [24, 24, 14, 22, 3, 20, 23]$ y cuya matriz de compatibilidad está dada por

$$\mathbf{M} = \begin{bmatrix} 2 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 2 & 1 & 1 & 1 & 0 & 0 \\ 0 & 1 & 2 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 2 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 2 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 2 & 1 \\ 0 & 0 & 0 & 0 & 1 & 1 & 2 \end{bmatrix}$$

Se ha realizado un exhaustivo estudio a través de las diferentes variantes propuestas del algoritmo PBIL para determinar que versión es mejor para la resolución del problema de asignación de frecuencias. Las variantes estudiadas son las siguientes:

PBIL-LR-Negativa: Se actualiza la matriz de probabilidad en dos fases: primero utilizando los μ mejores individuos y luego reemplazando el parámetro LR por una tasa de aprendizaje negativa NL , menor que la primera. De esta manera se pretende incorporar alguna característica de individuos de baja aptitud que podrían evolucionar hacia mejores soluciones.

PBIL- μ -Frec-Relativa: cada posición de la matriz de probabilidad se actualiza considerando la frecuencia relativa de 1's en cada posición de \mathbf{F} para μ individuos.

PBIL- μ -Equitativo: la matriz de probabilidad es movida igualmente en la dirección de cada uno de los μ mejores individuos seleccionados en cada generación. El procedimiento consiste en una primera actualización de \mathbf{P} utilizando el mejor individuo; posteriormente se realiza una segunda actualización con el segundo mejor individuo y así sucesivamente.

PBIL- μ -Consenso: la matriz de probabilidad es actualizada sólo en las posiciones en las cuales hay consenso en todos los μ mejores individuos en cada generación. Para cada componente, si todas las soluciones tienen el mismo valor, éste es tomado para la actualización, de lo contrario no se actualiza la componente en cuestión.

En las siguientes subsecciones se muestran los resultados obtenidos por cada variante del algoritmo. El algoritmo se ha ejecutado para 2000 generaciones. La elección de este valor límite está motivada en dos aspectos: para la magnitud del problema FAP planteado el valor es suficientemente grande como para establecer un criterio común para comparar los resultados obtenidos en todos los experimentos y por otro lado el tiempo consumido por la ejecución permite realizar varias repeticiones del experimento (en este caso 10 ejecuciones para cada configuración del algoritmo). El desempeño de las variantes del algoritmo PBIL se mide en función del número de interferencias que produce cada asignación de frecuencias producida por el algoritmo. Mientras menor sea el valor del costo (número de interferencias) mejor será el plan de asignación de frecuencias.

4.1 Experimentos con PBIL estándar

El propósito de estos experimentos es obtener combinaciones de valores para los parámetros LR , P_{MUT} y M_{MUT} que produzcan un buen desempeño del algoritmo PBIL estándar. Los valores asignados a las citadas variables pertenecen al intervalo (0.001, 0.5). De las combinaciones obtenidas se seleccionaron las 2 mejores (Tabla 1), las cuales serán referidas a lo largo de este trabajo como Combinación 1 y Combinación 2. El valor de la función de *fitness* producido por estas combinaciones será usado como referencia para comparar con los valores de ajuste que produzcan las variantes PBIL.

Combinación	LR	P_{MUT}	M_{MUT}
1	0.25	0.016	0.125
2	0.125	0.5	0.0001

Tabla 1 – Parámetros de PBIL Estándar que producen mejor desempeño

La figura 1 muestra los resultados obtenidos al realizar 10 experimentos con cada combinación.




Figura 1. Desempeño de PBIL estándar

La media de los 10 experimentos para la Combinación 1 es 16.1 y para la Combinación 2 es 18,5 incompatibilidades.

4.2 Experimentos con PBIL-LR-Negativa

Se comienza con la versión *PBIL-LR-Negativa*. Para ajustar esta versión se fija el parámetro NL (*LR negativa*) del algoritmo. En la figura 2 se resumen los experimentos realizados para ajustar este parámetro. Se muestran los valores medios del número de interferencias obtenidos para valores de NL correspondientes al rango (0.003, 0.100). El resto de los parámetros de configuración de PBIL son los óptimos obtenidos previamente.

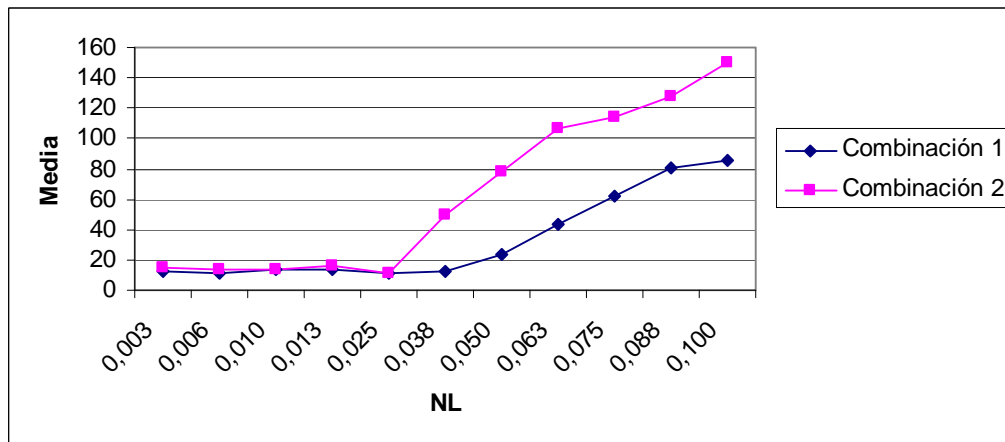


Figura 2 – Medias para diferentes valores de NL

Se puede ver en la figura que el mejor resultado es obtenido con la Combinación 2 de parámetros y para $NL = 0.025$ produciendo asignaciones de frecuencias con 11.4 interferencias en promedio. Este enfoque produce mejoras respecto a PBIL estándar.

4.3 Experimentos aplicando PBIL- μ -Frec-Relativa

En esta variante, el parámetro a ajustar es μ (número de individuos seleccionados). Los valores de μ usados son 2, 3, 4, 5 y 6. La Fig. 3 muestra los valores medios obtenidos.




Figura 3 - Medias para diferentes valores de μ

Esta variante logra una significativa mejora en el desempeño comparada con la obtenida con PBIL estándar y *PBIL-LR-Negativa*. El mejor resultado se logra con la Combinación 2 con una media de 6,5 para $\mu = 5$.

4.4 Experimentos aplicando PBIL- μ -Consenso.

El parámetro a ajustar es μ . La matriz de probabilidad **P** debe actualizarse sólo en aquellas posiciones (i,j) donde hay consenso para los μ mejores individuos en cada generación. Para ello se crea una matriz llamada **matrizconsenso** donde cada posición (i,j) vale 1 si en cada uno de los μ mejores individuos también hay un 1 en la posición (i,j) y vale 0 si en cada uno de los μ mejores individuos también hay un 0 en la posición. Los valores de **matrizconsenso** indican los elementos que se actualizarán en **P**. Los resultados obtenidos son mostrados en la figura 4.




Figura 4 - Desempeño de PBIL- μ -Consensus

Con esta variante se logra el mejor desempeño con la combinación 1 para $\mu = 2$ con un valor medio de 24. De todos modos, esta variante muestra un desempeño inferior al logrado en la versión estándar de PBIL.

4.5 Experimentos aplicando PBIL- μ -Equitativo

En este experimento, en cada generación la matriz de probabilidad es actualizada μ veces. La primera vez se usa el mejor individuo, luego el segundo mejor individuo, y así siguiendo hasta el μ -ésimo mejor individuo. Se muestran los resultados en la figura 5.




Figura 5 - Desempeño de PBIL-μ-Equitativo

Con esta variante se logra el mejor desempeño con la Combinación 1 para $\mu = 2$ con un valor medio de 11,3. La Tabla 2 resume los resultados obtenidos por las diferentes variantes de PBIL.

Algoritmo	Combinación	Media	Desvío
PBIL Estándar	1	16,1	4.86
PBIL -LR-Negativa	2	11.4	3.44
PBIL-μ-Frec-Relativa	2	6.5	2.79
PBIL-μ-Consenso	1	24	6.31
PBIL-μ-Equitativo	1	11.3	5.35

Tabla 2- Resumen de los resultados obtenidos con las diferentes variantes de PBIL

Por último, la figura 6 muestra la convergencia de los algoritmos para cada variante implementada, graficando el número de incompatibilidades encontrado en cada caso en función del número de generación.




Figura 6. Convergencia para cada variante.

5-CONCLUSIONES

Este trabajo describe el estudio de diferentes variantes de PBIL para resolver un FAP en una red GSM.

Después de este estudio se concluye que, salvo la variante *PBIL-μ-Consenso*, todas las otras produjeron mejoras en los resultados obtenidos con respecto a los producidos por la versión PBIL estándar. El mejor desempeño fue obtenido con *PBIL-μ-Frec-Relativa*.

En la figura 6 puede apreciarse claramente que la versión estándar exhibe una curva de velocidad de convergencia de mayor pendiente en las primeras generaciones, hasta un punto donde sufre un estancamiento. Esto es, presenta características de convergencia prematura. En contraste, la versión *PBIL-μ-Frec-Relativa* puede mantener una

población de mayor diversidad de potenciales soluciones, lo cual le permite escapar de valores subóptimos y alcanzar soluciones de mejor calidad.

Referencias

- [1] W. C. Y. Lee, "Mobile Cellular Telecommunications" McGraw-Hill. 1989 – ISBN 0-07-113479-1
- [2] V. Garg and J. Wilkes, "Wireless and Personal Communications Systems" Prentice Hall Inc. 1996- ISBN 0-13-234626-5
- [3] W. Wang, and C. K. Rushforth "An Adaptive Local Search Algorithm for the Channel Assignment Problem (CAP)," IEEE. Trans. Veh. Technol, vol. 45, no. 3, pp 459-466, 1996
- [4] Jim N. J. Moon, Lesley A. Hughes, and Derek H. Smith. Assignment of Frequency Lists in Frequency Hopping Networks. IEEE Transactions on Vehicular Technology, VOL. 54, NO. 3, pp 1147-1159. 2005
- [5] Da Silva M., Vega-Rodríguez M., Gómez Pulido, J., Sanchez Peérez, J. Analysis of Parameter Settings for Differential Evolution Algorithm to Solve a Real-World Frequency Assignment Problem in GSM Networks. Second International Conference on Advanced Engineering Computing and Applications in Sciences. Pp 77-82. 2008.
- [6] Baluja, S. Population-based incremental learning: A method for integrating genetic search based function optimization and competitive learning (Technical Report CMU-CS-94-163); Carnegie Mellon University; Pittsburgh, PA, USA, 1994
- [7] Gupta, D.K.; Metaheuristic algorithms for frequency assignment problems. Personal IEEE International Conference on Wireless Communications, ICPWC pp 456 – 459. 2005.
- [8] P. Larrañaga and J.A. Lozano. Estimation of distribution algorithms. A new tool for evolutionary computation. Kluwer Academic Publishers, 2001.