

**XIII Congreso Español
de Metaheurísticas,
Algoritmos Evolutivos y
Bioinspirados
(XIII MAEB)**

MAEB 8.1:
ALGORITMOS MULTIOBJETIVO
Y APLICACIONES





Metaheurísticas híbridas para el problema del apagado de celdas en redes 5G

Pablo H. Zapata-Cano*, Francisco Luna†, Juan F. Valenzuela-Valdés*, Antonio M. Mora*, Pablo Padilla*

*Dpto. de Teoría de la Señal, Telemática y Comunicaciones
CITIC, Universidad de Granada
pablozapata@correo.ugr.es, {juanvalenzuela, amorag, pablopadilla}@ugr.es

†Dpto. de Lenguajes y Ciencias de la Computación
Universidad de Málaga
flv@lcc.uma.es

Resumen—La densificación masiva de estaciones base (BS) es una de las tecnologías facilitadoras bien reconocidas por la literatura para el desarrollo de la quinta generación de redes de telecomunicaciones (5G). Su implementación, sin embargo, que requiere el despliegue de miles de BSs por km², está en claro conflicto con uno de los requisitos de diseño de este tipo de redes, que pretende tener un 90 % menos de consumo energético que la actual cuarta generación. Una forma de reducir el coste de estas redes ultradensas consiste en apagar un subconjunto de BSs de forma que minimice su consumo energético pero, a su vez, se maximice la capacidad de la misma. Es, por tanto, un problema de optimización multi-objetivo. En este trabajo se propone un nuevo operador específico para el problema que es capaz de mejorar considerablemente la efectividad de varios algoritmos multiobjetivo. Para ello, se han realizado experimentos con 9 escenarios de diferentes niveles de densificación tanto de BSs como de usuarios que muestran un comportamiento consistente y efectivo independientemente del algoritmo e instancia abordada.

I. INTRODUCCIÓN

La demanda de tráfico de datos en las redes de telefonía móvil ha crecido de manera constante desde el comienzo de estos sistemas de telecomunicación, y así seguirá haciéndolo en el futuro, según transcurre de diferentes informes tanto de entidades públicas como privadas. En efecto, uno de estos informes recientes elaborado por Ericsson expone que “El tráfico de datos móvil total se espera que crezca a una tasa compuesta anual del 42 %” [1], siendo los smartphones la fuente del 90 % de este tráfico. Para dar servicio a semejante demanda, las diferentes entidades, tanto públicas como privadas, tienen sobre la mesa el desarrollo de la quinta generación de redes de telefonía, la conocida como 5G. De entre las diferentes tecnologías facilitadoras de los sistemas 5G [2], la densificación de la red, i.e., el despliegue de miles de estaciones base (BS) de diferentes tipos por km², permite una mayor reutilización del espectro y, por tanto, incrementar en gran medida la capacidad del sistema. Son las denominadas redes ultra-densas o *Ultra-Dense Networks* (UDNs) [3].

El despliegue de UDNs impone muchas tareas complejas a diferentes niveles de la red (*backhauling*, coordinación de *handovers*, etc.), y se realiza en base a unas estimaciones de

tráfico máximas a las que hay que dar servicio. Esta forma de proceder plantea un serio problema de consumo energético, ya que requiere mantener funcionando ese elevado número de BSs, y es especialmente crítico en periodos de baja demanda de tráfico, donde la red está infrutilizada. Una línea de trabajo prometedora para reducir dicho consumo consiste en, dado un escenario fijo que puede representar a la demanda en un determinado intervalo de tiempo, apagar un subconjunto de las BSs de forma que se minimice la energía por las BSs y, a la vez, mantenga la red operativa maximizando su capacidad [4], [5]. Se trata de un problema de optimización combinatoria NP-completo [6] cuyo espacio de búsqueda crece exponencialmente con el número de BSs de la UDN.

La aproximación en este trabajo, dado los tamaños que previstos para dichas redes, es usar metaheurísticas [7]. En particular, el problema se ha formulado como un problema de optimización multi-objetivo [8] ya que los dos criterios anteriores, consumo *vs.* capacidad, están en conflicto entre sí, puesto que más BSs permiten potencialmente servir a más usuarios o UEs (del inglés, *User Equipments*), pero también se necesita más energía. En un estudio previo [9], se ha abordado el problema utilizando dos metaheurísticas multi-objetivo, una clásica como es NSGA-II [10], y otra relativamente más reciente denominada MOCeII [11]. La contribución del presente trabajo trata de incorporar conocimiento experto del problema en la búsqueda de ambos algoritmos con un operador, denominado CSO (del inglés *Cell Switch Off*), cuyo comportamiento se fundamenta en apagar aquellas BSs que no tienen UEs conectados. Hasta donde conocemos, es la primera vez que se proponer un operador de búsqueda específico para el problema del encendido/apagado de BSs en UDNs. Para mostrar su efectividad, se ha incorporado al ciclo evolutivo de NSGA-II y MOCeII, dando lugar a sus versiones híbridas NSGA-II_{CSO} y MOCeII_{CSO}, y se han comparado a las versiones canónicas de los algoritmos sobre un conjunto de 9 escenarios diferentes que utilizan una densificación creciente tanto en BSs como en UEs. Los resultados han mostrado que se trata de un operador que permite mejorar considerablemente la búsqueda de ambas metaheurísticas multi-objetivo.

Tabla I: Parámetros del modelo para BSs y UEs

Celda	Parámetro	LL	LM	LH	ML	MM	MH	HL	HM	HH
macro	G_{tx}	14								
	f	2 GHz (BW = 100 MHz)								
micro1	G_{tx}	12								
	f	3.5 GHz (BW = 175 MHz)								
	λ_P^{macro1} [BS/km ²]	100	100	100	200	200	200	300	300	300
micro2	G_{tx}	10								
	f	5 GHz (BW = 250 MHz)								
	λ_P^{micro2} [BS/km ²]	100	100	100	200	200	200	300	300	300
pico1	G_{tx}	5								
	f	10 GHz (BW = 500 MHz)								
	λ_P^{pico1} [BS/km ²]	500	500	500	600	600	600	700	700	700
pico2	G_{tx}	7								
	f	14 GHz (BW = 700 MHz)								
	λ_P^{pico2} [BS/km ²]	500	500	500	600	600	600	700	700	700
femto1	G_{tx}	4								
	f	28 GHz (BW = 1400 MHz)								
	λ_P^{femto1} [BS/km ²]	1000	1000	1000	2000	2000	2000	3000	3000	3000
femto2	G_{tx}	3								
	f	66 GHz (BW = 3300 MHz)								
	λ_P^{femto2} [BS/km ²]	1000	1000	1000	2000	2000	2000	3000	3000	3000
UEs	λ_{UE}^{UE} [UE/km ²]	1000	1000	1000	2000	2000	2000	3000	3000	3000

El resto del trabajo se organiza como sigue: la siguiente sección detalla el modelado de las UDNs y el cálculo de las funciones objetivo. La Sección III describe el operador CSO y su integración en los ciclos evolutivos de NSGA-II y MOCeCell. La metodología de los experimentos y el análisis de resultados se realiza en la Sección IV. Por último, la Sección V incluye las principales conclusiones del trabajo y las líneas de trabajo futuro que se abren a partir de él.

II. MODELADO DEL PROBLEMA

Esta sección se dedica a la descripción del modelo de UDN utilizado. Se considera un área de servicio de $500 \times 500 m^2$, que se ha discretizado utilizando una malla de 100×100 puntos (también llamados “pixels” o elementos de área) distribuidos uniformemente y, por tanto, cada uno cubre un área de $25 m^2$ donde la potencia de la señal se asume constante. La UDN está dividida en 10 regiones diferentes, cada una con unas condiciones de propagación diferentes.

Para calcular la potencia de señal recibida en cada punto, P_{rx} [dBm], se ha utilizado el siguiente esquema:

$$P_{rx}[\text{dBm}] = P_{tx}[\text{dBm}] + P_{Loss}[\text{dB}] \quad (1)$$

donde P_{rx} es la potencia recibida en dBm, P_{tx} es la potencia transmitida en dBm, y P_{Loss} son las pérdidas globales de señal, que depende de las condiciones de propagación de cada región, y se calcula como:

$$P_{Loss}[\text{dB}] = GA + PA \quad (2)$$

siendo GA las ganancias de las dos antenas (transmisión y recepción), y PA las pérdidas de transmisión en el espacio, calculadas como:

$$PA[\text{dB}] = \left(\frac{\lambda}{2 * \pi * d} \right)^K \quad (3)$$

donde d es la distancia Euclídea del punto correspondiente a la BS, K es el exponente de pérdidas, que varía aleatoriamente

en el intervalo [2.0, 4.0] para cada una de las 10 regiones. El ratio señal-interferencia más ruido (*Signal to Interference plus Noise Ratio* o SINR) para el UE k , se calcula como:

$$SINR_k = \frac{P_{rx,j,k}[\text{mW}]}{\sum_{i=1}^M P_{rx,i,k}[\text{mW}] - P_{rx,j,k}[\text{mW}] + P_n[\text{mW}]} \quad (4)$$

donde $P_{rx,j,k}$ es la potencia recibida por el UE k de la BS j , el sumatorio es la potencia total recibida por el UE k desde todas las BSs activas y operando a la misma frecuencia que j , y P_n es la potencia del ruido, calculada como:

$$P_n = -174 + 10 \log_{10} BW_j \quad (5)$$

siendo BW_j el ancho de banda de la BS j , definida como el 5% de la frecuencia de operación de la BS. La Tabla I incluye todos los valores para los parámetros del modelo. Finalmente, la capacidad del UE k es:

$$C_k[\text{bps}] = BW_k^j[\text{Hz}] * \log_2(1 + SINR_k) \quad (6)$$

donde BW_k^j es el ancho de banda asignado al UE k cuando se conecta a la BS j , asumiendo una planificación en round-robin, esto es:

$$BW_k^j = \frac{BW_j}{N_j} \quad (7)$$

considerando N_j como el número de UEs conectados a la BS j . La política de asignación de UEs a BSs es que un UE siempre es servido por la BS con mayor SINR, independientemente del tipo de BS.

El modelo de UDN usado en este trabajo utiliza 4 tipos de celdas que tienen diferentes tamaños (i.e., zonas de cobertura). Ordenadas según su tamaño, tenemos femtoceldas, picoceldas, microceldas y macroceldas. De los tres primeros tipos, además, se han definido dos subtipos (ver Tabla I), con lo que suman un total de 7 tipos de celdas diferentes. Las BSs que sirven a dichas celdas tienen todas una potencia de transmisión $P_{tx} = 750mW$, por lo que su cobertura real está definida por sus



frecuencias de operación y las consiguientes pérdidas que se inducen en el cálculo de la SINR (a mayor frecuencia, menor cobertura).

Las BSs se despliegan utilizando un Proceso de Poisson (PPP) independiente con diferentes densidades (definidas por λ_P^{BS}). Los UEs también se posicionan usando una PPP con valor λ_P^{UE} , pero utilizando atractores sociales (SAs por sus siglas en inglés), siguiendo el procedimiento propuesto en [12]. Este esquema de despliegue usa, además, dos factores α and μ_β , que indican cómo de fuerte es la atracción de BSs a SAs, y de SAs a UEs. Los valores usados en las simulaciones son $\alpha = \mu_\beta = 0.25$.

La parametrización detallada de los 9 escenarios abordados en este trabajo se incluye en la Tabla I. Los nombres en las nueve últimas columnas, XY, indican la densidad del despliegue de BSs y UEs, respectivamente, de forma que X,Y = {L,M,H} significa un despliegue de baja (L), media (M) o alta (H) densidad para BSs (parámetro λ_P^{BS} del PPP) y UEs (parámetro λ_P^{UE} del PPP). Los parámetros G_{tx} y f de cada tipo de celda se refieren a la ganancia en transmisión y la frecuencia de operación de la BS, respectivamente.

El cálculo de las funciones objetivo se realiza como sigue. Para el primer objetivo, que mide el consumo eléctrico, cuenta el número de BSs que están activas en la solución candidata de la metaheurística. Se asume que, una vez encendidas sólo se considera la potencia de transmisión, que tiene valor $P_{tx} = 750mW$ para todos los tipos. Para calcular la capacidad total del sistema, como medida de la cantidad de información que pueden recibir (downlink) los UEs presentes en la UDN, se usa el siguiente procedimiento: primero, los UEs se asignan a las BSs que les proporcionan mejor SINR; segundo, el ancho de banda disponible en la BS se reparte entre los UEs conectados; y, finalmente, se calcula la capacidad para cada uno de ellos según la Ecuación 6 y se agrega la de todos.

III. METAHEURÍSTICAS HÍBRIDAS: EL OPERADOR CSO

En esta sección se detalla, en primer lugar, la representación utilizada para abordar el problema y los consiguientes operadores genéticos, en segundo lugar, el operador CSO, la contribución de este trabajo, y, finalmente, una breve descripción de las metaheurísticas multi-objetivo utilizadas y cómo integran al operador dentro de su ciclo evolutivo.

III-A. Representación y operadores genéticos

La representación utilizada para las soluciones candidatas es el clásico array de bits en el que cada bit representa a una celda de la UDN e indica si está encendida ('1') o apagada ('0'). Los operadores de selección, cruce y mutación son, respectivamente, torneo binario, cruce de dos puntos con $c_r = 0.9$, y bit flip con $m_r = 1/L$, donde L es el número de BSs de la UDN. La condición de parada consiste en computar 100000 evaluaciones de función. Todos los algoritmos de este trabajo comparten la implementación tanto la representación de soluciones, como de los operadores, ya que están integrados en el framework para optimización multiobjetivo jMetal¹.

¹<https://github.com/jMetal/>

Algoritmo 1 Pseudocódigo del operador CSO

```

1:  $C \leftarrow \text{celdas}(UDN)$ 
2: for  $c$  in  $C$  do
3:   if (UEsConectados( $c$ ) == 0) then
4:     apagar( $c$ )
5:   end if
6: end for

```

III-B. El operador CSO

Para incorporar información del problema a la búsqueda de las metaheurísticas, el operador CSO recorre todas las celdas de la solución candidata, y apaga aquellas que no están sirviendo a ningún UE.

Su aparente simpleza no impide que sea un operador con gran capacidad de intensificación de la búsqueda y, como se verá más adelante en la sección experimental, se ha de aplicar con precaución. Hay que tener en cuenta que si, en cada solución candidata, se apagan todas las celdas que no tienen usuarios conectados, se impide que el algoritmo pueda evolucionar soluciones que reasignen UEs de una BS a otra vacía, puesto que todas estarían apagadas al aplicar el operador.

III-C. Los algoritmos híbridos NSGA-II_{CSO} y MOCeII_{CSO}

Esta sección se articula en base a la plantilla genérica de metaheurística multiobjetivo (Algoritmo 2) a partir de la cual se describen las versiones canónicas de NSGA-II y MOCeII para, posteriormente, detallar los cambios necesarios para introducir el operador CSO.

El algoritmo NSGA-II (*Non-dominated Sorting Genetic Algorithm II* por sus siglas en inglés) fue propuesto por Deb *et al.* en [10]. Se trata de un algoritmo genético cuyo funcionamiento se basa en generar, a partir de una población P_t , otra auxiliar Q_t usando los operadores genéticos de selección, cruce y mutación (línea 8 del Algoritmo 2); entonces, las soluciones incluidas en $P_t \cup Q_t$ se ordenan según su rango y, aquellas con mejor valor de este indicador de calidad, con las que pasan a la siguiente generación P_{t+1} (línea 11). En caso de tener que seleccionar entre individuos de mismo rango, NSGA-II utiliza

Algoritmo 2 Plantilla de una metaheurística multi-objetivo

```

1:  $S(0) \leftarrow \text{GenerarSolucionesIniciales}()$ 
2:  $A(0) \leftarrow \emptyset$ 
3: Evaluar( $S$ )
4:  $A(0) \leftarrow \text{Actualizar}(A(0), S(0))$ 
5:  $t \leftarrow 0$ 
6: while not CondiciónDeParada() do
7:    $t \leftarrow t + 1$ 
8:    $S(t) \leftarrow \text{OperadoresGenéticos}(A(t-1), S(t-1))$ 
9:   Evaluar( $S'(t)$ )
10:   $A(t) \leftarrow \text{Actualizar}(A(t), S'(t))$ 
11: end while
12: Salida:  $A$ 

```

Algoritmo 3 NSGA-II_{CSO} y MOCeCell_{CSO}

```
8:  $S(t) \leftarrow \text{OperadoresGenéticos}(A(t-1), S(t-1))$ 
9:  $S'(t) \leftarrow \text{CSO}(S(t))$ 
10: Evaluar( $S'(t)$ )
11:  $A(t) \leftarrow \text{Actualizar}(A(t), S'(t))$ 
```

un estimador de densidad que prioriza aquellas que están en las zonas menos pobladas de la aproximación al frente.

Por su parte, MOCeCell (*Multi-Objective Cellular Genetic Algorithm* por sus siglas en inglés) es un algoritmo genético celular propuesto en [11]. Como muchas otras metaheurísticas multi-objetivo, MOCeCell incluye un archivo externo para almacenar las soluciones no-dominadas que encuentra durante su ejecución (línea 4 del Algoritmo 2). Este archivo está acotado y usa el mismo estimador de densidad de NSGA-II para mantener la diversidad en su aproximación al frente de Pareto. Su diferencia fundamental radica en la relación de vecindad entre las soluciones, que se disponen en una malla toroidal 2D. El operador de selección escoge una solución de dicho vecindario y otra desde el archivo externo. Después de aplicar los operadores de cruce y mutación, el nuevo individuo generado se compara con el actual y lo reemplaza si es mejor; si ambas soluciones son no-dominadas, MOCeCell reemplaza el peor individuo del vecindario. En estos dos últimos casos, el nuevo individuo se añade al archivo externo.

La integración del operador CSO dentro del ciclo evolutivo de NSGA-II y MOCeCell se consigue reemplazando las líneas 8 a 10 del Algoritmo 2 por las líneas del algoritmo Algoritmo 3, es decir, justo después de aplicar los operadores genéticos, y antes de evaluar para determinar su incorporación o no a la siguiente generación de soluciones del algoritmo. Esto permite apagar aquellas celdas que no está sirviendo a ningún UE. Su aplicación, como el cruce y la mutación, depende de una tasa de aplicación, $csor$, sobre la que se han diseñado diferentes experimentos para ver su impacto.

IV. EXPERIMENTACIÓN

Esta sección describe la metodología utilizada para la realización de los experimentos que muestran la efectividad de las nuevas propuestas híbridas, NSGA-II_{CSO} y MOCeCell_{CSO}, así como el análisis de los resultados obtenidos.

IV-A. Metodología

Dado que las metaheurísticas son algoritmos estocásticos, se han realizado 30 ejecuciones independientes para cada algoritmo en cada uno de los nueve escenarios. Cada ejecución genera una instancia aleatoria del problema, pero se usan las mismas 30 semillas para garantizar que todos los algoritmos abordan el mismo conjunto de instancias. Se han utilizado dos indicadores para medir la calidad de las aproximaciones al frente de Pareto alcanzadas por los cuatro algoritmos: el hypervolume (HV) [13] y las superficies de consecución (del inglés *attainment surfaces*) [14].

El HV está considerado como uno de los indicadores más fiables dentro de la comunidad multi-objetivo. Es un indicador

a maximizar cuyos valores dependen de la escala arbitraria de los valores de las funciones objetivo. Para su uso correcto, en caso de no disponer del frente óptimo de Pareto, se genera un frente de referencia (RPF) para cada instancia del problema, compuesto por todas las soluciones no dominadas encontradas por todos los algoritmos para el mismo. Con ese RPF, se normaliza cada aproximación al frente antes de calcular el valor del HV. Para dotar a estos resultados de confianza estadística, se ha comprobado primero la normalidad (test de Kolmogorov-Smirnov) y homocedasticidad (Test de Levene) de las muestras y, una vez verificadas ambas condiciones, se ha usado un test paramétrico (test one-way ANOVA) para verificar si se rechaza la hipótesis nula. Por último, se ha aplicado el test de Tukey para realizar la comparación por pares. En todos los casos se ha utilizado un nivel de confianza del 95 %.

Si bien el HV permite comparar varios algoritmos numéricamente, desde el punto de vista del experto que ha de elegir una solución del frente, este indicador no da información sobre la forma en la que se distribuyen las soluciones no-dominadas a lo largo de las diferentes aproximaciones al frente de Pareto. Las *attainment surfaces* tienen precisamente esa funcionalidad. Son una representación gráfica del rendimiento esperado y su variabilidad de diferentes ejecuciones de un algoritmo multi-objetivo. Informalmente, la 50%-attainment surface se podría considerar como la aproximación promedio al frente de Pareto, es decir, sería el equivalente a la mediana en el caso mono-objetivo.

IV-B. Resultados

Se ha planteado un diseño experimental para medir el efecto de la hibridación entre NSGA-II y MOCeCell, y el operador CSO. Para ello, se han planteado dos tasas de aplicación de este último: 0.01 y 0.1, que se han usado como superíndice en el nombre para distinguirlos. Así, se puede ver que, por cada algoritmo, hay tres columnas: su versión canónica y las versiones híbridas con tasa de aplicación de 0.01 y 0.1. En la Tabla II, que incluye los resultados del HV, usa un fondo en gris los mejores valores de este indicador por cada algoritmo.

Hay una primera conclusión clara: la hibridación mejora la búsqueda de los algoritmos, ya que, en ningún escenario, un algoritmo canónico ha sido mejor que uno híbrido. Esto es un resultado muy prometedor porque existen pocas aproximaciones híbridas en el dominio y es un terreno amplísimo por explorar. La segunda es que, entre las versiones híbridas, aquellas que usan una tasa de aplicación más pequeña (0.01 vs. 0.1) permiten alcanzar mejores aproximaciones al frente de Pareto. Después de inspeccionar trazas de las ejecuciones (no incluidas por falta de espacio), se puede observar que el operador tiene un gran efecto en la diversidad de la población, es decir, si se aplica con mucha frecuencia, termina apagando en gran medida las mismas celdas y cercena el nuevo material genético creado por los operadores de cruce y mutación.

Si nos detenemos un poco más en los números concretos y se analizan según las instancias, se puede observar que las diferencias en el HV se hace más manifiesta a medida que



Tabla II: Resultados del HV para todos los algoritmos sobre los 9 escenarios

	NSGA-II	NSGA-II ^{0.01} _{CSO}	NSGA-II ^{0.1} _{CSO}	MOCcell	MOCcell ^{0.01} _{CSO}	MOCcell ^{0.1} _{CSO}
<i>LL</i>	0.4560 ±0.1017	0.5372 ±0.1263	0.5296 ±0.1250	0.4737 ±0.1180	0.5359 ±0.1250	0.5329 ±0.1274
<i>LM</i>	0.4364 ±0.0929	0.5404 ±0.1141	0.5338 ±0.1179	0.4155 ±0.0928	0.5385 ±0.1155	0.5351 ±0.1145
<i>LH</i>	0.4548 ±0.1027	0.5408 ±0.1274	0.5371 ±0.1271	0.4324 ±0.0903	0.5340 ±0.1252	0.5371 ±0.1248
<i>ML</i>	0.3288 ±0.0698	0.4907 ±0.1045	0.4853 ±0.1045	0.3584 ±0.0817	0.4892 ±0.1059	0.4867 ±0.1032
<i>MM</i>	0.3904 ±0.0728	0.5573 ±0.1095	0.5455 ±0.1045	0.3947 ±0.0728	0.5554 ±0.1061	0.5508 ±0.1044
<i>MH</i>	0.3243 ±0.0580	0.5356 ±0.0948	0.5401 ±0.0874	0.3194 ±0.0650	0.5235 ±0.0925	0.5565 ±0.0954
<i>HL</i>	0.1316 ±0.0798	0.5117 ±0.1071	0.4981 ±0.1093	0.2681 ±0.0729	0.5142 ±0.1076	0.5051 ±0.1093
<i>HM</i>	0.1103 ±0.0706	0.4837 ±0.0921	0.4714 ±0.0900	0.2157 ±0.0679	0.4790 ±0.0920	0.4743 ±0.0903
<i>HH</i>	0.1518 ±0.0681	0.4852 ±0.0905	0.4717 ±0.0917	0.2335 ±0.0619	0.4774 ±0.0863	0.4690 ±0.0880

umenta la densidad tanto de BSs como de UEs. Es decir, a medida que las instancias se hacen más grandes y complejas, el efecto del operador es mucho más determinante. Esto es además consistente para ambos algoritmos, ya que NSGA-II y MOCcell tienen unos promedios de HV de 0.1313 y 0.2390 en las instancias HX, respectivamente, cuando las versiones híbridas están en torno a 0.4935 y 0.4902.

Un último efecto del operador CSO sobre los algoritmos es que reduce e incluso invierte las mejoras en la búsqueda existentes entre NSGA-II y MOCcell. Con esto nos referimos a que, tanto en el trabajo previo [9], como en los valores del HV alcanzados por los algoritmos canónicos, MOCcell supera claramente a NSGA-II. Sin embargo, cuando se usa el operador CSO, la situación se invierte, y es NSGA-II el que obtiene valores más altos de este indicador. Las diferencias son mínimas y estadísticamente no significativas según el test de Tukey, pero viene a poner de manifiesto que el motor de búsqueda de NSGA-II ha integrado mejor el operador CSO.

La corroboración gráfica de lo que muestra el HV se puede observar en las attainment surfaces (Fig. 1). A medida que los escenarios son más densos, las aproximaciones medianas al frente de las versiones canónicas se van separando cada vez más de las versiones híbridas. Sin embargo, se aprecia un efecto que el HV oculta, y de ahí la importancia de tener representaciones gráficas de los frentes obtenidos: las versiones híbridas muestrean mucho más las zonas del espacio de búsqueda que contienen pocas BSs activas (áreas más hacia la izquierda), pero las versiones canónicas obtienen soluciones no-dominadas con muchas BSs operativas (mayor consumo), pero también de mayor capacidad (áreas más a la izquierda). Esto está provocado porque el operador CSO, en realidad, sólo mejora uno de los objetivos (consumo), descuidando el otro (capacidad).

V. CONCLUSIONES

Este trabajo se ha planteado la resolución del apagado de celdas en el contexto de los despliegues ultradensos de

estaciones base que serán necesarios para la quinta generación de sistemas de telecomunicación. Se ha formulado como un problema de optimización multi-objetivo en el que se ha de minimizar el consumo (número de BSs activas), a la vez que se ha de aumentar la capacidad (GBps en *downlink*). Se ha propuesto un nuevo operador de búsqueda local, llamado CSO, que se ha integrado dentro de dos algoritmos del dominio, uno muy bien conocido, NSGA-II, y otro más reciente, pero que ha resultado en una mejor exploración del espacio de búsqueda, denominado MOCcell. Las versiones híbridas, NSGA-II_{CSO} y MOCcell_{CSO}, han alcanzado aproximaciones al frente de Pareto del problema con una mejora notable en el indicador HV, si bien las attainment surfaces han mostrado que el operado ha centrado la búsqueda en zonas con UDNs que activan un bajo número de BSs, y también de menor capacidad. Como trabajo futuro se pretende seguir diseñando operadores de búsqueda que equilibren ambos objetivos, así como el impacto de los mismos en otras metaheurísticas multi-objetivo del dominio.

RECONOCIMIENTOS

Este trabajo ha sido financiado parcialmente por el Ministerio de Economía y Competitividad y los fondos FEDER con los proyectos TIN2016-75097-P, TIN2014-56494-C4-3-P, TIN2017-85727-C4-2-P y TEC2015-68752. Francisco Luna también agradece la ayuda de la Universidad de Málaga y el proyecto PPIT.UMA.B12017/15 del I Plan Propio de Investigación y Transferencia.

REFERENCIAS

- [1] Ericsson, "Mobility Report," *White Paper*, no. June, 2017. [Online]. Available: <https://www.ericsson.com/assets/local/mobility-report/documents/2017/ericsson-mobility-report-june-2017.pdf>
- [2] D. Lopez-Perez, M. Ding, H. Claussen, and A. H. Jafari, "Towards 1 Gbps/UE in Cellular Systems: Understanding Ultra-Dense Small Cell Deployments," *IEEE Communications Surveys & Tutorials*, vol. 17, no. 4, pp. 2078–2101, 2015.
- [3] X. Ge, S. Tu, G. Mao, C.-X. Wang, and T. Han, "5G Ultra-Dense Cellular Networks," *IEEE Wireless Communications*, vol. 23, no. 1, pp. 72–79, feb 2016.




Figura 1: Attainment surfaces de NSGA-II, MOCeII y sus versiones híbridas, NSGA-II_{CSO} y MOCeII_{CSO}, para los 9 escenarios considerados

- [4] Q.-N. Le-The, T. Beitelmal, F. Lagum, S. S. Szyszkowicz, and H. Yanikomeroglu, "Cell Switch-Off Algorithms for Spatially Irregular Base Station Deployments," *IEEE Wireless Communications Letters*, vol. 6, no. 3, pp. 354–357, jun 2017.
- [5] F. Lagum, Q.-N. Le-The, T. Beitelmal, S. S. Szyszkowicz, and H. Yanikomeroglu, "Cell Switch-Off for Networks Deployed With Variable Spatial Regularity," *IEEE Wireless Communications Letters*, vol. 6, no. 2, pp. 234–237, apr 2017.
- [6] D. Gonzalez G., J. Hamalainen, H. Yanikomeroglu, M. Garcia-Lozano, and G. Senarath, "A Novel Multiobjective Cell Switch-Off Framework for Cellular Networks," *IEEE Access*, vol. 4, pp. 7883–7898, 2016.
- [7] C. Blum and A. Roli, "Metaheuristics in combinatorial optimization: Overview and conceptual comparison," *ACM Computing Surveys*, vol. 35, no. 3, pp. 268–308, 2003.
- [8] D. Gonzalez Gonzalez, E. Mutafungwa, B. Haile, J. Hämäläinen, and H. Poveda, "A Planning and Optimization Framework for Ultra Dense Cellular Deployments," *Mobile Information Systems*, vol. 2017, pp. 1–17, 2017.
- [9] F. Luna, J. F. Valenzuela-Valdés, R. Luque-Baena, J. M. Cruz, and P. Padilla, "Addressing the 5g cell switch-off problem with a multi-objective cellular genetic algorithm," in *IEEE 5G World Forum, 9-11 July, Santa Clara, USA*, 2018, pp. 422–426.
- [10] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182 – 197, 2002.
- [11] A. J. Nebro, J. J. Durillo, F. Luna, B. Dorronsoro, and E. Alba, "Mocell: A cellular genetic algorithm for multiobjective optimization," *Int. J. of Intelligent Systems*, vol. 24, no. 7, pp. 723 – 725, 2009.
- [12] M. Mirahsan, R. Schoenen, and H. Yanikomeroglu, "HetHetNets: Heterogeneous Traffic Distribution in Heterogeneous Wireless Cellular Networks," *IEEE Journal on Selected Areas in Communications*, vol. 33, no. 10, pp. 2252–2265, 2015.
- [13] E. Zitzler and L. Thiele, "Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach," *IEEE Trans. Evolutionary Computation*, vol. 3, no. 4, pp. 257–271, 1999.
- [14] J. Knowles, "A summary-attainment-surface plotting method for visualizing the performance of stochastic multiobjective optimizers," in *5th International Conference on Intelligent Systems Design and Applications (ISDA'05)*, 2005, pp. 552 – 557.



MOEA-EFEP: Un algoritmo evolutivo multi-objetivo para la extracción de patrones emergentes difusos

A.M. García-Vico, C.J. Carmona, P. González, M.J. del Jesus

Departamento de Informática, Instituto Andaluz Interuniversitario en Data Science and Computational Intelligence

Universidad de Jaén, Jaén, España

{agvico|ccarmona|pglez|mjjesus}@ujaen.es

Resumen—Este trabajo es un resumen del publicado por los autores en la revista *IEEE Transactions on Fuzzy Systems* [1] en el que se presenta un nuevo modelo evolutivo multi-objetivo para la extracción de patrones emergentes difusos con un gran balance entre la capacidad descriptiva de los mismos y su fiabilidad.

Index Terms—Descubrimiento de reglas descriptivas supervisadas, minería de patrones emergentes, algoritmos evolutivos multi-objetivo, sistemas difusos evolutivos.

I. RESUMEN

Tradicionalmente, en minería de datos se distinguen dos enfoques claramente diferenciados: un enfoque predictivo, cuyo objetivo es la obtención de un modelo para la predicción del valor de una variable de interés en nuevas instancias no vistas hasta el momento, utilizando para ello aprendizaje supervisado; y un enfoque descriptivo con el objetivo de crear un modelo que describa relaciones interesantes en los datos utilizando para ello habitualmente aprendizaje no supervisado. Sin embargo, a lo largo de la literatura se han ido desarrollando una serie de técnicas que se encuentran a medio camino entre ambos enfoques, agrupadas bajo el nombre de “descubrimiento de reglas descriptivas basadas en aprendizaje supervisado” (SDRD) [2], [3] cuyo propósito es la obtención de un modelo descriptivo con de conocimiento relevante sobre una variable de interés en un conjunto de datos.

El principal objetivo de las técnicas SDRD no es la extracción de un modelo con el fin de clasificar nuevas instancias, sino la obtención de un modelo que permita describir de una manera simple y fácilmente comprensible el fenómeno subyacente en los datos por parte de los expertos. Por tanto, en este grupo de tareas se agrupan todas aquellas técnicas de minería de datos que utilizan un modelo de reglas y aprendizaje supervisado para obtener conocimiento descriptivo sobre los datos, como por ejemplo el descubrimiento de subgrupos [4], [5], la minería de conjuntos de contraste [6] o la minería de patrones emergentes [7], [8], entre otras.

La minería de patrones emergentes (EPM) se define como la búsqueda de todos los patrones que, dados dos conjuntos de datos D_1 y D_2 , tengan un índice de crecimiento (GR) mayor a un umbral $\rho > 1$. Este índice de crecimiento se define como la siguiente función:

$$GR(X) = \begin{cases} 0, & \text{Si } Sop_1(X) = Sop_2(X) = 0, \\ \infty, & \text{Si } Sop_1(X) = 0 \wedge Sop_2(X) \neq 0, \\ \frac{Sop_2(X)}{Sop_1(X)}, & \text{en otro caso} \end{cases} \quad (1)$$

donde $Sop_i(X)$ indica el soporte del patrón X en el conjunto de datos i . EPM tiene como objetivos principales la descripción de características discriminativas entre clases, la descripción de fenómenos emergentes en datos temporales, donde el primero de estos objetivos ha sido el más desarrollado a lo largo de la literatura.

El principal problema de la extracción de patrones emergentes reside en su propia definición, ya que definen un espacio de búsqueda que no es convexo debido a que el GR es una proporción de soportes [9]. Esto permite que aquellos patrones con soportes más altos puedan tener un GR menor que aquellos patrones con soportes menores. Por esta razón a lo largo de la literatura se han desarrollado diferentes tipos de patrones emergentes, como por ejemplo los patrones emergentes *Jumping* [10] o los patrones emergentes χ^2 [11]. Asimismo, se han desarrollado diferentes técnicas de extracción como las técnicas basadas en límites o en árboles con el objetivo de extraer de manera eficiente aquellos de mayor calidad y poder discriminativo. Sin embargo, la gran mayoría de estos métodos han sido completamente enfocados a clasificación ignorando por completo las capacidades descriptivas de los mismos. No obstante, en los últimos años se han desarrollado técnicas basadas en algoritmos evolutivos que han permitido la extracción de patrones emergentes con un buen balance entre las capacidades descriptivas y la fiabilidad de las mismas [8].

Nuestra aportación a la literatura es un algoritmo genético multi-objetivo que permite la extracción de patrones emergentes difusos llamado MOEA-EFEP (*Multi-Objective Evolutionary Algorithm for the Extraction of Fuzzy Emerging Patterns*). MOEA-EFEP utiliza lógica difusa para el tratamiento de variables de tipo numérico con el fin de evitar pérdidas de información y mejorar la interpretabilidad de los resultados. Asimismo, MOEA-EFEP está basado en el algoritmo multi-objetivo NSGA-II [12], el cual ha sido modificado para que el proceso de búsqueda esté orientado a la extracción de patrones

emergentes de gran calidad, es decir, un conjunto de patrones simple, con gran capacidad de generalización y fiable.

En concreto, MOEA-EFEP emplea un enfoque “cromosoma = regla” en el que un individuo de la población representa una regla potencial y el resultado final es el conjunto formado por la unión de varios individuos. En este punto, es importante remarcar que MOEA-EFEP representa tanto el antecedente como el consecuente de la regla por lo que puede extraer patrones emergentes para todas las clases del problema en una única ejecución. Asimismo, se permite el uso de dos representaciones del conocimiento diferentes en función de las necesidades del problema: reglas canónicas, formadas por conjunciones de pares atributo-valor o bien reglas en forma normal disyuntiva (DNF) donde se permite que un atributo pueda tener más de un posible valor mediante disyunciones.

Los individuos de la población interactúan entre sí mediante el uso de un enfoque cooperativo-competitivo. Este enfoque se basa, por un lado, en la competición propia de un algoritmo evolutivo a través de los operadores genéticos. Dichos operadores son, en concreto, un operador de inicialización guiada, que genera individuos con pocas variables y, por tanto, muy generales; un operador de cruce multi-punto; un operador de mutación orientada con capacidad para eliminar o modificar aleatoriamente un gen de un individuo; y el operador de reemplazo de la población basado en la ordenación rápida por frentes de dominancia propia del algoritmo NSGA-II. Asimismo, se utiliza una población élite y un mecanismo de competición adicional basado en el proceso de competición de tokens [13]. En la actualización de esta población élite es cuando los individuos cooperan entre sí con el objetivo de obtener una población élite con la atipicidad [3] media más elevada. Esta población élite se actualiza en el operador de reinicialización, que se activa si la población actual no ha sido capaz de cubrir ejemplos no cubiertos anteriormente por un 5 % del total de las evaluaciones totales con el objetivo de evitar estancamientos en óptimos locales.

Finalmente, una vez termina el proceso evolutivo, se realiza un filtro de post-procesamiento con el fin de eliminar aquellas reglas que no tengan una calidad suficiente para el experto. En concreto, para el algoritmo MOEA-EFEP se proponen tres filtros diferentes: obtener patrones con un valor de confianza superior al 60 %, obtener sólo patrones minimales u obtener sólo patrones maximales.

La validez del método propuesto se estudia a través de un exhaustivo estudio experimental con 50 conjuntos de datos con tres objetivos diferentes: por un lado, se plantea la elección de la mejor representación del conocimiento; por otro, se plantea la elección del mejor filtrado de post-procesamiento y, finalmente, se compara MOEA-EFEP con aquellos métodos más relevantes para EPM en función de su metodología de extracción de patrones tal y como se expone en [8]. Todos los resultados obtenidos han sido avalados mediante el uso de test estadísticos no-paramétricos.

En el estudio experimental realizado se demuestra que la capacidad de las reglas en forma normal disyuntiva para la extracción de patrones emergentes con un mayor equilibrio

entre generalidad y fiabilidad de los resultados. Por otro lado, se demostró la calidad de las reglas extraídas mediante el uso del filtro de post-procesamiento basado en valores de confianza mayores al 60 %. Por último, MOEA-EFEP superó de manera significativa al resto de métodos comparados en cuanto a la generalidad de las reglas descriptivas con una fiabilidad similar utilizando para ello un número de reglas mucho menor. Por lo tanto, MOEA-EFEP es un algoritmo que obtiene un modelo de patrones emergentes con el mejor balance generalidad-fiabilidad así como el modelo de reglas más simple.

AGRADECIMIENTOS

Este trabajo ha sido subvencionado por el Ministerio de Economía y Competitividad bajo el proyecto TIN2015-68454-R y el contrato predoctoral FPI referencia BES-2016-077738 asociado al mismo (Fondos FEDER).

REFERENCIAS

- [1] A. M. García-Vico, C. J. Carmona, P. González, and M. J. del Jesus, “Moea-efep: Multi-objective evolutionary algorithm for extracting fuzzy emerging patterns,” *IEEE Transactions on Fuzzy Systems*, In Press.
- [2] P. Kralj-Novak, N. Lavrac, and G. I. Webb, “Supervised Descriptive Rule Discovery: A Unifying Survey of Constraint Set, Emerging Pattern and Subgroup Mining,” *Journal of Machine Learning Research*, vol. 10, pp. 377–403, 2009.
- [3] C. J. Carmona, M. J. del Jesus, and F. Herrera, “A Unifying Analysis for the Supervised Descriptive Rule Discovery via the Weighted Relative Accuracy,” *Knowledge-Based Systems*, vol. 139, pp. 89–100, 2018.
- [4] W. Kloesgen, “Explora: A Multipattern and Multistrategy Discovery Assistant,” in *Advances in Knowledge Discovery and Data Mining*. American Association for Artificial Intelligence, 1996, pp. 249–271.
- [5] S. Wrobel, “An Algorithm for Multi-relational Discovery of Subgroups,” in *Proc. of the 1st European Symposium on Principles of Data Mining and Knowledge Discovery*, ser. LNAI, vol. 1263. Springer, 1997, pp. 78–87.
- [6] S. D. Bay and M. J. Pazzani, “Detecting group differences: Mining contrast sets,” *Data Mining and Knowledge Discovery*, vol. 5, no. 3, pp. 213–246, 2001.
- [7] G. Z. Dong and J. Y. Li, “Efficient Mining of Emerging Patterns: Discovering Trends and Differences,” in *Proc. of the 5th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM Press, 1999, pp. 43–52.
- [8] A. M. García-Vico, C. J. Carmona, D. Martín, M. García-Borroto, and M. J. del Jesus, “An overview of emerging pattern mining in supervised descriptive rule discovery: Taxonomy, empirical study, trends and prospects,” *WIREs: Data Mining and Knowledge Discovery*, vol. 8, no. 1, 2018.
- [9] L. Wang, H. Zhao, G. Dong, and J. Li, “On the complexity of finding emerging patterns,” in *Proc. of the 28th Annual International Computer Software and Applications Conference*, vol. 2, 2004, pp. 126–129.
- [10] G. Z. Dong, J. Y. Li, and X. Zhang, “Discovering jumping emerging patterns and experiments on real datasets,” in *Proc. on International Database Conference Heterogeneous and Internet Databases*, 1999, pp. 155–168.
- [11] K. Ramamohanarao and H. Fan, “Patterns Based Classifiers,” *World Wide Web*, vol. 10, no. 1, pp. 71–83, 2007.
- [12] K. Deb, A. Pratap, S. Agrawal, and T. Meyarivan, “A fast and elitist multiobjective genetic algorithm: NSGA-II,” *IEEE Transactions Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002.
- [13] K. S. Leung, Y. Leung, L. So, and K. F. Yam, “Rule Learning in Expert Systems Using Genetic Algorithm: 1, Concepts,” in *Proc. of the 2nd International Conference on Fuzzy Logic and Neural Networks*, K. Jizuka, Ed., 1992, pp. 201–204.