

Impacto de la heterogeneidad espacial del tráfico de red en el problema del apagado de celdas en redes ultra-densas

Jesús Galeano-Brajonés⁽¹⁾, Francisco Luna-Valero^(2,3), Javier Carmona-Murillo⁽¹⁾,
Juan F. Valenzuela-Valdés⁽⁴⁾, Pablo H. Zapata Cano⁽⁵⁾
jgaleanobra@unex.es, flv@lcc.uma.es, jcarmur@unex.es, juanvalenzuela@ugr.es, pablozapata@auth.gr

⁽¹⁾Dpto. de Ingeniería de Sistemas Informáticos y Telemáticos, Centro Universitario de Mérida,
Universidad de Extremadura, Mérida, 06800, Spain

⁽²⁾Dpto. de Lenguajes y Ciencias de la Computación, Universidad de Málaga, E.T.S.I. Informática, Málaga, 29071, Spain

⁽³⁾ITIS Software, Universidad de Málaga, Edificio de Investigación Ada Byron, Málaga, 29071, Spain

⁽⁴⁾Dpto. de Teoría de la Señal, Telemática y Comunicaciones, CITIC, Universidad de Granada, Granada, 18014, Spain

⁽⁵⁾School of Electrical and Computer Engineering, Aristotle University of Thessaloniki, Thessaloniki, 541 24, Greece

Resumen—The ultra-dense deployment of small base stations is one of the enabling technologies for the next generation of mobile networks (5G and 6G), which leads to an increase in the energy consumption of the infrastructure. This work addresses the selective switch-off of these base stations as a multi-objective optimization problem and analyzes its impact on complexity compared to a network traffic distribution modeling with different levels of irregularity (severity of heterogeneity) in the location of the user equipment. Experimental analysis with three multi-objective metaheuristics on nine different scenarios shows that as the spatial modeling of traffic becomes more irregular, the search for solutions by the algorithms is affected and can alter their ranking, while both network capacity and energy consumption decrease.

I. INTRODUCCIÓN

El despliegue de redes de quinta generación (5G), así como el desarrollo de la siguiente generación (6G) son una realidad actualmente, debido a casos de uso con requisitos que demandan cada vez más prestaciones de la red en términos de tasas de transmisión, latencia y/o número de conexiones en las celdas, añadiendo aspectos de fiabilidad, posicionamiento de alta precisión, inteligencia autónoma, etc. [1]. De entre las diferentes tecnologías habilitadoras para lograr dichas prestaciones, la densificación de la red es clave para el reuso del espectro, y además inducida por el pequeño tamaño de las celdas que imponen las bandas de frecuencias milimétricas [2]. No obstante, este despliegue masivo tiene como contrapartida un incremento en el consumo de la red, puesto que las estaciones base son las responsables de entre el 50 % al 80 % de la demanda energética de este tipo de sistemas [3]. De entre las diferentes estrategias planteadas en la literatura para reducir dicho consumo [4], el apagado de celdas en periodos de baja demanda de tráfico de red es una aproximación estandarizada por el 3GPP [5]. Esta aproximación define un problema de optimización subyacente (la selección del subconjunto óptimo de celdas encendidas), conocido como el Problema del Apagado de Celdas, o CSO por sus siglas en inglés [6], que es NP-completo. Dado el nivel de densificación de las redes 5G/6G, el tamaño de las instancias pueden ascender amiles de celdas y, por tanto, el uso de metaheurísticas para su resolución en la literatura es

bien conocido [7]–[9].

En este trabajo se estudia cómo la heterogeneidad en la infraestructura (despliegue de estaciones base en la red) y la heterogeneidad en la distribución espacial del tráfico de red afecta a la complejidad del problema de optimización anterior. Para ello, se ha utilizado un generador de tráfico propuesto en [10], denominado HetHetNet, que permite ajustar las propiedades estadísticas de la severidad de la heterogeneidad tanto en el modelado espacial del tráfico como en la infraestructura, y su correlación, mediante el uso de Procesos de Puntos de Poisson (PPP). HetHetNet usa el concepto de atractor social (o SA por sus siglas en inglés), como edificios residenciales, universidades, estaciones de transporte público, etc., para generar una distribución de tráfico correlada entre estaciones base (BSs) y equipos de usuario (UEs) en base a dos parámetros α y β como sigue: partiendo de una distribución de Poisson de BSs heterogéneas (micro, pico y femto), una distribución independiente de SAs y una distribución independiente de Poisson de UEs (User Equipments), cada SA se mueve hacia la BS más cercana en términos de la potencia de señal recibida con un factor $\alpha \in [0, 1]$; a continuación, se mueve cada UE hacia el SA más cercano en base a la distancia Euclídea, con un factor $\beta \in [0, 1]$. Mayores valores de α y β permiten generar tráfico mucho más correlado, es decir, con un nivel de agrupamiento mayor. Usando 16 combinaciones de valores propuestos en [10] para estos dos parámetros, y tomando como punto de partida nueve escenarios distintos de redes ultradensas (UDNs) con distintos niveles de densificación de BSs y UEs, se ha evaluado el comportamiento de tres metaheurísticas multi-objetivo, NSGA-II [11], MOCeCell [12] y SMS-EMOA [13]. Los resultados han mostrado que una correlación más elevada, lo que supone un mayor agrupamiento de UEs en torno a SAs y BSs, modifica el espacio de búsqueda del problema multi-objetivo subyacente y hace que la efectividad de los algoritmos varíe, con lo que es posible recomendar uno u otro en base a esta característica del problema. Por otro lado, este mayor agrupamiento también reduce, tanto el consumo de energía (los algoritmos pueden apagar más celdas al estar los UEs más concentrados), como, consecuentemente, la capacidad total ofrecida por la red.

El trabajo se ha estructurado como sigue. En la siguiente sección se formula el modelado de una UDN y del problema CSO. En la Sección III se describe la metodología experimental seguida de los resultados obtenidos. Por último, en la Sección IV se exponen las conclusiones alcanzadas y las líneas de trabajo futuro a desarrollar.

II. DEFINICIÓN DEL PROBLEMA

En esta sección se describe el modelado de una UDN, su parametrización, y la formulación matemática del problema de optimización CSO. Dado que este artículo parte de un trabajo previo [7], esta sección se limita a describir las modificaciones realizadas por limitaciones de espacio.

A. Modelado de la red ultra-densa

Respecto al artículo previo (ver Sección 3 de [7]), el modelado de la UDN ha tenido dos modificaciones en el mecanismo de asociación UE-celda. En primer lugar, en [7], la asociación UE-celda se realiza mediante la máxima SINR (Signal-to-Interference-plus-Noise Ratio) recibida en el UE. Debido a que las interferencias se mitigan en gran medida y pueden ser despreciadas mediante un reúso inteligente de las frecuencias [14], [15], en este artículo se hace uso de la SNR (Signal-to-Noise Ratio). Por lo tanto, la SNR para un UE k se calcula como:

$$SNR_k [dB] = P_{rx,j,k} - P_n \quad (1)$$

donde $P_{rx,j,k}$ es la potencia de señal recibida por el UE k de la celda j y P_n es la potencia del ruido (Ec. 5 en [7]).

En segundo lugar, en el artículo previo la asociación se realizaba considerando el máximo valor de SINR recibida por los UEs. En este trabajo se ha optado por utilizar como mecanismo de asignación la capacidad máxima teórica que se puede ofrecer al usuario suponiendo que la celda no tiene UEs asociados y que puede dedicar todo su ancho de banda al UE en cuestión. Con este mecanismo se promueve la asociación de UEs a celdas más pequeñas y de mayor frecuencia que, por tanto, proveen una mayor capacidad a la vez que inducen un menor consumo.

B. Formulación del problema y objetivos

Siendo \mathcal{B} el conjunto de BSs desplegadas mediante un PPP y \mathcal{C}_b el conjunto de celdas instaladas en la BS b , $\forall b \in \mathcal{B}$, una solución para el problema CSO es una cadena binaria s , donde s_c^b indica si la celda c de la BS b está activa o no. El primer objetivo a minimizar se obtiene mediante:

$$\min f_{Cons.}(s) = \sum_b P_b \sum_c s_c^b \quad (2)$$

donde P_b es el consumo de potencia de la BS b (Ec. 8 de [7]). Recaltar que P_b incluye tanto la potencia de transmisión de cada celda $c \in \mathcal{C}_b$ como su consumo de mantenimiento.

Siendo \mathcal{U} el conjunto de UEs desplegados también mediante un PPP y \mathcal{C} el conjunto completo de celdas en \mathcal{B} . A continuación, para calcular la capacidad total del sistema, los UEs primero se asocian a la celda activa que les ofrece la mayor capacidad teórica. Siendo $\mathcal{A}(s) \in \{0, 1\}^{|\mathcal{U}| \times |\mathcal{C}|}$ la matriz donde $a_{ij} = 1$ si $s_j = 1$ y la celda j sirve al UE i con la mayor capacidad teórica, y $a_{ij} = 0$ si no, el segundo

objetivo a maximizar, la capacidad total proporcionada a todos los UEs, se calcula mediante:

$$\max f_{Cap.}(s) = \sum_c \min(C_c^{accum.}, C_c^{max}) \quad (3)$$

$$C_c^{accum.} = \sum_{i=1}^{|\mathcal{U}|} \sum_{j=1}^{|\mathcal{C}|} s_j \cdot a_{ij} \cdot C_i^j \quad (4)$$

donde $C_c^{accum.}$ es la capacidad acumulada que la celda $c \in \mathcal{C}$ sirve a los UEs del escenario, C_c^{max} es la capacidad máxima que la celda c puede servir, calculada con una $SNR = 25$ dB, y C_i^j es la capacidad que la celda j proporciona al UE i (Ec. 7 de [7]). El $\min(C_c^{accum.}, C_c^{max})$ evita que al objetivo de la capacidad se añadan valores por encima del umbral de capacidad máxima establecido en las celdas. Debemos recalcar que los dos objetivos del problema son claramente contrapuestos, puesto que apagar celdas implica una reducción en el consumo de la red a la vez que repercute en la capacidad servida a los UEs, dado que la distancia UE-celda se incrementa (aumento de las pérdidas por propagación) al mismo tiempo que el BW disponible para servir a los usuarios se reduce.

III. EXPERIMENTACIÓN Y RESULTADOS

En esta sección se describe la metodología experimental utilizada, así como el análisis de los resultados obtenidos.

A. Metodología experimental

Con el objetivo de estudiar el efecto de la heterogeneidad espacial del tráfico de red en la búsqueda de los algoritmos de optimización, hemos utilizado tres metaheurísticas multiobjetivo bien conocidas en la literatura y ya utilizadas en trabajos previos: NSGA-II [11], MOCcell [12] y SMS-EMOA [13]. Los tres algoritmos se han enfrentado al mismo conjunto de instancias del problema: 50 semillas diferentes para cada uno de los nueve escenarios definidos en la Sección 3 de [7]. En total, se han abordado un conjunto de 450 instancias diferentes, con distintas densidades y despliegues, si bien, por motivos de espacio, sólo se presentan resultados de la instancia MM (el resto de adjunta como material suplementario en doi.org/10.6084/m9.figshare.22698826). Además, el código fuente utilizado, que incluye tanto los algoritmos como el modelado, está disponible en github.com/galeanobra/CSO_URSI23. Para analizar las aproximaciones al frente de Pareto obtenidas se han utilizado las superficies de consecución (del inglés *attainment surfaces*) [16], que son una representación gráfica del rendimiento esperado en el espacio de objetivos. En este trabajo se ha usado la *50%-attainment surface* que, informalmente, es la mediana del frente obtenido en el caso monoobjetivo. Por último, en cuanto a los parámetros para el generador de tráfico HetNet, α y β , se han utilizado las 16 configuraciones resultantes de la combinación de los valores [0.0, 0.3, 0.6, 0.9] tanto para α como para β , siguiendo los valores de referencia (ver Figura 8 de [10]).

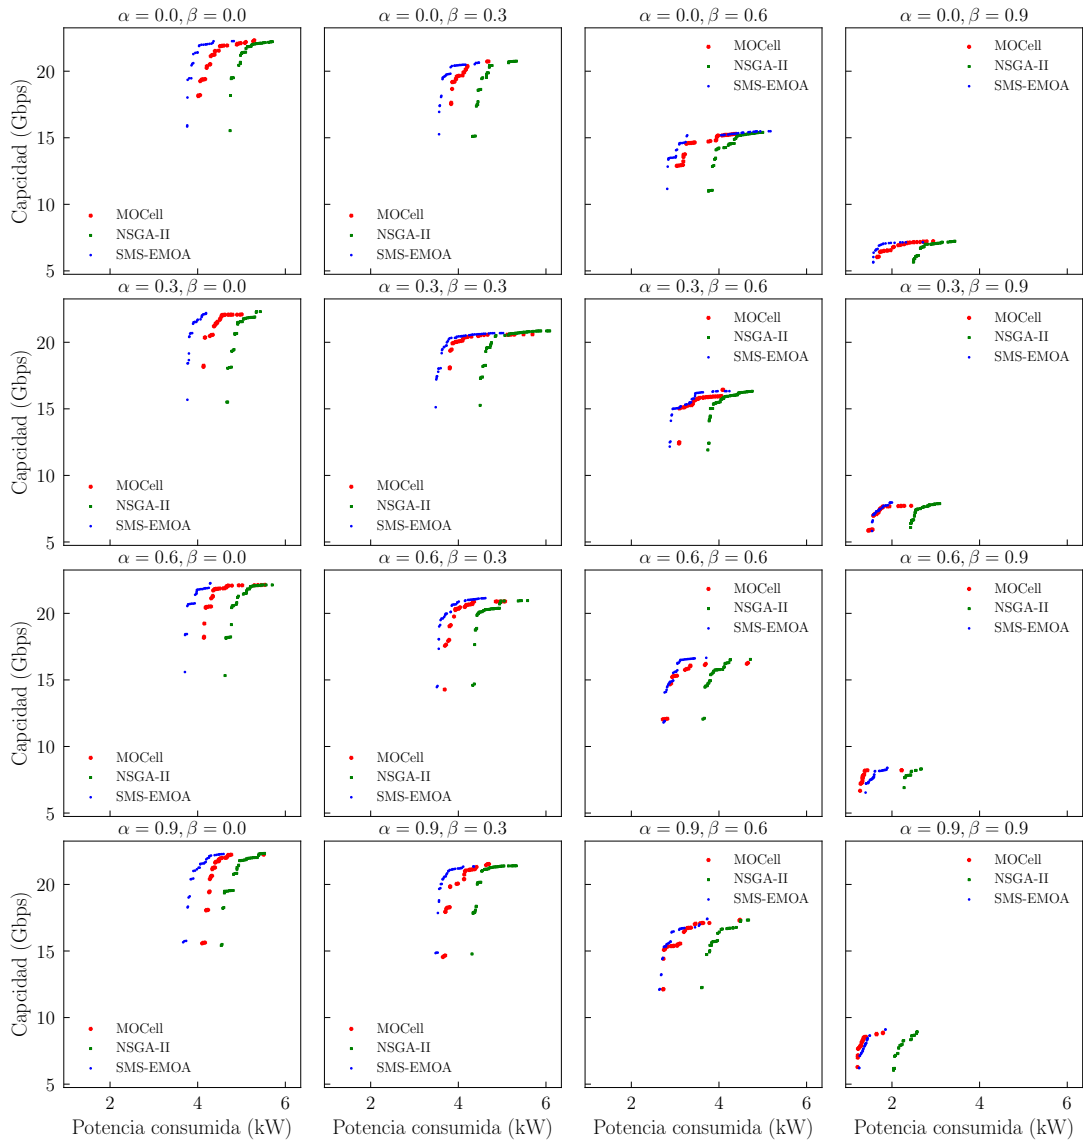


Fig. 1. Superficies de consecución para el escenario MM y las 16 combinaciones de los coeficientes de correlación α y β

B. Resultados

En la Figura 1 se muestran las superficies de consecución de los tres algoritmos para el escenario MM. Esta figura incluye 16 gráficas, una para cada combinación de α y β , organizadas de forma que permita analizar tanto el impacto de variaciones de β (horizontalmente, por filas) y de α (verticalmente, por columnas).

Si comenzamos fijando el valor de α y variando β , se puede observar que las aproximaciones medianas al frente de Pareto llevan a soluciones no dominadas en las que la capacidad de la red se ve reducida, al igual que disminuye el consumo de energía, es decir, dichas aproximaciones tienden hacia la parte inferior izquierda de las gráficas. Esto es debido a que un mayor valor de β supone un mayor nivel de agrupamiento (clustering) de UEs en torno a BSs, con lo que la demanda espacial de tráfico se concentra alrededor de un pequeño conjunto de celdas, que se sobrecargan y pueden servir un menor ancho de banda por UE. Por otro lado, al quedar los UEs asociados a un menor número de celdas, los algoritmos consiguen alcanzar soluciones de menor consumo energético

ya que hay más celdas que no sirven a ningún UE y, por tanto, terminan entre el subconjunto de las mismas que se apagan.

Verticalmente podemos observar que, exceptuando la primera columna, el incremento de α supone que las aproximaciones al frente conllevan leves mejoras de la capacidad a la vez que empeora el consumo de potencia. Esto es claramente visible en la última columna, para $\beta = 0.9$, donde con $\alpha = 0.0$ se alcanzan valores de capacidad de alrededor de 7.5 Gbps, mientras que para $\alpha = 0.9$ se obtienen valores de casi 10 Gbps. Lo mismo ocurre en el consumo de potencia, aunque de forma menos significativa. En el caso de la primera columna, no se muestran cambios significativos debido a que las cuatro subgráficas tienen el valor de $\beta = 0$ mientras que el que varía es α . Esto es debido a que α agrupa los SA alrededor de las BSs pero, si no se agrupan también los UEs alrededor de los SA ($\beta > 0$), es decir, mayor correlación, el despliegue no se verá afectado.

En cuanto al comportamiento de los algoritmos, se observa una constante en la que SMS-EMOA es el que mejores aproximaciones al frente obtiene (es decir, alcanza los mejores

valores tanto de consumo como de capacidad), seguido por MOCcell y, por último, NSGA-II. Cabe destacar que NSGA-II es en todos los casos el algoritmo que obtiene la peor aproximación, y que, para valores elevados tanto de α como de β , MOCcell mejora su rendimiento alcanzando a SMS-EMOA ($\alpha = 0.3, \beta = 0.9$), e incluso superándolo ($\alpha = 0.6, \beta = 0.9$ y $\alpha = 0.9, \beta = 0.9$). Este comportamiento puede comprobarse también en el escenario HH (Fig. 2) de forma aún más significativa. Esta diferencia de comportamiento para los distintos niveles de heterogeneidad espacial de la demanda de tráfico puede ser debido a que una mayor concentración de UEs facilita el apagado de celdas ya que habrá un mayor número de celdas sin, o con muy pocos UEs. Por lo tanto, podemos concluir que estos dos algoritmos ven influenciado su rendimiento por el grado de correlación espacial del tráfico, siendo MOCcell el más beneficiado, y por el grado de densidad de la UDN, ya que en las superficies de consecución de HH se observa de forma más significativa este comportamiento.




Fig. 2. Superficies de consecución para el escenario HH y las 4 combinaciones más elevadas de los coeficientes de correlación α y β

IV. CONCLUSIONES

El apagado de celdas en redes 5G/6G ultradensas es un tema candente para la reducción del consumo energético de las redes de próxima generación. La complejidad de este problema es dependiente de diversos factores de la red, entre los que se encuentra la heterogeneidad espacial del tráfico. En este trabajo se ha comprobado que la complejidad de este problema se ve significativamente afectada por esta heterogeneidad, demostrando que llega a alterar el ranking entre los algoritmos a la vez que disminuye tanto la capacidad como el consumo de la red, lo que conlleva la recomendación de uno u otro algoritmo en función de esta característica.

Como trabajo futuro, proponemos el análisis de la heterogeneidad espacial para distintos mecanismos de asociación UE-celda como, por ejemplo, basándose en máxima SNR/SINR recibida por el UE. Además, realizaremos un estudio en

profundidad sobre el comportamiento de los algoritmos en la búsqueda de soluciones con la heterogeneidad espacial.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por la Unión Europea NextGenerationEU/PRTR con los proyectos TED2021-131699B-I00 y TED2021-129938B-I0 (MCIN/AEI/10.13039/501100011033, FEDER), y por el Ministerio de Ciencia e Innovación con el proyecto PID2020-112545RB-C54. Los autores también quieren agradecer al Centro de Supercomputación y Bioinnovación de la Universidad de Málaga por proveer sus servicios y el supercomputador Picasso para la realización de los experimentos (<https://www.scbi.uma.es/>).

REFERENCIAS

- [1] C. X. Wang, X. You, X. Gao, X. Zhu, Z. Li, C. Zhang, H. Wang, Y. Huang, Y. Chen, H. Haas, J. S. Thompson, E. G. Larsson, M. D. Renzo, W. Tong, P. Zhu, X. Shen, H. V. Poor, and L. Hanzo, "On the Road to 6G: Visions, Requirements, Key Technologies and Testbeds," *IEEE Communications Surveys and Tutorials*, 2023.
- [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] M. Yao, M. Sohil, X. Ma, V. Marojevic, and J. H. Reed, "Sustainable green networking: exploiting degrees of freedom towards energy-efficient 5G systems," *Wir. Networks*, vol. 25, no. 3, pp. 951–960, 2019.
- [4] O. Alamu, A. Gbenga-Ilori, M. Adelabu, A. Imoize, and O. Ladipo, "Energy efficiency techniques in ultra-dense wireless heterogeneous networks: An overview and outlook," *Engineering Science and Technology, an International Journal*, 2020.
- [5] 3GPP, "Small Cell Enhancements for E-UTRA and E-UTRAN—Physical Layer Aspects," tech. rep., 3rd Generation Partnership Project (3GPP), 2014.
- [6] G. David, E. Mufafungwa, B. Haile, J. Hamalainen, and H. Poveda, "A Planning and Optimization Framework for Ultra Dense Cellular Deployments," *Mobile Information Systems*, vol. 2017, pp. 1–17, 2017.
- [7] J. Galeano-Brajones, F. Luna-Valero, J. Carmona-Murillo, P. H. Z. Cano, and J. F. Valenzuela-Valdés, "Designing problem-specific operators for solving the cell switch-off problem in ultra-dense 5G networks with hybrid MOEAs," *Swarm and Evolutionary Computation*, vol. 78, p. 101290, 2023.
- [8] F. Luna, R. Luque-Baena, J. Martínez, J. Valenzuela-Valdés, and P. Padilla, "Addressing the 5G cell switch-off problem with a multi-objective cellular genetic algorithm," in *IEEE 5G World Forum, 5GWF 2018 - Conference Proceedings*, pp. 422–426, 2018.
- [9] D. G. González, J. Hämäläinen, H. Yanikomeroglu, M. García-Lozano, and G. Senarath, "A novel multiobjective cell switch-off framework for cellular networks," *IEEE access*, vol. 4, pp. 7883–7898, 2016.
- [10] 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.
- [11] 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.
- [12] A. J. Nebro, J. J. Durillo, F. Luna, B. Dorronsoro, and E. Alba, "MOCcell: A cellular genetic algorithm for multiobjective optimization," *Int. Journal of Intelligent Systems*, vol. 24, no. 7, pp. 726–746, 2009.
- [13] N. Beume, B. Naujoks, and M. Emmerich, "SMS-EMOA: Multiobjective selection based on dominated hypervolume," *Euro. J. of Operational Research*, vol. 181, no. 3, pp. 1653–1669, 2007.
- [14] M. A. Mohan and K. Giridhar, "Interference-aware accurate signal recovery in sub-1 ghz uhf band reuse-1 cellular ofdma downlinks," *IEEE Open Journal of the Communications Society*, vol. 3, pp. 2087–2105, 2022.
- [15] N. Al-Falahy and O. Y. Alani, "Network capacity optimisation in millimetre wave band using fractional frequency reuse," *IEEE Access*, vol. 6, pp. 10924–10932, 2017.
- [16] 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)*, pp. 552–557, IEEE, 2005.