

Metaheurísticas para Smart Mobility: Reducción de Emisiones y Consumo de Carburantes en el Tráfico Urbano

José García-Nieto and Enrique Alba

Dept. de Lenguajes y Ciencias de la Computación,
Universidad de Málaga, E.T.S.I. Informática,
B. Louis Pasteur 35, 29071, España
{jnieto,eat}@lcc.uma.es

Resumen Hoy en día, la mejora del tráfico vehicular supone una labor ineludible en nuestras ciudades a la hora de mitigar problemas como la excesiva emisión de gases contaminantes y el consumo no sostenible de carburantes. El concepto de Smart Mobility enmarca el conjunto de acciones, técnicas e infraestructuras encaminadas a la mejora de la movilidad y organización del tráfico en las ciudades. En este contexto, proponemos en este trabajo una estrategia de optimización basada en técnicas metaheurísticas de Inteligencia Colectiva para la programación de ciclos en los semáforos desplegados en grandes zonas metropolitanas. De esta forma, pretendemos mejorar el flujo del tráfico de los vehículos con el objetivo global de reducir las emisiones de gases contaminantes (CO_2 y NO_x) y el consumo de combustible en las áreas observadas. En este estudio seguimos el modelo de referencia en la Unión Europea para las emisiones de tráfico HBEFA y nos centramos en dos áreas urbanas localizadas en las ciudades de Málaga y Sevilla. Tras varias comparativas entre diferentes técnicas de optimización y con soluciones dadas por expertos en el dominio, comprobamos cómo nuestra propuesta es capaz de obtener reducciones significativas en términos de emisiones contaminantes y de consumo de carburante.

Keywords: Programación de Semáforos, Particle Swarm Optimization, Simulador de Tráfico SUMO, Modelo de Emisiones de Tráfico HBEFA

1. Introducción

En las últimas décadas, el elevado nivel de contaminación del aire y el consumo de hidrocarburos derivado del tráfico urbano están desembocando en serios problemas que directamente afectan a la salud de los ciudadanos, a la economía global y al mantenimiento de nuestras ciudades. Por tanto, la mejora de la movilidad supone una tarea fundamental en las grandes áreas metropolitanas, lo cual repercute en la gestión eficiente del tráfico vehicular. Debido a que la modernización de las infraestructuras físicas es muy costosa y no es siempre abordable, los esfuerzos en este sentido deben dirigirse en gran medida hacia una planificación

eficiente de los semáforos. De esta forma se puede agilizar, con un bajo coste, la circulación de vehículos en las ciudades [7,8,9]. No obstante, el número de semáforos operativos está creciendo y su planificación conjunta es cada vez más compleja debido a la gran cantidad de combinaciones de periodos de colores que se deben manejar. Por tanto, la utilización de sistemas automáticos inteligentes para la programación óptima de ciclos de semáforos es una tarea indispensable en la gestión del tráfico vehicular.

En este sentido, el empleo de técnicas inteligentes de optimización, como los algoritmos metaheurísticos [1], ha ido ganando importancia con el tiempo ya que se ha demostrado su adecuación en la planificación de semáforos [3,9,10]. Sin embargo, en ningún caso (según nuestro conocimiento) se ha tratado la optimización de los programas de ciclos desde la perspectiva medioambiental, para la reducción de emisiones contaminantes y de consumo de fuel. Además, en la mayoría de los casos, el uso de dichos sistemas inteligentes se ha limitado por lo general a la optimización de instancias académicas pequeñas, con uno o dos cruces y con 8 semáforos como mucho, o que están diseñados en exclusiva para zonas muy específicas, impidiendo estudios de ciudades completas.

Por tanto, la motivación principal de este trabajo es la de proponer una estrategia de optimización, basada en un algoritmo de Cúmulo de Partículas (o PSO, Particle Swarm Optimization) [5], para la obtención de programas de ciclos de semáforos eficientes desde el punto de vista de varios factores medioambientales: emisiones de CO_2 y NO_x , además de la cantidad total de combustible consumido por los vehículos. Lo haremos además sobre grandes áreas urbanas y para un elevado número de semáforos y vehículos, demostrando que las metaheurísticas son una tecnología clave para el escalado futuro en este dominio de aplicación.

PSO es un algoritmo de fácil configuración que por lo general desarrolla una rápida convergencia a soluciones de calidad [5]. Esto es una característica deseable ya que nos permite obtener soluciones satisfactorias en fases tempranas de optimización. Para la evaluación de los programas de ciclos generados (codificados como vectores solución), hemos utilizado el simulador de tráfico microscópico SUMO (Simulator of Urban Mobility) [6], mediante el que se obtiene una fuente de información constante sobre el flujo de vehículos. Esto es fundamental para poner usar un algoritmo avanzado y hacer planificación automática. Además, SUMO nos permite trabajar con el modelo estándar de emisiones HBEFA (Hand-Book Emission Factors) [4], a través del cual obtenemos la información sobre las emisiones de polución y el consumo de combustible, que será utilizada por el algoritmo de optimización para la evaluación de soluciones.

Para este estudio hemos utilizado dos instancias localizadas en los centros urbanos de Málaga y Sevilla, con cientos de semáforos y diferentes densidades de tráfico (entre 250 y 500 vehículos circulando en tiempo de simulación). Los resultados y comparaciones con otras técnicas: Evolución Diferencial (DE) [11], Random Search (RANDOM) y Sumo Cycle Program Generator (SCPG) [6], ponen de relieve las mejoras significativas obtenidas por nuestra propuesta en términos de emisiones de CO_2 y NO_x , así como de consumo de combustible.

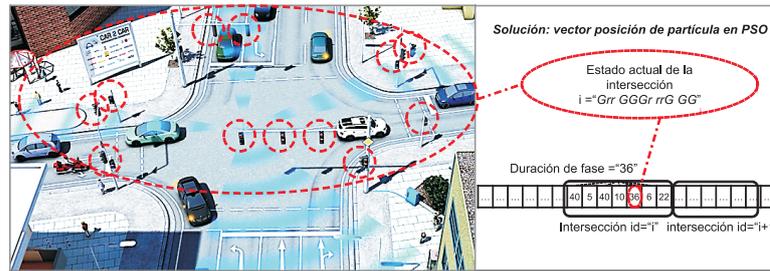


Figura 1. Programa de ciclos en una intersección

Este trabajo se organiza de la siguiente manera. En la Sección 2 se presenta el problema de la programación óptima de ciclos en semáforos y se introduce el modelo de emisiones HBEFA. La Sección 3 describe nuestra estrategia de optimización. La Sección 4 está dedicada a los experimentos y análisis de soluciones. Las conclusiones globales y el trabajo futuro se resumen en la Sección 5.

2. Programas de Ciclos y Modelo de Emisión HBEFA

En la red vial de tráfico, los semáforos se sitúan en las intersecciones y controlan el flujo del tráfico mediante sus programas de estados de colores y periodos de duración. Dentro de una misma intersección, todos los semáforos se gobiernan por un programa común, ya que deben estar necesariamente sincronizados por motivos de seguridad. Además, para todos los semáforos en una misma intersección, la combinación de colores durante un periodo de ciclo debe ser siempre válida, siguiendo las reglas de tráfico específicas con el fin de evitar colisiones y accidentes en general. En nuestro modelo trabajamos exclusivamente con combinaciones válidas de estados de colores para cada intersección, las cuales permanecen constantes durante el proceso de optimización. Así se evita la aparición de combinaciones de estado no válidas y se restringe la optimización únicamente a la búsqueda de estados factibles.

En este contexto, nuestro principal objetivo consiste en encontrar **programas de ciclos optimizados** para todos los semáforos situados en una determinada área urbana. Definimos un ciclo como el periodo de tiempo en el que un conjunto de semáforos (en un cruce) permanecen con sus estados de luces/colores fijos. Al mismo tiempo, estos programas deben también coordinarse con semáforos en intersecciones adyacentes, mejorando así el flujo de vehículos que circulan conforme a la regulación vial establecida.

- *Codificación.* Siguiendo la especificación de SUMO para la programación de ciclos, hemos codificado las posibles soluciones como vectores de naturales. De esta forma, cada elemento del vector (variable) representa una duración de fase de los semáforos implicados en una determinada intersección. La Figura 1 muestra un ejemplo de codificación representando la intersección “*i*”, la cual consta de 12 semáforos con estado actual “*Grr GGGr rrG GG*”, es decir 7 semáforos

en verde (G) y los otros 5 en rojo (r), durante 36 segundos. La siguiente fase cambiará el estado de los semáforos a otra combinación válida “ $yGG rrry GGr yy$ ” (siendo ‘ y ’ ámbar), durante 6 segundos. Tras finalizar la última fase en una intersección (el número de fases en cada intersección puede ser diferente), vuelve a tomar la primera actuando de manera cíclica. Esta representación nos permite además tener en cuenta la interdependencia entre variables, no sólo para duraciones de fase en una misma intersección, sino que también para semáforos en intersecciones adyacentes.

Por otra parte, SUMO nos permite simular factores medioambientales basados en el modelo HBEFA (HandBook Emission Factors for Road Transport) [4]. A través de este modelo podemos simular diferentes condiciones de vehículos con información sobre aceleraciones, deceleraciones, frenado, velocidades máximas, así como su repercusión en las emisiones basadas en HBEFA: hidrocarburos, partículas emitidas, niveles de CO , CO_2 , NO_x y otros agentes de polución. En este estudio nos hemos centrado en los agentes contaminantes CO_2 y NO_x , además del consumo de combustible ($Fuel = F$).

- *Función de Fitness.* Para evaluar cada programa de ciclos se ha formulado la siguiente función de fitness $f(s)$, mediante la cual se considera la información del tráfico obtenida por simulación con datos reales de la ciudad:

$$f(s) = \frac{\| \sum_{V_i} CO_2(s) \|_l + \| \sum_{V_i} NO_x(s) \|_l + \| \sum_{V_i} F(s) \|_l}{\#edges} + \rho \cdot \bar{V}(s) \quad (1)$$

El objetivo principal consiste en minimizar los niveles de emisiones y consumo general en los escenarios estudiados. Como puede observarse en la Ecuación 1, en primer término se consideran los cómputos de cada indicador de emisión por vehículo (V), normalizados por la longitud de la vía (l) en la que se obtienen dichos niveles de emisión, CO_2 y NO_x en mg/s, además del consumo F en l/s. Esta suma de tres términos se divide además entre el número de vías/calles ($\#edges$) transitadas por los vehículos. Finalmente, se considera el producto de los vehículos que no llegan al destino en tiempo de observación (\bar{V}), por una constante de gasto medioambiental ρ . Debido a que no es posible computar los niveles medioambientales de los vehículos que quedan atascados (no llegan en tiempo de simulación), se ha calculado esta constante $\rho = 0,75$ como el gasto aproximado medio por vehículo en recorrer su ruta en diferentes condiciones de densidad de tráfico.

3. Estrategia de Optimización

Nuestra estrategia de optimización se compone por dos partes principales: la optimización con Particle Swarm Optimization (PSO) [5] y la obtención de datos desde SUMO. Para el desarrollo de nuestro PSO hemos seguido las especificaciones del último estándar 2011 [2]. En este algoritmo, cada posición de partícula x^i se actualiza cada iteración g mediante la Ecuación 2.

$$x_{g+1}^i = x_g^i + v_{g+1}^i \quad (2)$$

donde el término v_{g+1}^i se calcula por la actualización de la velocidad:

$$v_{g+1}^i = w \cdot v_g^i + Gr_g^i - x_g^i + HS(Gr, \| Gr - \mathbf{x}_g \|) \quad (3)$$

$$\text{con } Gr_g^i = \frac{x_g^i + p_g^i + l_g^i}{3}, \quad p_g^i = x_g^i + c \cdot (p_g^i - x_g^i), \quad l_g^i = x_g^i + c \cdot (l_g^i - x_g^i) \quad (4)$$

En esta fórmula, p_g^i es la mejor solución que la partícula i ha obtenido en toda su historia, l_g^i es la mejor partícula dentro de un vecindario de dimensión $k = 3$ seleccionada aleatoriamente (uniforme) del cúmulo y w es el factor de inercia (decrece linealmente con el número de iteraciones de 0,5 a 0,1). El coeficiente de aceleración $c > 1$ es un valor aleatorio normal con $\mu = 1/2$ y $\rho = 1/12$. Este coeficiente se actualiza de nuevo para cada componente en el vector de velocidad. Por último, HS es un generador de números aleatorios en una hipersfera (Hyper-Sphere), con Gr como centro de gravedad. Es decir, Gr se calcula como el punto equidistante entre p_g^i , l_g^i y x_g^i . Con este mecanismo se consigue la independencia sobre el sistema de coordenadas, mejorando este aspecto sobre las anteriores versiones de PSO [2].

Debido a que la optimización de programas de ciclos se codifica mediante vectores de números naturales (representando ciclos de duración de fase), hemos utilizado el método de cuantificación (*quantisation*) provisto en la especificación del estándar PSO 2011 [2]. El método de cuantificación se aplica a cada nueva partícula (generada con la Ecuación 2) y transforma las variables continuas a discretas. Básicamente consiste en un cuantificador uniforme de Mid-Thread como se especifica en la Ecuación 5, con paso de cuantificación $\Delta = 0,5$.

$$Q(x) = \Delta \cdot \lfloor x/\Delta + 0,5 \rfloor \quad (5)$$

La simulación se utiliza para asignar un valor de calidad *fitness* a las soluciones codificadas en las partículas, para un determinado escenario urbano. Esta simulación se lleva a cabo instanciando SUMO con datos de la ciudad. Así, cuando el algoritmo PSO genera una nueva solución con un nuevo programa de ciclos, se inicia SUMO para procesar distintos escenarios de tráfico sobre la ciudad con: calles, direcciones, semáforos, vehículos, rutas, etc., respecto al nuevo programa de ciclos. Tras el procesado de diferentes escenarios, SUMO devuelve los valores necesarios para computar la función de *fitness* (Ecuación 1). Cada nuevo programa de ciclos se carga en cada proceso de simulación. En este sentido, lo demandado actualmente en ingeniería civil son programas de ciclos constantes para áreas y para franjas horarias preestablecidas (hora punta, horario nocturno, festivos, etc.), lo cual nos llevó a abordar el problema con este enfoque.

4. Experimentos

En este trabajo hemos generado dos escenarios de tráfico con información real a partir de mapas digitalizados (ilustrados en la Figura 2). Estos escenarios están físicamente localizados en las ciudades de Málaga y Sevilla cubriendo áreas similares de aproximadamente $0,75 \text{ km}^2$.

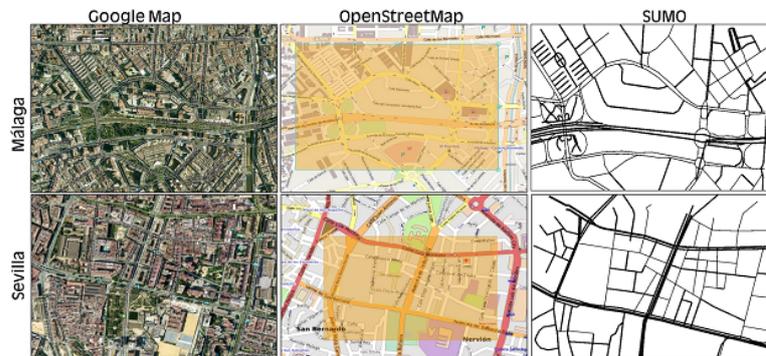


Figura 2. Instancias de Málaga y Sevilla exportadas al formato de SUMO

La información utilizada para ello consiste en: reglas de tráfico regulado, situación de las señales, direcciones, calles, intersecciones, etc. Además, se ha determinado el número de vehículos circulando, así como sus velocidades a partir de las especificaciones de las Delegaciones de Movilidad de estas ciudades ¹. Dichas áreas contienen las siguientes características:

1. *Málaga*. Localizado entre las avenidas Andalucía y Aurora, este escenario (Figura 2, arriba) se compone de avenidas y calles con diferente longitud y número de vías, además de varias rotondas. Contiene intersecciones incluyendo desde 4 a 16 semáforos cada una.
2. *Sevilla*. Cubre el céntrico distrito de Nervión (Figura 2, abajo). Se compone de intersecciones con entre 4 y 17 semáforos cada una.

El número de intersecciones estudiadas es de 70 en ambos escenarios aunque, cabe clarificar, que el número de semáforos no es el mismo ya que dichas intersecciones son muy diferentes entre sí, sumando 304 semáforos en Málaga y 323 en el caso de Sevilla. Además, para cada escenario hemos generado dos instancias con diferentes densidades de tráfico con 250 y 500 vehículos circulando en un tiempo de estudio de 1.200 segundos (iteraciones de microsimulación). Este tiempo de duración fue determinado como el tiempo máximo que tarda un coche en completar su ruta, incluso si éste debiera parar en todos los semáforos que encontrara y con la densidad de tráfico inicial. Cuando un vehículo abandona el recorrido del escenario, ya no volverá a aparecer de nuevo durante el tiempo de observación. Cada uno de los vehículos recorre su propia ruta con una velocidad máxima de 50 *km/h* (velocidad típica en las áreas urbanas).

Para la ejecución del algoritmo hemos utilizado la implementación en C++ de PSO (Standard 2011) que provee la biblioteca MALLBA [1]. La fase de simulación se realiza mediante el simulador SUMO en su versión 0.12.0 para Linux.

¹ Málaga (<http://movilidad.malaga.eu/>), Sevilla (<http://www.trajano.com/>). Esta información se obtuvo a partir de puntos sensorizados en ciertas calles de la ciudad, calculando así una medida de la densidad de tráfico en varios intervalos temporales.

Los experimentos se realizaron en clusters de máquinas, en su mayoría equipadas con procesadores Quad Core (4 núcleos), 2GB de RAM y S.O. Linux Debian.

Para cada escenario se realizaron 30 ejecuciones independientes de nuestro PSO. El tamaño del cúmulo es de 30 partículas, realizando 300 iteraciones de optimización (resultando de esta manera 9.000 evaluaciones de SUMO) por ejecución e instancia. Como ya comentamos en la sección anterior, el tamaño de la partícula depende directamente del número de fases en cada programa de ciclos de los semáforos, siendo 312 y 368 para las instancias de Málaga y Sevilla, respectivamente.

De manera adicional, hemos implementado para esta experimentación un algoritmo de Evolución Diferencial (DE) [11] en su versión Canónica *DE\rand\1* y otro de Random Search, los dos en el ámbito de la biblioteca MALLBA. De esta forma, sometiendo estos algoritmos al mismo procedimiento experimental que a PSO esperamos obtener algunos indicios sobre la potencia de nuestra propuesta, respecto a otra metaheurística (en el caso de DE) con modelo de aprendizaje cercano al de PSO, así como respecto al un algoritmo puramente estocástico, como en el caso de Random Search (RAND). El número máximo de evaluaciones a realizar por estos dos algoritmos fue también de 9.000.

Por último, añadimos un cuarto algoritmo a la comparación que consiste en el generador de programas de ciclos de SUMO (SCPG). Este último algoritmo consiste básicamente en asignar a las duraciones de fase de los semáforos nuevos valores en el rango (6, 31), de acuerdo a tres factores diferentes: la proporción de estados en verde de las fases, el número de vías de entrada en las intersecciones y el tiempo de frenado de los vehículos cuando se acercan a los semáforos². De esta forma, podemos contrastar también el rendimiento de nuestra propuesta frente al modelo humano que SCPG representa.

4.1. Resultados y Comparaciones

En primer lugar, analizamos en esta sección el comportamiento de nuestra propuesta desde el punto de vista de su rendimiento computacional. En la Tabla 1 podemos ver los resultados, en cuanto a valor de calidad (*fitness*), obtenidos por nuestro PSO. Estos resultados consisten en el máximo (Max.), la mediana (Med.), el mínimo (Min.), la media (Mea.) y la desviación Típica (Std.) de las distribuciones obtenidas para los escenarios de Málaga y Sevilla, con densidades de tráfico de 250 y 500 vehículos. Junto a estos resultados se disponen además los obtenidos utilizando DE, RAND y SCPG, siguiendo el mismo procedimiento de optimización y sobre las diferentes instancias. Además, en esta misma tabla, las últimas filas para cada instancia contienen el resultado de realizar tests estadísticos (no-paramétricos) [12] de Friedman y Holm para determinar qué algoritmo muestra mejor *ranking* y si existen diferencias significativas con respecto a éste y los demás. En concreto, estos resultados consisten en los *p-valores ajustados* por el test de Holm (HA_p) para un valor de confianza estadística $\alpha = 0,05$.

² La información completa sobre el funcionamiento del algoritmo SCPG en [6].

Tabla 1. Valores de calidad obtenidos para Málaga y Sevilla con 250 y 500 vehículos

Ciudad	Valor	Densidad de tráfico (Número de vehículos)							
		250				500			
		PSO	DE	RAND	SCPG	PSO	DE	RAND	SCPG
Málaga	Max,	1,04E+02	1,08E+02	1,11E+02	1,05E+02	2,95E+02	3,06E+02	3,42E+02	5,59E+02
	Med,	9,76E+01	1,02E+02	1,08E+02	1,05E+02	2,41E+02	2,62E+02	3,07E+02	5,59E+02
	Min,	9,12E+01	9,83E+01	1,04E+02	1,05E+02	1,92E+02	2,25E+02	2,66E+02	5,59E+02
	Mea,	9,72E+01	1,02E+02	1,08E+02	1,05E+02	2,41E+02	2,64E+02	3,04E+02	5,59E+02
	Std,	3,00E+00	1,93E+00	1,50E+00	0,00E+00	2,50E+01	1,94E+01	1,95E+01	0,00E+00
	HA_p	-	<i>1,42E-02</i>	<i>1,78E-08</i>	<i>1,33E-16</i>	-	<i>1,09E-01</i>	<i>5,20E-06</i>	<i>5,49E-16</i>
Sevilla	Max,	2,04E+02	2,19E+02	2,16E+02	3,96E+02	5,89E+02	5,91E+02	5,58E+02	7,27E+02
	Med,	1,73E+02	1,89E+02	2,10E+02	3,96E+02	4,74E+02	5,00E+02	5,34E+02	7,27E+02
	Min,	1,54E+02	1,79E+02	1,97E+02	3,96E+02	4,21E+02	4,79E+02	5,09E+02	7,27E+02
	Mea,	1,78E+02	1,92E+02	2,08E+02	3,96E+02	4,75E+02	5,10E+02	5,36E+02	7,27E+02
	Std,	1,49E+01	9,08E+00	5,79E+00	0,00E+00	3,17E+01	2,96E+01	9,55E+00	0,00E+00
	HA_p	-	<i>7,18E-02</i>	<i>1,52E-07</i>	<i>6,82E-17</i>	-	<i>9,32E-03</i>	<i>9,58E-07</i>	<i>1,89E-17</i>

Como primera observación de la Tabla 1, podemos destacar que nuestra estrategia de optimización con PSO obtiene el mejor fitness (minimizando) para todos los escenarios de tráfico, siendo las diferencias entre las distribuciones de resultados de los algoritmos estadísticamente significativas. Existe una excepción en el escenario de Sevilla con 250 vehículos para el cual, los resultados de DE son estadísticamente similares ($p\text{-valor} = 7,18E-02$) a los de PSO, aunque con peor *ranking* para DE. Precisamente, el algoritmo DE obtiene el segundo mejor *ranking*, seguido por RAND y SCPG.

En este sentido, una segunda interesante observación consiste en que todos los algoritmos de búsqueda con componente estocástica obtienen, por lo general, mejor resultado que el propio generador de SUMO (SCPG), de operación determinista. Podemos ver que incluso el algoritmo RAND genera, tras cierto número de simulaciones, mejores configuraciones de semáforos que SCPG. Estos resultados nos dan cierta confianza respecto a la eficacia de nuestra estrategia de optimización, ya que en la gran mayoría de los experimentos, PSO nos proporciona beneficios cuantitativos respecto al método utilizado actualmente.

4.2. Análisis de los Factores Medioambientales

En esta sección pasamos a analizar el impacto directo sobre los factores medioambientales estudiados. Para ello utilizaremos los programas de ciclos resultantes tras la experimentación.

Tal y como se contempla en el modelo HBEFA [4], las emisiones de CO_2 y NO_x son los compuestos químicos con más concentración detectados en los tests de tubo de escape en vehículos de gasolina y diesel, respectivamente³. Por tanto, para este estudio hemos contabilizado las trazas de estos dos compuestos generados por todos los vehículos circulando en nuestros escenarios. La Figura 3 (derecha) contiene las gráficas de barras de concentraciones generales (g/s) de los mejores programas de ciclos generados por cada algoritmo, para los escenarios de Málaga y Sevilla. Además, se disponen también los valores de consumo de carburantes ($Fuel$ en l/s).

³ Las emisiones de CO son proporcionales a las de CO_2 en HBEFA.

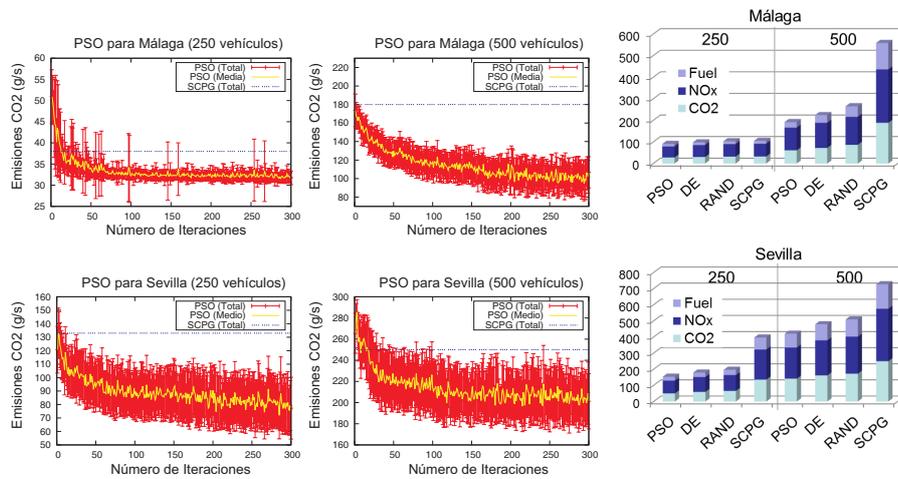


Figura 3. Trazas de emisión de CO_2 (izq.) y coste medioambiental general (der.)

De manera general, se puede observar cómo el gasto medioambiental de los programas de ciclos generados por PSO es inferior al de las demás estrategias. Si bien, es SCPG el que provoca un empeoramiento cualitativo mayor respecto a todos los factores de polución y consumo. Estas diferencias se incrementan para los casos con más densidad de vehículos (500), lo cual refleja que el margen de mejora de PSO podría ser aún mayor en escenarios de gran escala, con miles de vehículos y grandes áreas metropolitanas. En concreto, en el caso de Sevilla con 500 vehículos, la mejora obtenida por PSO para el CO_2 con respecto a SCPG es del 43,2%; la mejora respecto al NO_x es del 40,9%; y la mejora respecto al consumo de carburante es del 43,4%.

Como caso particular, en la Figura 3 (izquierda-centro) se disponen las gráficas de evolución de CO_2 para cada instancia producidas por los programas de ciclos generados mediante PSO. En el caso de Sevilla, se puede observar una mayor variabilidad en los programas de ciclos obtenidos por PSO que para el escenario de Málaga. Esto nos da idea de la diferencia en la complejidad entre los dos escenarios. No obstante, para ambos casos, ya desde las primeras etapas de optimización, nuestra propuesta consigue mejorar los niveles de polución con respecto a la solución de SUMO (representada mediante líneas de puntos).

5. Conclusiones

En este trabajo, proponemos una estrategia de optimización basada en PSO y simulación con SUMO para la generación de programas de ciclos de semáforos. El objetivo es reducir las emisiones de CO_2 y NO_x , así como el consumo de carburantes mediante la mejora del tráfico rodado. Como casos de estudio hemos seguido modelos de tráfico realistas localizados en dos áreas de $0,75km^2$ en las ciudades de Málaga y Sevilla, con densidades de tráfico de 250 y 500 vehículos.

Como conclusión global podemos destacar que nuestra propuesta de optimización consigue mejoras significativas en términos de emisiones de polución y de consumo de combustible, respecto a los programas de los expertos en el área (utilizadas en SUMO). Dependiendo de la instancia, la mejora para los tres factores (CO_2 , NO_x y $Fuel$) está en el rango entre el 12% y 43%. Si extrapolamos estas cantidades al caso real de la ciudad de Málaga, con aproximadamente 600.000 habitantes y 2,15 toneladas CO_2 habitante/año de tráfico rodado⁴, el ahorro aproximado rondaría las 510.000 toneladas (40% menos) de CO_2 que se dejarían de emitir por año en esta ciudad.

Como trabajo futuro, pretendemos extender el estudio a instancias de aún mayor escala (cubriendo ciudades enteras) y utilizando algoritmos con operadores de diseño específico al problema.

Agradecimientos Este trabajo está parcialmente financiado por el Ministerio de Economía y Competitividad (MINECO) del Gobierno de España y fondos FEDER con el proyecto roadME con TIN2011-28194 (<http://roadme.lcc.uma.es>). José García-Nieto disfruta de una beca con código BES-2009-018767 del MINECO.

Referencias

1. E. Alba, G. Luque, J. García-Nieto, G. Ordoñez, and G. Leguizamón. Mallba: a software library to design efficient optimisation algorithms. *International Journal of Innovative Computing and Applications*, 1(1):74–85, 2007.
2. M. Clerc and J. Kennedy. Standard PSO 2011. Particle Swarm Central Site [online] <http://www.particleswarm.info/>, January 2011.
3. J. García-Nieto, A. Olivera, and E. Alba. Optimal cycle program of traffic lights with particle swarm optimization. *IEEE Trans. on Evo. Comp.*, In Press, 2013.
4. M. Keller. Handbook of Emission Factors for Road Transport (HBEFA) 3.1. quick reference. Technical report, INFRAS, 2010.
5. J. Kennedy and R. C. Eberhart. *Swarm Intelligence*. Morgan Kaufmann Publishers, San Francisco, California, 2001.
6. D. Krajzewicz, M. Bonert, and P. Wagner. The open source traffic simulation package SUMO. *RoboCup 2006 Infrastructure Simulation Competition*, 2006.
7. X. Li, G. Li, S. Pang, X. Yang, and J. Tian. Signal timing of intersections using integrated optimization of traffic quality, emissions and fuel consumption: a note. *Transportation Research Part D: Transport and Environment*, 9(5):401 – 407, 2004.
8. J. McCrean and S. Moutari. A hybrid macroscopic-based model for traffic flow in road networks. *European Journal of Operational Research*, 207(2):676–684, 2010.
9. J. Sánchez Medina, M. Galán Moreno, and E. Rubio Royo. Applying a Traffic Lights Evolutionary Optimization Technique to a Real Case: Las Ramblas Area in Santa Cruz de Tenerife. *IEEE Trans. on Evo. Comp.*, 12(1):25 –40, 2008.
10. L. Peng, M. Wang, J. Du, and G. Luo. Isolation niches particle swarm optimization applied to traffic lights controlling. In *48th IEEE Conference on Decision and Control and 28th Chinese Control Conference*, pages 3318 –3322, dec. 2009.
11. K. Price, R.M. Storn, and J.A. Lampinen. *Differential Evolution: A Practical Approach to Global Optimization*. Natural Computing. Springer, 2005.
12. D. J. Sheskin. *Handbook of Parametric and Nonparametric Statistical Procedures*. Chapman & Hall/CRC, 2007.

⁴ Fuentes Dictamen para el año 2008, Área de Medio Ambiente Diputación de Málaga