

# Management of Urban Traffic Flow Based on Traffic Lights Scheduling Optimization

P. Vidal, and A. Olivera

**Abstract**—The automobile has become an essential element in the daily life of people. In the urban traffic network, an intersection is the “bottleneck point” of road network capacity. Most cities in Latin America have a traditional single control system or none. In this context, adequate programming of the traffic light cycles helps to reduce vehicles’ waiting time and improve traffic flow. In this paper, we compare five metaheuristics to minimize vehicles’ waiting time and maximize the velocity of vehicles in two real scenarios of Argentina and Uruguay. Analysis of experimental results shows that the proposed model optimizes the vehicular flow in a multiple-junction urban traffic network with different topologies and traffic flow.

**Index Terms**—Metaheuristics, Optimization, Simulation, Traffic lights scheduling.

## I. INTRODUCCIÓN

EL crecimiento imparable del parque automotriz es un fenómeno presente en las ciudades. El principal problema está dado por la infraestructura vial de las ciudades que no están preparadas para los nuevos desafíos de la actividad moderna. Frente a esto en algunos casos la infraestructura y topología de la ciudad no es posible modificarla debido a que suele traer aparejados altos costos económicos. Existen entonces diferentes alternativas para abordar esta problemática, algunos investigadores abordan la resolución de congestiones del tráfico mediante diferentes herramientas [1]–[3]. Siguiendo con estas iniciativas, los investigadores en esta área están de acuerdo de que una correcta programación de los semáforos reduce la congestión, mejorando el flujo vehicular [4].

Dado que optimizar el flujo del tráfico vehicular mediante la correcta configuración de los ciclos de los semáforos en escala real tiene una complejidad computacional no polinómica [5], surge la necesidad de buscar herramientas computacionales que aproximen el óptimo para el problema en cuestión. Varias técnicas de inteligencia artificial han probado ser útiles en la resolución de problemas de optimización, obteniendo buenos resultados en tiempos razonables de cómputo. En particular, las metaheurísticas han sido utilizadas para resolver problemas de programación de ciclos de semáforos en diferentes escenarios [4]–[9].

En el presente trabajo, se propone un modelo de optimización y se realiza el análisis del mismo sobre dos topologías urbanas reales utilizando técnicas metaheurísticas combinadas con simulación con el objetivo de mejorar la programación de los ciclos de los semáforos a fin de aportar

fluidez al tráfico y, al mismo tiempo, minimizar el impacto ambiental de los vehículos circulantes disminuyendo su concentración en las arterias de la red. Las principales contribuciones se pueden resumir en:

- Se presenta una función mono-objetivo relacionada únicamente con factores del flujo vehicular. La función considera como principal componente a la velocidad de los vehículos y el tiempo de espera de los mismos. Esto permite utilizarla para zonas donde exista una planta automotriz con autos eléctricos o híbridos además de los de combustible fósil.
- Se realiza un análisis de las soluciones obtenidas por algoritmos populares en la literatura *recocido simulado* (RS), *algoritmos genéticos* (AG) y *optimización por cúmulo de partículas* (OCP); y un algoritmo reciente, *optimización de colonia de abejas* (OCA) en contraposición con *evolución diferencial* (ED) sobre dos casos de estudio con datos de flujo vehicular tomados *in situ* de las ciudades de Posadas en Argentina y Montevideo en Uruguay.
- Los resultados demostraron que no solo las variables incluidas en la función objetivo son mejoradas ampliamente por ED con respecto al resto de los algoritmos y a la configuración actual de los semáforos sino también otras variables, no contempladas en forma directa, como la emisión de contaminantes y el gasto de combustible fósil. Esto último, no significa que simplemente se consume menos combustible sino también que los vehículos combustionan mejor ayudando a mantener la vida útil de los mismos.

El manuscrito se organiza de la siguiente manera: la Sección II presenta un resumen de los trabajos relacionados con el tema. El problema de la programación de los ciclos de los semáforos se describe en la Sección III. En la Sección IV se introduce nuestra propuesta. En la Sección V se describen las instancias utilizadas para evaluar las metaheurísticas y en la Sección VI se analizan los resultados. Por último, en la Sección VII se describen las conclusiones alcanzadas.

## II. ESTADO DEL ARTE

Diferentes investigadores han abordado el problema de la programación de los ciclos de los semáforos tratando de reducir tiempos de viaje, contaminación ambiental y consumo de combustible, entre otros. En particular el uso de métodos inteligentes ha demostrado ser útil para la programación de los semáforos [5], [10].

Olivera et al. [4] utilizan optimización basada en cúmulo de partículas para la planificación de ciclos de semáforos en

la ciudades de Sevilla y Málaga. La función mono-objetivo usa a la polución como un aspecto a optimizar aunque posee problemas para manejar la visión global del tráfico, por ejemplo, en el caso de atascos que disminuyan el flujo vehicular, una solución puede ser considerada muy buena desde el punto de vista de la reducción de contaminación dependiendo del peso que tenga este término. Este problema está dado por la inclusión de las emisiones contaminantes y el combustible (fósil) como parte de la función mono-objetivo lo que genera, por ejemplo, que no se tenga en cuenta la posibilidad de autos eléctricos o híbridos circulando. Más aún, la función mono-objetivo es dependiente del peso utilizado en el término que considera el flujo vehicular lo que podría distorsionar los valores obtenidos por la simulación. Los autores tampoco consideran el *offset* como parte de la solución a optimizar, utilizan el valor por defecto, o sea "0" esto significa que las programaciones comienzan todas en el mismo momento. Por lo tanto, el *offset* no es aprovechado para conseguir ondas verdes en avenidas utilizando dicha variable como si lo es en el presente trabajo.

Damay [7] optimiza la duración de la luz verde para una red de tráfico real de la ciudad de Rouen en Francia. Se integra el simulador SUMO (simulación de movilidad urbana) [11] como herramienta de simulación y un algoritmo multi-objetivo. Este trabajo, tiene como propósito minimizar el tiempo de espera total y las emisiones contaminantes de los vehículos. La propuesta mejora el programa de los ciclos de los semáforos, minimizando la mayoría de las variables analizadas si se compara con el programa utilizado en la red.

Ji et al. [12] presentan un esquema de coordinación de señales de tráfico enfocado en la reducción de emisiones vehiculares y la disminución de la demora de los vehículos en la ciudad de Changzhou (China). Se utiliza una plataforma de simulación de emisión microscópica comercial y se establece un modelo de emisión completo para estimar la reducción de emisiones de tráfico.

Chou et al. [6] consideran la tecnología de redes vehiculares *ad hoc* (VANET) para construir un entorno de semáforos virtuales para reducir la congestión del tráfico. El objetivo de este estudio es ajustar los ciclos de luces de los semáforos según la demanda para permitir que los vehículos pasen por numerosas intersecciones rápidamente, ahorrando así energía y reduciendo el consumo de combustible. El estudio utiliza el protocolo de entorno de semáforos virtuales guiado por velocidad para mejorar la situación de congestión del tráfico en áreas urbanas. Puede facilitar un flujo de tráfico eficiente en las intersecciones y evitar paradas innecesarias. Sin embargo, no considera posibles ataques maliciosos a las VANET.

En [13], los autores proponen reducir la congestión del tráfico, unificando dos estrategias: el reencaminamiento dinámico de vehículos y control de los ciclos de los semáforos. Cada vehículo, es representado como un agente que deposita feromonas digitales sobre su ruta, mientras que los agentes de infraestructura recolectan feromonas y las fusionan para evaluar las condiciones del tráfico en tiempo real y para predecir los niveles esperados de congestión vial en el futuro. Una vez que se predice la congestión vial, se emplea una estrategia proactiva de reencaminamiento de vehículos basada

en la distancia global y feromonas locales para asignar rutas alternativas a vehículos seleccionados antes de que entren en las arterias congestionadas. Al mismo tiempo, los agentes modifican los ciclos de los semáforos para aliviar aún más la congestión del tráfico. El principal inconveniente de esta técnica es la inversión económica tanto para el ente regulador como los usuarios del servicio para ponerla en práctica.

En [14], Leal et al. describen un control activo para encontrar dinámicamente programas de ciclos de semáforos que optimicen las condiciones del tráfico en redes delimitadas y corredores. El sistema propuesto, incluye un modelo predictivo de demora de tiempo, utilizado junto con enfoques evolutivos como algoritmos genéticos y técnicas de evolución diferencial. Los datos recopilados son de la ciudad de Belo Horizonte, en Brasil y se propone utilizar un simulador comercial. El proceso de optimización consiste en modificar los tiempos de luces verdes de los semáforos en, sólo, cuatro intersecciones, utilizando un algoritmo genético y evolución diferencial. Con los resultados obtenidos, se observa que el uso de AG como algoritmo de optimización, disminuye en un 47% el tiempo de demora promedio total de vehículos en la red estudiada en comparación con el plan de control en uso.

En Perés et al. [5] se analiza el impacto de tres algoritmos multiobjetivo evolutivos sobre la programación de los ciclos de los semáforos en Montevideo, Uruguay. Los resultados son promisorios considerando el uso de operadores clásicos no adaptados a las características del problema en cuestión.

En el presente trabajo, se realiza un estudio de la programación de los ciclos de los semáforos sobre el microcentro de Posadas (Argentina) y una parte del barrio Jacinto Vera en Montevideo (Uruguay), con diferentes topologías, con el objetivo de minimizar el tiempo de espera de los vehículos circulando por la red y maximizar su velocidad. Para ambas instancias se utilizó información real del estado de los semáforos y del tráfico circulante a fin de comparar los resultados obtenidos a través de cinco metaheurísticas populares en la literatura. Los resultados obtenidos mejoran la fluidez del tráfico reduciendo los tiempos de espera y aumentando la velocidad de los vehículos favoreciendo la disminución del combustible consumido y la contaminación ambiental. En particular, evolución diferencial se destaca por mejorar no solo la fluidez de los vehículos sino también por reducir la polución y el gasto de combustible.

### III. PROGRAMACIÓN DE LOS CICLOS DE LOS SEMÁFOROS

Distintos investigadores [7], [14], [15] están de acuerdo en que, cuando no es posible cambiar la topología de una red de tráfico, el uso de dispositivos reguladores como los semáforos ayudan a minimizar los impactos negativos de la circulación de vehículos en las ciudades. En este sentido, programar los ciclos de las luces de los semáforos constituye una herramienta que incide directamente en el flujo vehicular.

La programación de los ciclos de los semáforos se define como los segundos durante los cuales un estado de luces o fase permanece activo del conjunto de estados de luces que atraviesa una intersección. Dichas fases siguen las reglas del tráfico y son definidas previamente considerando la topología

de cada intersección. Para el presente estudio las fases serán siempre válidas y previamente definidas, variando únicamente, los segundos durante los cuales están activas. Además cada intersección posee un *offset* que regula el momento dentro de las fases en que inicia cada intersección.

Para este trabajo, se desea optimizar la programación de los ciclos de las luces de los semáforos analizando su impacto sobre la red de tráfico considerando como función objetivo minimizar  $Z$  definido en (1).

$$Z = \frac{w}{v} \times 3.6 \quad (1)$$

donde,  $w$  es el tiempo en segundos (s) de espera medio que tuvieron los vehículos sobre la red de tráfico mientras que la  $v$  es la velocidad media de los vehículos (m/s) sobre la red. Luego, la constante 3.6 realiza la conversión de m/s a km/h.  $Z$  entonces expresa la relación entre la espera y la velocidad de forma tal que cuanto mayor sea la espera de vehículos detenidos, mayor es la congestión. Esto implica que la velocidad de los vehículos en la red disminuye. Dicho de otra manera, cuanto menor sea  $Z$  mejor será la fluidez del tráfico. Esto implica menos tiempos de espera en la red y mayor velocidad de los vehículos.

Tanto los tiempos perdidos como la velocidades medias son obtenidas a partir de la simulación del tráfico con SUMO del microcentro de Posadas y del barrio Jacinto Vera en Montevideo. SUMO [11], [16] es un microsimulador popular en la literatura que toma como entrada un mapa, una programación de los semáforos del mapa, vehículos y sus rutas a fin de simular la red de tráfico. Como resultado el simulador obtiene información relevante sobre parámetros de eficiencia de la red de tráfico en las distintas calles de la ciudad, el número de vehículos circulando, entre otros. A partir de estos datos se construye el valor de  $Z$ .

#### IV. METODOLOGÍA DE OPTIMIZACIÓN

Con el objetivo de obtener programaciones de los ciclos de los semáforos que ayuden a mejorar el flujo vehicular en dos diferentes topologías urbanas se analizó el comportamiento de cinco metaheurísticas populares en la literatura combinadas con el simulador SUMO.

La metodología general de optimización se muestra en la Fig. 1. Un algoritmo de optimización obtiene soluciones (programaciones de los ciclos de semáforos) que son enviadas al simulador. SUMO, con el mapa de la zona, la programación de los ciclos de los semáforos (programación\_semáforos.xml) y la información real de las rutas de los vehículos (rutas.xml) realiza la simulación. A partir de los datos de salida del simulador se evalúan las soluciones. Este proceso se repite hasta alcanzar la condición de terminación.

##### A. Codificación de la Solución

Dada la topología de una red de tráfico representada como un grafo  $G = (N, A)$  donde  $N$  es el conjunto de nodos (intersecciones) y  $A$  el conjunto de arcos (calles). Entonces del conjunto  $N$  estaremos interesados en aquellos nodos que poseen semáforos  $N_s \in N$ . Para cada intersección semaforizada ( $s_i$ )

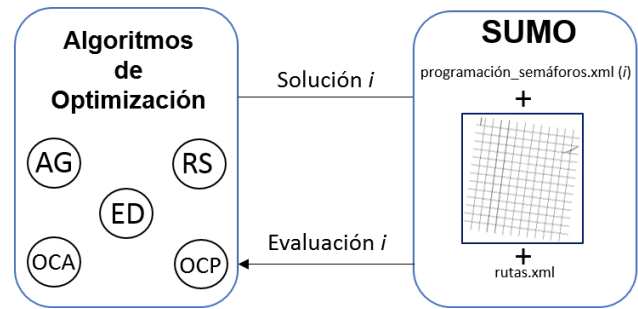


Fig. 1. Esquema de la metodología utilizada.

tendremos un *offset* ( $o_i$ ) y las duraciones en segundos de cada fase ( $k$ ) del ciclo asociado a dicha intersección ( $t_{i_k}$ ). Luego, una solución para el problema de programación de los ciclos de los semáforos estará codificada como una lista de enteros  $[o_1 t_{1_1} t_{1_2} \dots t_{1_l} \dots o_h t_{h_1} \dots t_{h_j}]$ ,  $h = 1..|N_s|$ . El *offset* permite a una intersección iniciar dicho programa en diferentes momentos de su ciclo con el objetivo de lograr una coordinación (onda verde) con los demás semáforos de la red y mejorar el flujo vehicular.

##### B. Algoritmos de Optimización

Optimizar la programación de los ciclos de los semáforos implica explorar un enorme espacio de soluciones, lo cual conlleva para simuladores de tráfico y técnicas exactas un gran tiempo de computo que afecta la toma de decisiones cuando las instancias son grandes. El uso de técnicas inteligentes, en particular algoritmos de optimización estocásticos, ha demostrado ser útil para obtener soluciones de calidad en tiempos razonables [17], [18]. En el presente trabajo, se utilizaron cinco algoritmos de optimización: *algoritmos genéticos* [17], [19], *evolución diferencial* [20], [21], *recocido simulado* [1], [22], *optimización por cúmulo de partículas* [4], [23], [24] versión 2011 y un algoritmo reciente en la literatura conocido como *optimización de colonias de abejas artificiales* [25]. Los algoritmos seleccionados presentan diferentes características que permiten explorar y explotar de diversas formas el espacio de soluciones. OCP es aplicado en varios trabajos para el tratamiento del problema de programación de semáforos [4]. Los AG fueron de los primeros algoritmos de optimización aplicados a la optimización de semáforos. RS es una técnica probabilística, no basada en población. La ED es una estrategia de optimización bien conocida para varios tipos de problemas y, para este trabajo, se muestra su potencial para mejorar el flujo de tráfico en las áreas urbanas. Finalmente, se utiliza un algoritmo de optimización reciente no aplicado antes a la programación de semáforos, el algoritmo OCA.

#### V. EXPERIMENTOS

Para analizar el impacto de los diferentes algoritmos utilizados para programar los ciclos de los semáforos sobre el tráfico vehicular se utilizaron datos reales de dos áreas urbanas de las ciudades de Posadas (Argentina) y Montevideo (Uruguay). Cada área presenta una topología urbana distinta a fin de mostrar la potencialidad de la propuesta en diferentes




Fig. 2. Área de estudio seleccionada del microcentro de Posadas.

escenarios. En la codificación propuesta, todos los valores para las fases y demoras de los semáforos son enteros positivos y se expresan en segundos. Siguiendo trabajos anteriores sobre el tema [4], [5] y las regulaciones definidas en el Manual de Capacidad de Carreteras [26], se adoptó un límite de 60 segundos por fase. La duración del ciclo correspondiente depende del número de fases de semáforos definidas en cada intersección (dos fases en la mayoría de las intersecciones y tres fases en aquellas intersecciones donde se permite girar a la izquierda). Para la duración mínima de la fase, especialmente para las luces verdes, se tuvo en cuenta la información obtenida por observación [15]. Si consideramos que las fases tienen tiempos dentro del intervalo [12, 60] salvo las fases con semáforos en amarillo que tienen un tiempo fijo de 3 segundos, siguiendo las recomendaciones de la ingeniería del tráfico [26], el número de combinaciones posibles que deberían probarse para el caso, por ejemplo, de Posadas que contiene 71 intersecciones semaforizadas se puede definir como  $48^{142} \times 60^{71}$  (espacio de soluciones) considerando que 142 son las fases sin luces amarillas del número total de fases (213) mientras que el valor del *offset* varía dentro del intervalo [0, 60] [26].

Para Posadas, utilizamos una matriz origen-destino (matriz OD) de vehículos circulando por el microcentro de la ciudad de Posadas, Misiones, entre las avenidas Corrientes, Jorge Saenz Peña, Roque Perez y Bartolomé Mitre entre las 8 y las 9 a.m. en día de la semana. La topología de la red de tráfico se obtuvo a través del OpenStreetMap [27] (ver Fig. 2). Luego, se migró a SUMO y se construyó el escenario a partir de la matriz OD y la configuración de los semáforos. De manera similar, para la instancia de Montevideo (Fig. 3) utilizamos la matriz origen-destino de vehículos circulando entre las 8 y las 10 a.m. en día de semana. En las Fig. 2 y 3 se observan marcados con puntos rojos las intersecciones semaforizadas de ambas áreas urbanas. En ambos casos las redes de tráfico son simuladas por un periodo de 900 segundos.

Las configuraciones de los algoritmos están basadas en



Fig. 3. Área de estudio seleccionada de Montevideo.

estudios previos y en pruebas no reportadas. La Tabla I resume los valores asignados a los parámetros de cada algoritmo. En particular, para el AG se evalúan dos operadores de mutación, el primero modifica el valor en el intervalo  $[-5, +5]$  y el segundo ajusta el valor de la variable en múltiplos de 5. Cada algoritmo se denomina AG y AG\_R5 respectivamente.

Con el fin de verificar si las diferencias entre los algoritmos son estadísticamente significativas o solo por casualidad, se realiza una prueba de Kolmogorov-Smirnov para verificar si las muestras se distribuyen de acuerdo con una distribución normal o no. Si es así, se realiza una prueba ANOVA I; De lo contrario, se realiza una prueba de Kruskal-Wallis. Dado que más de dos algoritmos están involucrados en el estudio, se realizó una fase de prueba post-hoc que permite múltiples comparaciones de muestras (comparación múltiple) [28], [29].

Todas las pruebas estadísticas se realizan con un nivel de confianza del 95 %. Los algoritmos se han desarrollado en Python 2.7. Para todos ellos, la condición de parada se establece en 10000 evaluaciones. Se realizan 30 ejecuciones independientes con las instancias seleccionadas. Todas las ejecuciones se llevan a cabo en el cluster del Centro Nacional de Supercomputación (ClusterUY, <http://cluster.uy/>) [30].

## VI. RESULTADOS OBTENIDOS

Esta sección presenta la calidad de las soluciones obtenidas por los algoritmos evaluados. Los mejores resultados (mínimos) se han marcado en gris oscuro, mientras que los segundos mejores resultados se han marcado en gris claro. En primer lugar, se analiza el comportamiento de nuestra propuesta desde el punto de vista de su rendimiento computacional, posteriormente se examina la solución del mejor algoritmo contra la configuración actual y la incidencia de esta en factores tales como contaminantes y gasto de combustible.

En las tablas II y III se pueden observar los valores de aptitud obtenidos por los algoritmos y el alcanzado empleando la configuración actual de los semáforos en Posadas y en Montevideo respectivamente. La Tabla II y la Tabla III muestran el mejor, el peor, la media (Prom.), la desviación estándar (Std.) y se exponen los porcentajes de mejora (%) en

TABLA I  
CONFIGURACIÓN PARA CADA ALGORITMO

Algoritmo	Parámetro	Valor
AG	Población	100
	Selección	Torneo Binario
	Cruce	Un solo punto (SPX)
	Prob. cruce	con prob. 100%
	Mutación	Redondeo [-5,5] con prob. 10% Variación -5,5 con prob. 10%
OCA	Población	20
	Limite intentos	20
	Población	40
OCP	Coficiente Local ( $\varphi_1$ )	2.05
	Coficiente Social ( $\varphi_2$ )	2.05
	Inercia	0.5
	Población	1
RS	Factor enfriamiento	0.995
	Perturbación	Redondeo [-5,5]
	Porcentaje perturbación	10%
ED	Población	10
	Factor mutación	0.8
	Prob. cruce	0.85

velocidad promedio y tiempo de espera de cada algoritmo con respecto a la configuración actual.

Como primera observación de la Tabla II, podemos destacar que casi todas las estrategias de optimización seleccionadas (con excepción del RS) obtienen mejor valor de aptitud con respecto a la configuración actual. El algoritmo ED presenta los mejores resultados con respecto a la eficacia de las estrategias de optimización proporcionando beneficios cuantitativos respecto a la configuración actual utilizada. La ED supera los enfoques de AG, OCA, OCP y RS. Las dos variantes del AG y el OCA obtienen mejores valores que la configuración actual aunque las diferencias entre estos algoritmos parecen ser insignificantes. De la misma forma, el AG, el AG\_R5 y el OCA obtienen valores muy similares de porcentaje de mejora, presentando diferencias en el espacio de la solución en los tiempos de espera existiendo una diferencia de 1% aproximadamente. La utilización de la configuración de semáforos generada por la ED obtiene una mejora del 4% con respecto a la velocidad promedio de los autos y un 30% con respecto al tiempo de espera promedio de los autos en la simulación indicando una clara mejora en la fluidez del tráfico.

En la Tabla III podemos destacar que los mejores valores son obtenidos por la ED y en segundo lugar por el AG. El resto de algoritmos salvo el RS, obtienen valores similares de aptitud. Al evaluar los porcentajes de mejora vemos que todos salvo RS obtienen mejoras considerables en velocidad y reducción de tiempo de espera. La ED obtiene una mejora de velocidad del 8,6% aproximadamente en comparación a la configuración actual. Para el caso de los tiempos de espera vemos que La ED queda en segundo lugar con un 46,3% con respecto al AG que obtiene un 47,8% de mejora, lo que puede ser condicionado por la topología de la instancia de Montevideo y el número bajo de vehículos simulados. En general, la evidencia experimental sugiere que es beneficioso utilizar operadores orientados a la explotación para lograr rápidamente una solución competitiva.

Las Fig. 4 y 5 muestran la evolución de los valores de aptitud para las instancias de Posadas y Montevideo respecti-

TABLA II  
VALORES DE APTITUD DE LOS ALGORITMOS  
Y LA CONFIGURACIÓN ACTUAL PARA POSADAS

Alg.	Mejor	Peor	Prom.	Std.	Mejora Vel.(%)	Mejora T. espera(%)
C. Act.	52,73	52,73	52,73	-	-	-
AG	43,11	45,98	44,92	1,25	-0,358	10,708
AG_R5	43,47	47,33	44,84	1,40	-0,005	12,890
OCA	43,95	47,51	46,22	1,23	-0,124	11,969
OCP	39,37	41,05	40,38	0,66	0,859	20,941
RS	62,49	68,58	65,80	2,52	-4,933	-32,614
ED	30,34	35,49	32,74	2,03	4,406	33,181

TABLA III  
VALORES DE APTITUD DE LOS ALGORITMOS  
Y LA CONFIGURACIÓN ACTUAL PARA MONTEVIDEO

Alg.	Mejor	Peor	Prom.	Std.	Mejora Vel.(%)	Mejora T. espera(%)
C. Act.	194,21	194,21	194,21	-	-	-
AG	151,18	153,81	152,62	0,99	7,865	47,789
AG_R5	154,28	156,91	155,60	1,09	6,177	45,994
OCA	155,45	157,73	156,30	0,86	5,853	42,951
OCP	152,96	153,96	153,55	0,41	7,530	44,897
RS	204,28	215,25	209,16	4,20	-3,766	-26,049
ED	150,01	151,25	150,61	0,57	8,686	46,293

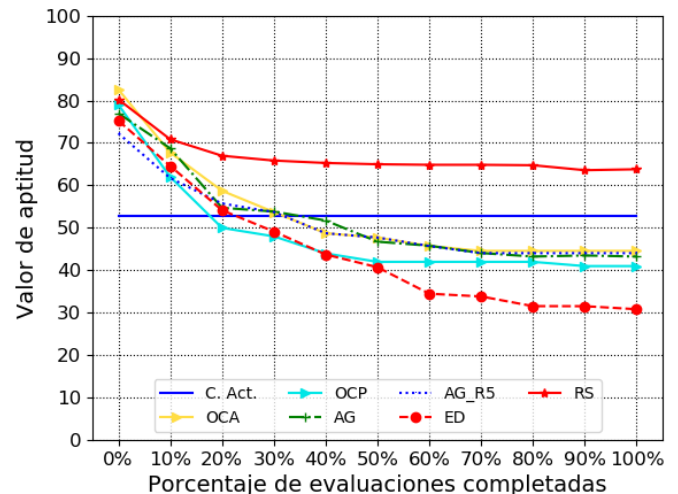


Fig. 4. Evolución del valor de aptitud promedio para los algoritmos y la configuración actual en una ejecución para Posadas.

vamente. La Fig. 4 presenta los valores de aptitud promedio obtenidos al alcanzar un determinado número de evaluaciones en una ejecución con la configuración actual de semáforos y los algoritmos evaluados. Se observa que al alcanzar el 40% de evaluaciones completadas casi todos los algoritmos mejoran la configuración actual (excepto el RS). Posteriormente, al llegar a la mitad del proceso las soluciones van convergiendo y las mejoras son mínimas comparado con la ED la cual logra seguir explorando y evitar el estancamiento prematuro. Para la instancia de Montevideo (Fig. 5), es importante remarcar que al alcanzar el 10% de evaluaciones completadas todos los algoritmos (salvo RS) mejoran el valor de aptitud con respecto al obtenido con la configuración actual de los semáforos. Una vez más, ED obtiene los mejores valores de aptitud al completar las evaluaciones.

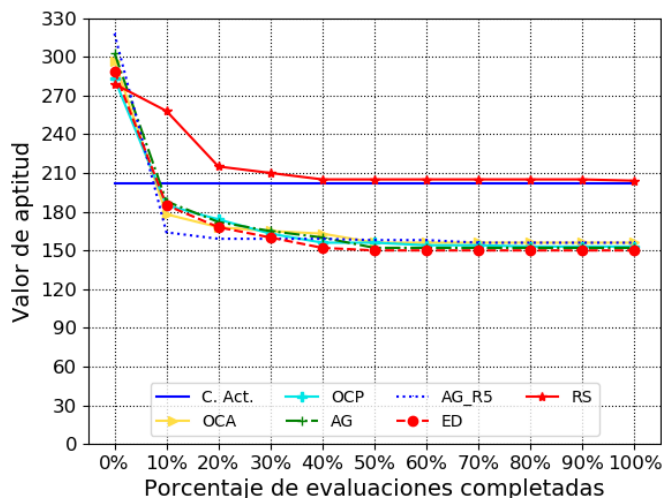


Fig. 5. Evolución del valor de aptitud promedio para los algoritmos y la configuración actual en una ejecución para Montevideo.

TABLA IV

SIGNIFICANCIA ESTADÍSTICA ENTRE LOS ALGORITMOS

Instancia	Algoritmo	AG_R5	OCA	OCP	RS	ED
Posadas	AG	▲	▲	▽	▲	▽
	AG_R5		▲	▽	▲	▽
	OCA			▽	▲	▽
	OCP				▲	▽
	RS					▽
Montevideo	AG	▲	▲	▽	▲	▽
	AG_R5			▽	▲	▽
	OCA				▲	▽
	OCP				▲	▽
	RS					▽

El análisis estadístico realizado (ver Tabla IV) confirma los resultados obtenidos por la ED. Los valores obtenidos se muestran en forma tabular, un triángulo hacia arriba negro (▲) indica que el algoritmo tiene valores estadísticamente más altos que el de la columna, un triángulo hacia abajo blanco (▽) indica que el algoritmo tiene valores estadísticamente más bajos que el presentado en la columna. Cuando no se encuentran diferencias estadísticamente significativas, el lugar se deja vacío. Se puede ver que el algoritmo ED presenta una significancia estadística con respecto al resto de algoritmos. La ED presenta un mejor comportamiento en este problema al mantener la diversidad y explorar mejores soluciones que los otros algoritmos, con un equilibrio adecuado entre la capacidad de explorar el espacio de búsqueda del problema y la de explotar las propiedades locales de búsqueda.

Finalizando el análisis cuantitativo, se presenta en las Fig. 6, 8, 7 y 9 la evolución de la velocidad promedio y el tiempo de espera promedio respectivamente entre el algoritmo ED (línea roja) contra lo obtenido por la configuración actual de los semáforos (línea azul punteada) para Posadas y Montevideo.

En el caso de la Fig. 6 se observa claramente como la velocidad promedio se mantiene con poca variación y mayor velocidad que la conseguida con la configuración actual. Para la Fig. 7 los tiempos de espera son similares para ED y no presentan diferencias excesivas en los tiempos de espera como pasa con la configuración actual. Para la instancia de

Montevideo, la velocidad promedio (ver Fig. 8) mejora en casi toda la simulación a la la velocidad promedio utilizando la configuración actual. Con respecto al tiempo de espera (Fig. 9) aumenta para el caso de evolución diferencial lo cual en principio parecería ir en detrimento de la metodología propuesta. La Fig. 10 nos muestra un análisis de los vehículos que fluyen por la red durante la simulación. El número de vehículos para Montevideo es mucho menor para el caso de ED (casi 100) que para el caso de la configuración actual (aproximadamente 150). De manera similar ocurre con Posadas. Se observa en general que la relación autos existentes en el sistema es más baja con la ED que la mostrada por la configuración actual lo que implica que los vehículos llegan a su destino rápidamente con la metodología propuesta.

A continuación se realiza un análisis ambiental (Fig. 11) entre una solución obtenida por el algoritmo ED (línea roja) y la conseguida con la configuración actual de los semáforos (línea azul punteada). En la Fig. 11 podemos observar la evolución de los contaminantes producidos CO (Monóxido de Carbono), CO<sub>2</sub> (Dióxido de Carbono), NO<sub>x</sub> (Óxidos de Nitrógeno), PM<sub>x</sub> (Partículas en Suspensión), HC (Hidrocarburos mal quemados) (mg/s) y el combustible consumido (ml/s) por los vehículos que circulan por la red de tráfico durante la simulación.

La Fig. 11a muestra que si bien las programaciones de los semáforos de la configuración actual y de la solución obtenida por ED comienzan la simulación produciendo CO (en mg/s) similar, a medida que la simulación avanza, la programación obtenida por ED mantiene una producción de CO con poca variación y más baja que la obtenida utilizando la programación actual. Al final de la simulación ED alcanza una diferencia a su favor de más del 10%. Para el caso del CO<sub>2</sub> (mg/s), Fig.11b, ambas configuraciones alcanzan valores similares al final de la simulación. Sin embargo, la configuración actual genera picos o momentos con grandes emisiones de CO<sub>2</sub> y otros momentos con menos emisiones. Esto esta relacionado directamente con las congestiones que se producen a lo largo de la simulación con la configuración actual lo que genera que los vehículos aceleren y desaceleren




Fig. 6. Velocidad media durante la simulación para Posadas.

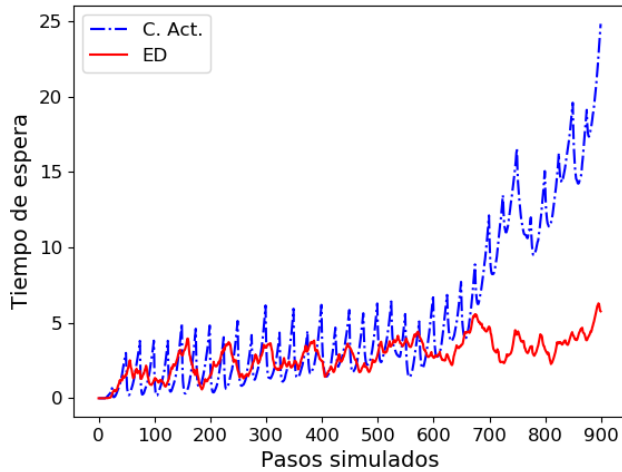


Fig. 7. Tiempo de espera promedio durante la simulación para Posadas.

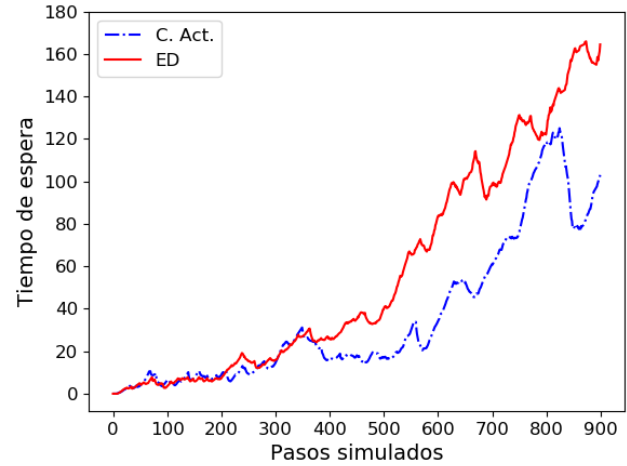


Fig. 9. Tiempo de espera promedio durante la simulación para Montevideo.




Fig. 8. Velocidad media durante la simulación para Montevideo.

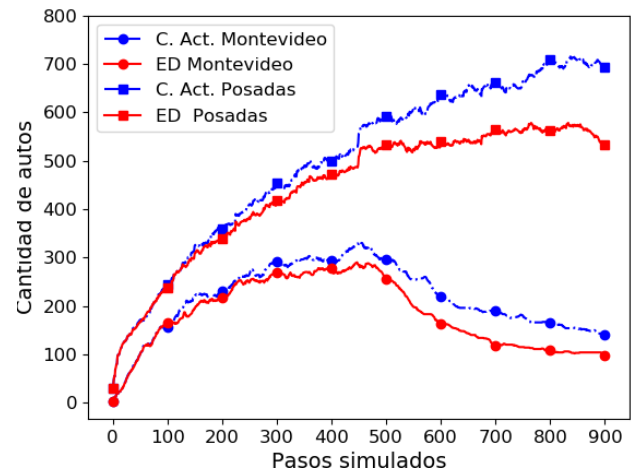


Fig. 10. Vehículos circulando durante la simulación.

constantemente provocando esta variación de  $\text{CO}_2$ .

Para los  $\text{NO}_x$  (Fig. 11c) y las  $\text{PM}_x$  (Fig. 11d), ED logra mantener, durante toda la simulación, emisiones bajas y sin picos comparado con las emisiones producidas por la configuración actual. El combustible consumido (Fig. 11e) utilizando la configuración del algoritmo ED muestra una curva casi plana, con pocos picos y que se mantiene durante toda la simulación, en contraposición con el combustible consumido utilizando la configuración actual. Esta última, presenta diferencias de hasta 1.2 ml/s de combustible gastado para las maniobras dentro de la ciudad lo que muestra el grado de congestión del escenario. ED alcanza una reducción del consumo de hasta 1.1 ml/s (casi 4 litros por hora) con respecto a la configuración actual.

Por último, los HC son, de todos los contaminantes, los que muestran diferencias más significativas entre la programación obtenida por la ED y la configuración actual. Como es de suponer la combustión y liberación de los hidrocarburos se produce en los momentos de aceleración y desaceleración de los vehículos frente a situaciones de congestión. Aquí nuevamente ED tiene picos más pequeños y el rango de valores es más estrecho que si se compara con lo simulado con la configuración actual. En conclusión, la ED claramente

favorece la fluidez del tráfico y reduce sustancialmente las emisiones instantáneas de los contaminantes mientras mantiene, en valores bajos, el combustible consumido por los vehículos.

## VII. CONCLUSIONES

En este trabajo, se propone un modelo de optimización y la aplicación de diversas estrategias algorítmicas para la generación de programas de ciclos de semáforos con el objetivo de mejorar la fluidez del tráfico vehicular. Como caso de estudio hemos utilizado dos instancias reales, con información precisa del tráfico, el microcentro de la ciudad de Posadas en Argentina y el barrio Jacinto Vera en Montevideo, Uruguay.

Para la instancia de Posadas, de las estrategias testeadas el algoritmo de evolución diferencial fue el que obtuvo mejores resultados, alcanzando reducciones del 30% en tiempo de espera de los vehículos y hasta un incremento del 4% en la velocidad promedio de los vehículos. En lo que respecta a factores de contaminación, el algoritmo ED consigue emisiones bajas y estables sin picos de contaminación en comparación con lo obtenido con la configuración actual. Asimismo, el algoritmo ED consigue una reducción significativa en el combustible consumido aún cuando la velocidad de los vehículos

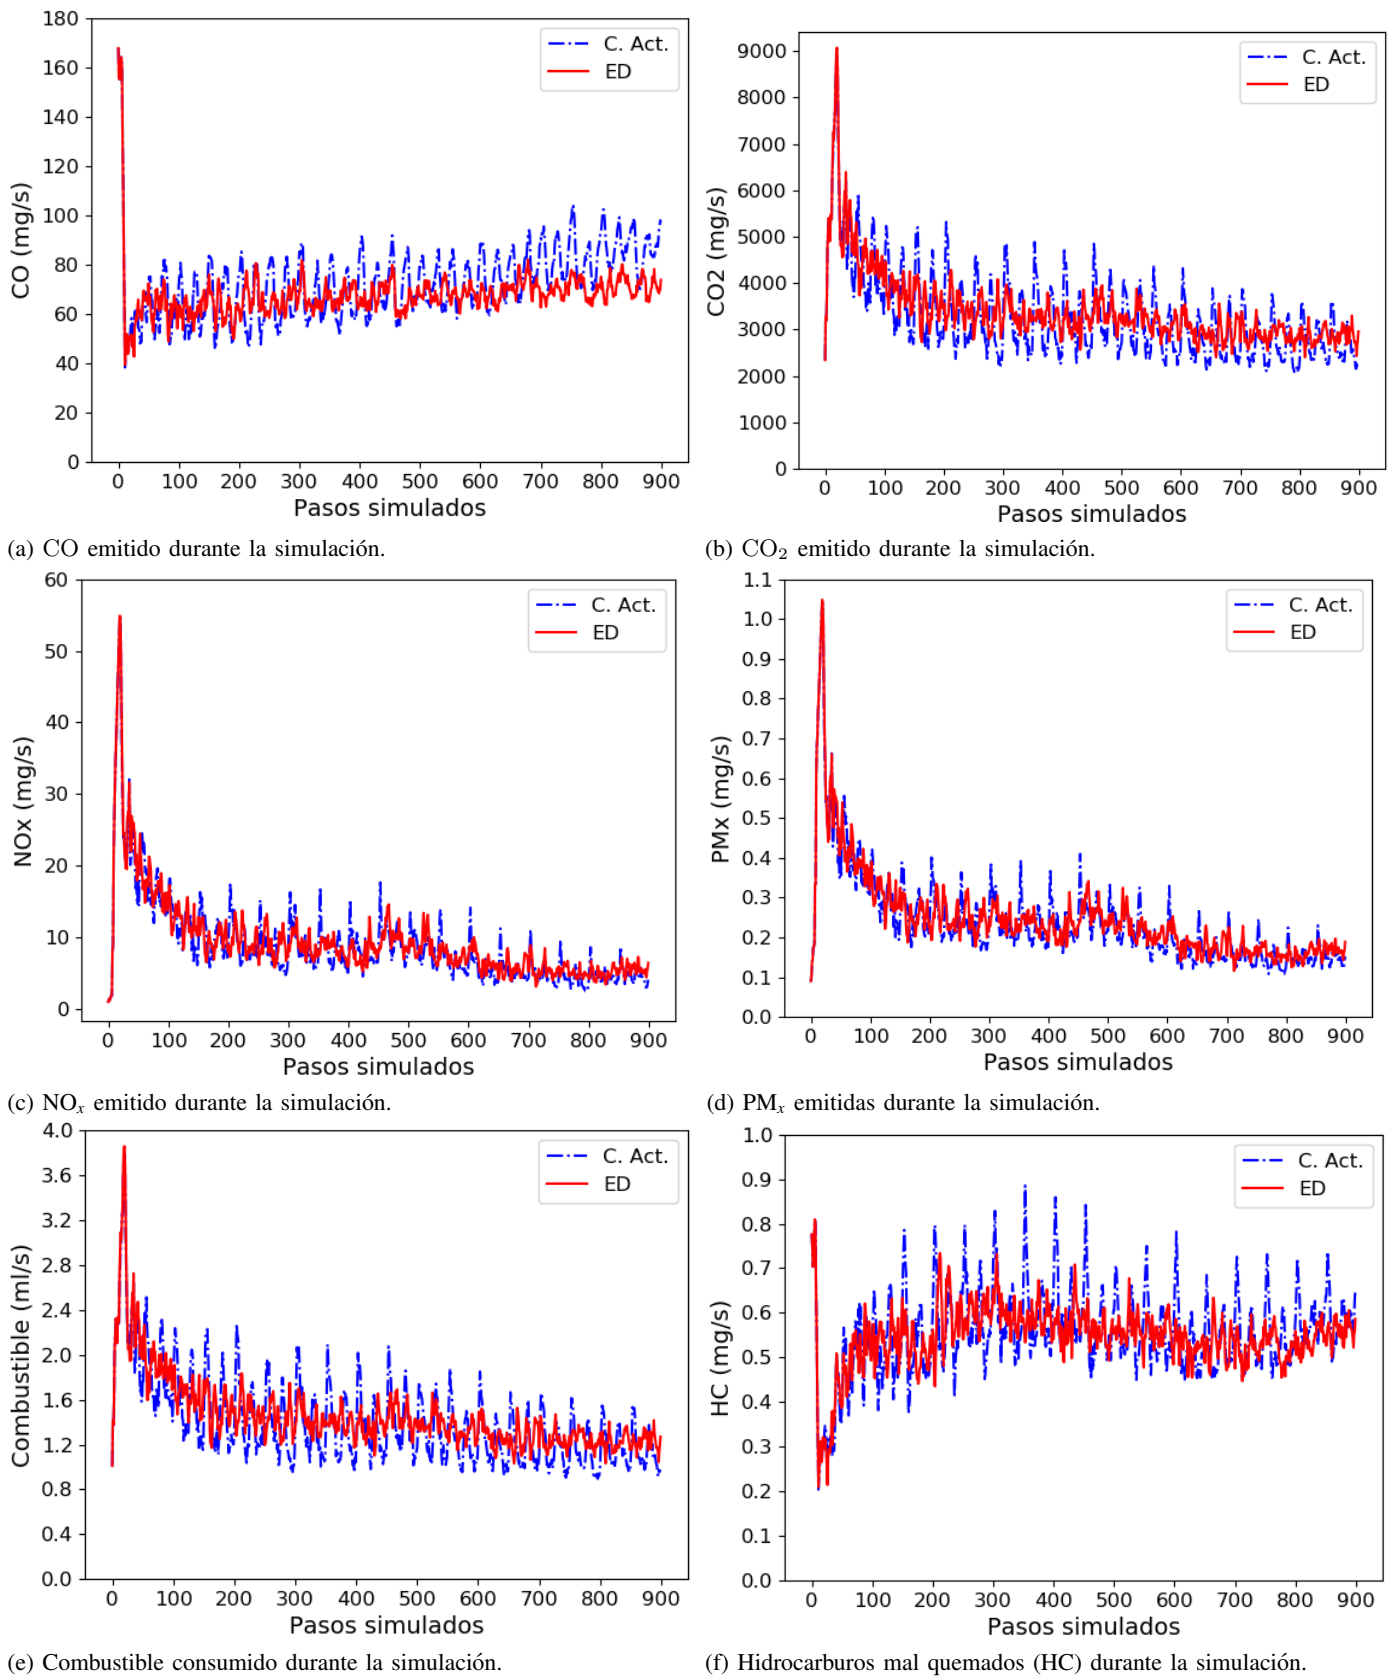


Fig. 11. Emisiones contaminantes y combustible consumido utilizando una solución del ED vs. la configuración actual para Posadas.

se incrementó. Esto demuestra que ED consigue mejorar la fluidez de los vehículos sin impactar en su consumo.

Similarmente, para la instancia de Montevideo, los resultados de evolución diferencial permiten concluir que los



vehículos fluyen a mayor velocidad lo que provoca el ingreso y salida de los vehículos en menor tiempo con respecto a utilizar la configuración actual de los semáforos.

Como trabajo futuro, pretendemos extender el estudio a instancias de mayor escala (cubriendo espacio de ciudades más grandes) y analizando no solo el tráfico de vehículos en las calles sino también el de las bicicletas en las ciclovías y peatonos en las intersecciones.

## AGRADECIMIENTOS

Los fondos para realizar esta investigación provienen del Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET, Argentina). Los autores agradecen a la Facultad de Ingeniería de la Universidad Nacional de Cuyo (Argentina).


## REFERENCIAS

- [1] C. M. Affonso and R. V. da Silva, "Demand side management of a residential system using Simulated Annealing," *IEEE Latin America Transactions*, vol. 13, no. 5, pp. 1355–1360, May 2015.
- [2] A. Mariano de Souza and L. Aparecido Villas, "A new solution based on inter-vehicle communication to reduce traffic jam in highway environment," *IEEE Latin America Transactions*, vol. 13, no. 3, pp. 721–726, March 2015.
- [3] J. A. Sanchez, D. Melendi, X. G. Paneda, and R. Garcia, "Towards smart mobility in urban areas using vehicular communications and smartphones," *IEEE Latin America Transactions*, vol. 16, no. 5, pp. 1380–1387, May 2018.
- [4] A. C. Olivera, J. M. García-Nieto, and E. Alba, "Reducing vehicle emissions and fuel consumption in the city by using particle swarm optimization," *Applied Intelligence*, vol. 42, no. 3, pp. 389–405, 2015.
- [5] M. Péres, G. Ruiz, S. Nesmachnow, and A. C. Olivera, "Multiobjective evolutionary optimization of traffic flow and pollution in Montevideo, Uruguay," *Applied Soft Computing*, vol. 70, pp. 472–485, Sep. 2018.
- [6] L.-D. Chou, T.-Y. Shen, C.-W. Tseng, Y.-J. Chang, and Y.-W. Kuo, "Green wave-based virtual traffic light management scheme with vanets," *International Journal of Ad Hoc and Ubiquitous Computing*, vol. 24, no. 1-2, pp. 22–32, 2017.
- [7] N. Damay, "Multiple-objective optimization of traffic lights using a genetic algorithm and a microscopic traffic simulator," Master's thesis, KTH, School of Computer Science and Communication, 2015.
- [8] A. Jovanović, M. Nikolić, and D. Teodorović, "Area-wide urban traffic control: A bee colony optimization approach," *Transportation Research Part C: Emerging Technologies*, vol. 77, 2017.
- [9] P. T. M. Nguyen, B. N. Passow, and Y. Yang, "Improving anytime behavior for traffic signal control optimization based on nsga-ii and local search," in *Neural Networks (IJCNN), 2016 International Joint Conference on*. IEEE, 2016, pp. 4611–4618.
- [10] D. McKenney and T. White, "Distributed and adaptive traffic signal control within a realistic traffic simulation," *Engineering Applications of Artificial Intelligence*, vol. 26, no. 1, pp. 574–583, 2013.
- [11] M. Behrisch, L. Bieker, J. Erdmann, and D. Krajzewicz, "Sumo—simulation of urban mobility: an overview," in *Proceedings of SIMUL 2011, The Third International Conference on Advances in System Simulation*. ThinkMind, 2011.
- [12] Y. Ji, B. Hu, G. Hill, W. Guo, P. Blythe, and L. Gao, "Signal coordination scheme based on traffic emission," *IET Intelligent Transport Systems*, vol. 10, no. 2, pp. 89–96, 2016.
- [13] Z. Cao, S. Jiang, J. Zhang, and H. Guo, "A unified framework for vehicle rerouting and traffic light control to reduce traffic congestion," *IEEE Trans. Intell. Transp. Syst.*, vol. 18, no. 7, pp. 1958–1973, 2017.
- [14] S. S. Leal, P. E. M. de Almeida, and E. Chung, "Active control for traffic lights in regions and corridors: an approach based on evolutionary computation," *Transp. Res. Proc.*, vol. 25, pp. 1774–1785, 2017.
- [15] P. S. Pegels, S. Pegels, and A. C. Olivera, "Metaheurísticas aplicadas a la optimización del tráfico vehicular en el microcentro de posadas," in *IEEE ARGENCON 2018 Congreso Bienal de IEEE Argentina*, 2018.

- [16] P. A. Lopez, M. Behrisch, L. Bieker-Walz, J. Erdmann, Y.-P. Flötteröd, R. Hilbrich, L. Lücken, J. Rummel, P. Wagner, and E. Wießner, "Microscopic traffic simulation using SUMO," in *The 21st IEEE International Conference on Intelligent Transportation Systems*. IEEE, November 2018. [Online]. Available: <https://elib.dlr.de/126857/>
- [17] D. K. de Sa Vieira and M. H. S. Mendes, "A comparison of algorithms for solving multicomponent optimization problems," *IEEE Latin America Transactions*, vol. 15, no. 8, pp. 1474–1479, 2017.
- [18] P. J. Vidal and A. C. Olivera, "Solving the DNA fragment assembly problem with a parallel discrete firefly algorithm implemented on GPU," *ComSIS*, vol. 15, no. 2, pp. 273–293, 2018.
- [19] J. H. Holland, "Genetic algorithms," *Scientific American*, Jul. 1992.
- [20] R. Storn and K. Price, "Differential evolution – a simple and efficient heuristic for global optimization over continuous spaces," *Journal of Global Optimization*, vol. 11, no. 4, pp. 341–359, 1997.
- [21] J. A. Malagoli, J. R. Camacho, M. V. F. da Luz, J. H. I. Ferreira, and A. M. Sobrinho, "Design of three-phase induction machine using Differential Evolution Algorithm," *IEEE Latin America Transactions*, vol. 13, no. 7, pp. 2202–2208, July 2015.
- [22] S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi, "Optimization by simulated annealing," *Science*, vol. 220 4598, pp. 671–680, 1983.
- [23] J. Kennedy and R. Eberhart, *Swarm intelligence*. San Francisco: Morgan Kaufmann Publishers, 2001.
- [24] C. Lagos, G. Guerrero, E. Cabrera, A. Moltedo-Perfetti, F. Johnson, and F. Paredes, "An improved particle swarm optimization algorithm for the vrp with simultaneous pickup and delivery and time windows," *IEEE Latin America Transactions*, vol. 16, no. 6, pp. 1732–1740, June 2018.
- [25] D. Karaboga and B. Basturk, "Artificial Bee Colony (ABC) optimization algorithm for solving constrained optimization problems," in *International Fuzzy Systems Association World Congress on Foundations of Fuzzy Logic and Soft Computing*. Springer, 2007, pp. 789–798.
- [26] T. R. Board, Ed., *HCM 2010 : Highway Capacity Manual*, fifth edition ed., Washington, D.C., 2010.
- [27] M. Haklay and P. Weber, "Openstreetmap: User-generated street maps," *IEEE Pervasive Computing*, vol. 7, no. 4, pp. 12–18, Oct 2008.
- [28] T. Bartz-Beielstein and M. Preuss, "Experimental research in evolutionary computation," in *9th annual conference companion on Genetic and evolutionary computation*. ACM, 2007, pp. 3001–3020.
- [29] J. N. Hooker, "Testing heuristics: We have it all wrong," *Journal of heuristics*, vol. 1, no. 1, pp. 33–42, 1995.
- [30] S. Nesmachnow and S. Iturriaga, "Cluster-UY: scientific HPC in Uruguay," in *International Supercomputing in Mexico*, 2019, pp. 1–15.



**Pablo Javier Vidal** received his degree of Dr. in Software Engineering and Artificial Intelligence, in 2106, from Universidad de Málaga, Spain. He is currently an adjunct professor at the Universidad Nacional de Cuyo, Argentine. Currently is an Assistant Researcher at National Council of Scientific and Technological Researches from the Ministerio de Ciencia y Tecnología de la Nación, Argentine. He has experience in software engineering with emphasis on automation and graphic processing units research. His main research topics are: parallel and distributed computing, evolutionary algorithms and metaheuristics and numerical modeling. ORCID: 0000-0001-6502-8010



**Ana Carolina Olivera** is an Adjunct Researcher at National Council of Scientific and Technological Researches from the Ministerio de Ciencia y Tecnología de la Nación, Argentine. Dr. in Computer Science from Universidad Nacional del Sur. She is an Associate Professor at the Facultad de Ingeniería from Universidad Nacional de Cuyo. She directs in several national and international projects. Her research focuses on bio-inspired algorithms, optimization and smart mobility. She has published several book chapters, articles in indexed journals and proceedings of refereed international conferences. ORCID: 0000-0001-7825-1959