



Universidad
de Alcalá

Programa de Doctorado en Tecnologías de la
Información y las Comunicaciones

**ESTRATEGIAS MULTI-MAPA PARA EL
ENRUTAMIENTO DINÁMICO DE TRÁFICO
URBANO**

Tesis Doctoral presentada por

ÁLVARO PARICIO GARCÍA

Director:

DR. MIGUEL ÁNGEL LÓPEZ CARMONA

Alcalá de Henares, 2021

D. Álvaro Paricio García ha realizado en el Departamento de Automática y bajo la dirección del Dr. D. Miguel Ángel López Carmona, la tesis doctoral titulada “Estrategias Multi-Mapa para el Enrutamiento Dinámico de Tráfico Urbano” en la modalidad de compendio de artículos, cumpliéndose todos los requisitos para la tramitación que conduce a su posterior lectura.

Alcalá de Henares, 25 de julio de 2021.

Coordinador del Programa de Doctorado

Fdo.: Dr. D. Sancho Salcedo Sanz

Labor omnia vincit
Virgilio

A mi querida Olga.
A mis hijas, Sofía, Inés y Elena.
A mis padres, Alvaro y Luisa.

Resumen

El estudio de la congestión de tráfico en redes urbanas ha sido objeto de investigación exhaustiva, tanto en su modelado matemático, como en la generación de propuestas y mecanismos de gestión, que se traducen en la implementación de sistemas inteligentes de gestión de tráfico (*Intelligent Transportation Systems*, ITS). Se estima que la reducción de congestión y las emisiones de gases y ruido asociadas podría conllevar el ahorro global de 277 billones de dólares [4]. En la misma línea, la Directiva «*Clean Transport, Urban Transport*» de la Unión Europea [127] identifica que la congestión en áreas urbanas tiene un coste anual acumulado de 100 billones de euros. El 60% de la población europea se ubica en áreas urbanas de más de 10,000 habitantes. De igual manera, se estima que la movilidad urbana es causante del 40% de emisiones de CO₂ y hasta el 70% de otros contaminantes.

Una de las cuestiones fundamentales a la hora de mitigar la congestión de tráfico urbano, es el diseño y la entrega de rutas óptimas a los conductores por parte de los ITS que minimicen su tiempo de viaje: es el denominado problema de asignación de tráfico (*Traffic Assignment Problem*, TAP). Éste es un problema bien caracterizado matemáticamente, complejo, no derivable y convexo [100], en el que la decisión de cada conductor en cada momento, modifica las condiciones de trabajo de la red, y afecta a las decisiones del resto de conductores, quienes a su vez, modifican las condiciones del sistema realimentando el bucle. Por este motivo, la resolución del TAP ha sido habitualmente aproximada mediante métodos heurísticos.

El cálculo y entrega de rutas óptimas desde los ITS se ve afectado por otros factores como son: la coincidencia de recomendaciones a vehículos con rutas similares, el uso simultáneo por parte de los conductores de varios ITS no integrados (TomTom, GoogleMaps, Waze, etc), y la variabilidad de los niveles de uso y aceptación (adherencia) por parte de los conductores. Son ellos quienes, a la postre, toman la última decisión sobre la ruta a seguir.

Asimismo, los nuevos modelos de SmartCities y de usos de movilidad urbana requieren ITS que ofrezcan rutas óptimas basados en modelos que tengan en consideración parámetros adicionales al mero tiempo de viaje. Así, se deberán tener en cuenta las necesidades y usos de los conductores, las características específicas de las flotas, los modelos de propiedad o de uso, las especificidades de los vehículos, los momentos del día o de la semana, la aparición de posibles eventos planificados o incidentales en el área urbana, e incluso otras posibles restricciones de la red viaria.

Esta tesis aborda el problema de cómo mitigar los escenarios de congestión en las redes de tráfico urbano teniendo en cuenta estos y otros factores, empleando un nuevo mecanismo original, basada en la entrega de mapas diferenciados de la red a los vehículos, denominada **TWM Traffic Weighted Multi-Maps**.

TWM entrega diferentes vistas (mapas) de la red viaria a los vehículos y a los ITS, provocando así la diversificación de caminos de sus usuarios, adaptando dichas vistas a los factores mencionados y optimizando el uso de la red para minimizar la congestión. La entrega de múltiples mapas de red permite el enrutamiento diferencial de los vehículos en la red, *coloreando el tráfico según el mapa empleado*. Los mapas actuales asimilan la vista física estructural de la red (nodos, enlaces, distancias, interconexiones, etc) a su vista lógica de uso (pesos basados en velocidades y restricciones): TWM permite desacoplar ambas perspectivas, habilitando diferentes vistas lógicas (mapas de pesos) sobre la misma infraestructura viaria.

La tesis está organizada como compendio de publicaciones de impacto [98, 99, 97, 2], donde cada una de ellas aborda diversos aspectos de la estrategia de enrutamiento de tráfico mediante múltiples mapas. La primera contribución de la tesis comprende el modelo y formulación de *Traffic Weighted Multi-Maps* y su aplicación a diversos casos de uso, combinando técnicas de asignación dinámica de tráfico con mapas aleatorizados bajo diversos criterios. Entre otros casos de uso se recogen: a) la reducción global de la congestión estructural mediante diversificación de caminos, b) la reducción de la congestión en escenarios de incidentes, c) el enrutamiento diferencial de flotas, y d) la generación de corredores de tráfico aligerados. En función de la complejidad de la red, el volumen de la demanda y el estado de la red, TWM permite obtener niveles de mejora de la congestión entre el 20 % y el 50 %.

La segunda contribución de la tesis se centra en los mecanismos de obtención de distribuciones óptimas de mapas TWM. El objetivo principal de mejora que se ha considerado es la minimización del nivel de congestión global en la red de tráfico, seleccionando como su indicador principal el tiempo total de tránsito de los vehículos

en la red. Los algoritmos empleados, no obstante, permiten la inclusión de cualquier otro criterio adicional.

La obtención del conjunto de mapas óptimos para una cierta demanda de tráfico en una red urbana, requiere la resolución del problema clásico de asignación de tráfico en la red (TAP). Debido a la complejidad de su resolución, se ha optado por aplicar la técnica heurística de algoritmos evolutivos, definiendo un modelo que incluye la propia red y su topología, las demandas de tráfico previstas, y el estado de la red. La implementación del modelo incluye un número muy elevado de variables a considerar, por lo que se presentan algunas variantes algorítmicas que nos permiten simplificar los espacios de búsqueda de soluciones, manteniendo un nivel de precisión razonable. La calidad de las soluciones encontradas es contrastada con otros algoritmos de cálculo aproximado del TAP, ofreciendo soluciones muy próximas al óptimo del sistema (*System Optimum*, SO). La diferencia fundamental en este caso es que TWM ofrece una solución basada en una estrategia de aplicación real, frente al resto de soluciones que implementan modelos matemáticos teóricos de cálculo del SO.

La eficacia de cualquier modelo de optimización de tráfico depende del nivel de adherencia por al mismo por parte de los vehículos, y evoluciona en el tiempo en función de la utilidad recibida y percibida por los vehículos. Algunos trabajos previos [11, 108] apuntan al efecto de aparición de «rutas injustas» (*route unfairness*, RU) en los modelos de tráfico orientados al óptimo del sistema, que describe cómo en estos modelos algunos vehículos reciben peores rutas en beneficio del resto. Este efecto debe tener impacto en la confianza de los conductores hacia los sistemas de recomendación de rutas, convirtiéndoles en promotores o detractores según reciban mejores o peores rutas.

En ese sentido, la tercera contribución fundamental de la tesis está centrada en el análisis de la dinámica en la adherencia de los conductores a TWM, proponiendo un modelo de análisis de comportamiento de los vehículos en base a criterios de utilidad. El modelo es generalizado, además, al caso de coexistencia de múltiples ITS en la red de tráfico entre los que se encuentra TWM, y la consideración de las utilidades de cada vehículo para la toma de su decisión.

La propuesta emplea una combinación de lógica difusa y modelos de elección discreta multinomiales que permiten modelar de forma genérica el comportamiento de los conductores. Los experimentos realizados muestran no sólo las mejoras obtenidas

por el uso de TWM, sino la rápida convergencia de la adherencia al modelo por parte de los conductores, considerando las diferentes utilidades.

La parte experimental de la tesis emplea simulaciones de tráfico microscópicas (SUMO [16]) y macroscópicas (MatLab y python) sobre redes sintéticas de tráfico para la validación de los modelos teóricos, y sobre redes reales de tráfico urbano para contrastar los resultados. Todos los modelos son originales y desarrollados para la tesis. Los experimentos avalan las hipótesis y expectativas expuestas en cada contribución. En el caso concreto de la red urbana de Alcalá de Henares, se han empleado medidas de la demanda de tráfico realizadas por sistemas reales de tráfico *crowd-sensing* donadas con fines de investigación.

Los buenos resultados obtenidos confirman los objetivos e hipótesis planteados inicialmente en la tesis. TWM (*Traffic Weighted Multi-Maps*) aparece como una técnica novedosa, viable, y fácilmente implementable en los sistemas actuales de tráfico, por lo que se espera que aparezcan nuevas contribuciones a la misma en el corto plazo, e implementaciones reales en ITS comerciales.

Palabras clave: sistemas inteligentes de transporte, congestión del tráfico, gestión del tráfico multi-mapa, asignación de tráfico, algoritmos genéticos, lógica difusa, modelos de elección discreta, modelos de comportamiento.

Abstract

The study of traffic congestion in urban networks has been the subject of exhaustive research, both in its mathematical modeling and in the generation of proposals and management mechanisms, resulting in the implementation of Intelligent Transportation Systems (ITS). It is estimated that the reduction of congestion and associated gas and noise emissions could lead to global savings of 277 billion dollars[4]. In the same vein, the European Union's Clean Transport, Urban Transport Directive [127] identifies that congestion in urban areas has a cumulative annual cost of €100 trillion. 60 % of the European population is located in urban areas with more than 10,000 inhabitants. Similarly, it is estimated that urban mobility is responsible for 40 % of CO₂ emissions and up to 70 % of other pollutants.

One of the key issues in mitigating urban traffic congestion is the design and delivery of optimal routes to drivers by ITS that minimize their travel time: it is the so-called Traffic Assignment Problem (TAP). TAP is a well-characterized, mathematically complex, non-derivable and convex problem[100], in which the decision of each driver at each moment, modifies the working conditions of the network, and affects the decisions of the rest of the drivers, who in turn, modify the system conditions by feeding back the loop. For this reason, the resolution of the TAP has usually been approximated by heuristic methods.

The calculation and delivery of optimal routes from ITS is affected by other factors such as: the coincidence of recommendations to vehicles with similar routes, the simultaneous use of several non-integrated ITS by drivers (TomTom, GoogleMaps, Waze, etc), and the levels of use and acceptance (adherence) by drivers who, in the end, make the final decision on the route to follow.

Likewise, the new models of SmartCities and urban mobility uses require ITS that offer optimal routes based on models that take into consideration parameters other than mere travel time. Thus, drivers' needs and uses, specific fleet characteristics,

ownership or usage patterns, vehicle properties, times of the day or week, the occurrence of possible planned or incidental events in the urban area, and even other possible road network constraints should be taken into account.

This thesis addresses the problem of how to mitigate congestion scenarios in urban traffic networks considering these and other factors, employing a new original mechanism, based on the delivery of differentiated network maps to vehicles, called **TWM Traffic Weighted Multi-Maps**.

TWM delivers different views (maps) of the road network to vehicles and ITS, thus causing the diversification of paths of its users, adapting these views to the aforementioned factors and optimizing the use of the network to minimize congestion. The delivery of multiple network maps enables differential routing of vehicles on the network, *coloring traffic according to the map used*. Current maps assimilate the physical structural view of the network (nodes, links, distances, interconnections, etc) to its logical usage view (weights based on speeds and constraints): TWM allows decoupling both perspectives, enabling several logical views (weight maps) on the same road infrastructure.

The thesis is organized as a compendium of impact publications [98, 99, 97, 2], each of them addressing different aspects of the traffic routing strategy using multiple maps. The first contribution of the thesis comprises the model and formulation of Traffic Weighted Multi-Maps and its application to various use cases combining dynamic traffic assignment techniques with randomized maps under various criteria. Other use cases include global structural congestion reduction through path diversification, congestion reduction in incident scenarios, differential routing of fleets, and the generation of lightened traffic corridors. Depending on the complexity of the network, the volume of demand and the state of the network, TWM allows obtaining congestion improvement levels between 20 % and 50 %.

The second contribution of the thesis focuses on the mechanisms for obtaining optimal distributions of TWM maps. The main improvement objective considered is the minimization of the global congestion level in the traffic network, selecting as its main indicator the total transit time of vehicles in the network. The algorithms used, however, allow the inclusion of any other additional criteria. Obtaining the set of optimal maps for a certain traffic demand in an urban network requires solving the classical network traffic assignment problem (TAP). Due to the complexity of its resolution, we have chosen to apply the heuristic technique of evolutionary algorithms, defining a model that includes the network itself and its topology, the

expected traffic demands, and the state of the network. The model includes a very large number of variables to be considered, so we present some algorithmic variants that allow us to simplify the solution search spaces, while maintaining a reasonable level of accuracy. The quality of the solutions found is contrasted with other TAP approximate calculation algorithms, offering solutions very close to the optimum of the system (System Optimum, SO). The fundamental difference in this case is that TWM offers a solution with real application, as opposed to the rest of the solutions that implement mathematical calculation models.

The effectiveness of any traffic optimization model depends on the level of adherence to it by the vehicles, and evolves over time as a function of the utility received and perceived by the vehicles. Some previous work [11, 108] points to the effect of "route unfairness" (route unfairness, RU) in system-optimal oriented traffic models, which describes how in these models some vehicles receive worse routes to the benefit of the rest. This effect has an impact on drivers' trust towards route recommendation systems, turning them into promoters or detractors depending on whether they receive better or worse routes. In this sense, the third fundamental contribution of the thesis is focused on the analysis of the dynamics of drivers' adherence to TWM, proposing a model for the analysis of vehicle behavior based on utility criteria. The model is further generalized to the case of coexistence of multiple ITS in the traffic network including TWM, and the consideration of their utilities for each vehicle for decision making. The proposal employs a combination of fuzzy logic and multinomial discrete choice models that allow generic modeling of driver behavior. The experiments conducted show not only the improvements obtained by the use of TWM, but also the rapid convergence of the drivers' adherence to the model, considering the different utilities.

The experimental part of the thesis employs microscopic (SUMO [16]) and macroscopic (MatLab and python) traffic simulations on synthetic traffic networks for the validation of the theoretical models, and on real urban traffic networks to contrast the results. All models are original and developed for the thesis. The experiments support the hypotheses and expectations stated in each contribution. In the specific case of the Alcalá de Henares network, traffic measurements made by real crowd-sensing traffic systems donated for research purposes have been used.

The good results obtained confirm the objectives and hypotheses initially stated in the thesis. TWM (Traffic Weighted Multi-Maps) appears as a novel, feasible, and easily implementable technique in current traffic systems, so it is expected that

new contributions to it will appear in the short term, and real implementations in commercial ITS.

Keywords: intelligent transportation systems, traffic congestion, multi-map traffic management, traffic assignment, genetic algorithms, fuzzy logic, discrete choice models, behavioral models.

Agradecimientos

El camino recorrido para conseguir culminar esta tesis ha sido largo, y venía precedido por un par de intentos previos cuyos inicios se remontan a los inicios de mi vida profesional. Esta tesis ha sido todo un reto personal, obtenido durante un intenso periodo de madurez profesional. Conseguir un buen equilibrio en todos los aspectos de la vida: investigador, docente, profesional, familiar y personal sólo ha sido posible gracias al apoyo de todas las personas que me rodean.

Quiero comenzar agradeciendo a mi director y tutor de tesis Dr. Miguel Ángel López Carmona la confianza depositada en mi desde un principio, y el enorme esfuerzo y trabajo invertido en estos años de preparación y desarrollo. El trabajo codo con codo con Miguel Ángel no sólo ha desembocado en la presente tesis, sino en una buena amistad, lo cual es aún más valioso.

Es de recibo, además, agradecer al Dr. Juan Ramón Velasco su apoyo desde hace ya muchos años para mi integración en la vida universitaria como investigador y profesor. Una andadura que se inició hace más de 30 años, y que culmina finalmente en esta tesis. Asimismo, quiero agradecer a mis compañeros del Área de Automática su inestimable colaboración y ayuda en estos años de docencia.

El tiempo es el recurso más escaso y perecedero del hombre, por ello, quisiera agradecer también a Luis de la Cruz su inestimable ayuda para acelerar la generación esta tesis, devolviéndome mucho de ese preciado tiempo. Quisiera igualmente agradecer a Valentín Alberti, su trabajo preliminar de simulación de tráfico que abrió la reflexión a alguna de las ideas recogidas en esta tesis.

El orden de los agradecimientos, en este caso, no refleja su importancia, ya que sin el incondicional apoyo de mi familia este trabajo habría sido imposible, especialmente por parte de Olga, mi compañera de vida. Ha sido un apoyo activo, de muchas

conversaciones y paseos de puesta en común, así como de mucha paciencia ante la cantidad de tiempo invertido en la tesis.

Quiero agradecer a mis padres el ejemplo que me han dado en esta vida, con especial cariño a mi padre, que seguro estaría orgulloso de ver el fruto de esta tesis.

Índice general

Índice de figuras	XXVI
Índice de tablas	XXIX
I. Motivación de la investigación y resumen amplio de la Tesis	1
1. Introducción	3
1.1. Planificación del transporte, asignación de tráfico y mecanismos de enrutamiento	3
1.1.1. Principios de asignación de tráfico	6
1.1.2. Selección de la ruta óptima	8
1.1.3. Funciones de coste de los enlaces	9
1.1.4. Métodos de asignación estática de tráfico	11
1.1.4.1. Asignación de Tráfico AON	11
1.1.4.2. Aproximación a la Asignación Óptima del Tráfico UE por acumulación de tráfico (CUM)	12
1.1.4.3. Aproximación a la Asignación Óptima del Tráfico UE mediante medias sucesivas (MSE)	12
1.1.4.4. Aproximación a la Asignación Óptima del Tráfico UE mediante aproximación por programación lineal (WEI-LP)	13
1.1.5. Enrutamiento dinámico del tráfico	13
1.1.6. Sistemas inteligentes de transporte	15
1.1.7. La congestión de tráfico en ámbitos urbanos	18
1.2. Planteamiento del problema	20
1.2.1. Enrutamiento mediante multi-mapas de tráfico	22
1.3. Objetivos y ámbito de las contribuciones	24
1.3.1. Modelado, generación y distribución de TWM	24
1.3.2. Asignación dinámica de tráfico por diversificación de caminos mediante TWM aleatorizados	25
1.3.3. Simulación microscópica de escenarios de uso de TWM	26

1.3.4.	Asignación estática de tráfico mediante TWM optimizados: caracterización del óptimo del sistema	27
1.3.4.1.	Asignación estática de tráfico mediante TWM	28
1.3.4.2.	Algoritmos de generación de conjuntos de mapas TWM óptimos.	28
1.3.5.	Modelado de la experiencia de usuario en entornos complejos de múltiples ITS.	28
1.3.6.	Dinámica de la adopción de TWM en sistemas complejos.	29
1.4.	Estructura de la tesis	30
2.	Resumen amplio: Algoritmos Multi-Mapa de Enrutamiento Dinámico de Tráfico Vehicular	35
2.1.	Caracterización de la congestión de tráfico	37
2.1.1.	La congestión y los tiempos de viaje	39
2.2.	Enrutamiento del tráfico urbano mediante multi-mapas TWM	43
2.2.1.	Asignación de tráfico mediante multi-mapas TWM	45
2.2.2.	Casos de uso de TWM	49
2.2.3.	Indicadores de medición de efectividad del ITS (TWM)	50
2.3.	Asignación dinámica de tráfico mediante TWM aleatorizados	53
2.3.1.	Impacto de la adherencia al uso de TWM	58
2.4.	Aplicación de TWM a gestión de incidentes en la red de tráfico	59
2.5.	Diseño de multi-mapas TWM óptimos	65
2.5.1.	Algoritmo de optimización B-TWM	68
2.5.2.	Algoritmo de optimización FP-TWM	69
2.5.3.	Algoritmo de optimización EFP-TWM	70
2.5.4.	Complejidad y rendimiento de los algoritmos	71
2.6.	Asignación estática de tráfico mediante multi-mapas óptimos	74
2.6.1.	Efecto de la adherencia de los conductores	77
2.6.2.	Efecto de las rutas injustas (<i>route unfairness</i>)	78
2.7.	Modelado de la experiencia de usuario en entornos multi-ITS	79
2.7.1.	Modelo de utilidad	82
2.7.2.	Variables de entrada del modelo de experiencia de usuario	82
2.7.3.	Reglas de utilidad	84
2.7.4.	La elección del enrutamiento a seguir	85
2.7.5.	Modelo de resistencia al cambio	86
2.8.	Simulación de la dinámica de adopción de TWM	88
2.8.1.	Evolución de la adherencia	91
2.9.	Simuladores de tráfico para TWM	93

II. Artículos publicados que dan lugar a la tesis	95
3. Urban Traffic Routing Using Weighted Multi-Map Strategies	97
3.1. Introducción	97
3.2. Relevancia de la publicación	99
3.3. Artículo	99
4. Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment	117
4.1. Introducción	117
4.2. Relevancia de la publicación	119
4.3. Artículo	119
5. Modeling Driving Experience with Smart Traffic Routing Strategies: Application to Traffic Multi-Map Routing	141
5.1. Introducción	141
5.2. Relevancia de la publicación	143
5.3. Artículo	144
6. Otras publicaciones relacionadas	161
6.1. Multimap Routing for Road Traffic Management	161
6.1.1. Introducción	161
6.1.2. Artículo	162
6.1.3. Relevancia de la publicación	175
III. Conclusiones	177
7. Discusión y conclusiones	181
7.1. Revisión de los objetivos planteados	181
7.2. Discusión y conclusiones	187
8. Difusión de las contribuciones	191
9. Líneas de investigación futuras	195
IV. Referencias	199
Glosario de Términos y Acrónimos	201
Bibliografía	206

V. Apendices	217
A. Escenarios de análisis	221
Tipología de los vehículos	222
Escenarios sintéticos	224
Escenario sintético Ortuzar-Willumsen	225
Configuración del tráfico	226
Escenario sintético Paricio-LopezCarmona	227
Configuración del tráfico	229
Escenario sintético Grid-64	230
Configuración del tráfico	231
Escenario sintético Grid-256	232
Configuración del tráfico	233
Escenario sintético Radial-241	235
Configuración del tráfico	236
Escenarios reales	237
Red urbana de Madrid-Retiro	238
Configuración del tráfico	239
Red urbana de Madrid-Las Tablas	240
Configuración del tráfico	242
Red urbana de Alcalá de Henares	243
Configuración del tráfico	246
B. Recursos y herramientas de investigación	249
Simuladores y herramientas de gestión de tráfico	249
Simuladores microscópicos	250
SUMO	250
Simuladores macroscópicos	252
Programas <i>opensource</i> de cálculo de algoritmos de asignación estática	253
Entorno de propósito general MatLab	254
C. Modelo de comportamiento <i>fuzzy</i> de los conductores en la adopción de TWM	257
D. Relación de productos y desarrollos generados durante la tesis	261
Entorno MuTraff.	261
Herramientas MatLab	268

E. Medición del tráfico en la red urbana de Alcalá de Henares mediante técnicas de crowd-sensing

271

Índice de figuras

1.1.	El modelo clásico en cuatro etapas para la planificación del transporte [94].	4
1.2.	El principio de racionalidad limitada del usuario en relación al equilibrio del tráfico [130].	7
1.3.	Funciones VDF para los modelos BPR (a, b) y cónicos (c, d) para diferentes ratios v/c [119].	10
1.4.	Tipologías de ITS según ETSI EN 302-665.	16
2.1.	Estimación de tiempos de viaje individuales y criterios de congestión.	40
2.2.	Composición básica del mapa de la red de tráfico.	43
2.3.	Multi-mapas de la red de tráfico.	45
2.4.	Inclusión de TWM en el modelo de planificación del transporte.	46
2.5.	Diagrama general de funcionamiento de MuTraff para TWM.	48
2.6.	Alcalá de Henares. Indicador de congestión NHD.	55
2.7.	Alcalá de Henares. Indicador de congestión MS.	55
2.8.	Alcalá de Henares. Indicador de congestión NHL.	55
2.9.	Alcalá de Henares. Mejora individual relativa de los tiempos de viaje empleando TWM.	57
2.10.	Alcalá de Henares. Histograma comparativo de tiempos de viaje empleando TWM.	57
2.11.	Alcalá de Henares. Distribución de probabilidad acumulada al aplicar TWM.	59
2.12.	Modelo de gestión de incidentes TWM	60
2.13.	Alcalá de Henares: incidente temporal y radio de impacto $R_x = 5$ para TWM	62
2.14.	Alcalá de Henares. Estructura TWM para gestión del incidente	62
2.15.	Alcalá de Henares. Configuración <i>mutraff_mapgen</i> para la gestión del incidente	62
2.16.	Alcalá de Henares. Congestión tras incidente. NHD.	63
2.17.	Alcalá de Henares. Gestión de incidentes. Congestión. NHD.	63
2.18.	Alcalá de Henares. Gestión de incidentes. Congestión. MS.	64

2.19.	Alcalá de Henares. Gestión de incidentes. Congestión. NHL.	64
2.20.	Alcalá de Henares. Distribución de probabilidad acumulada en la gestión del incidente con TWM.	65
2.21.	Algoritmo genético empleado en B-TWM, FP-TWM y EFP-TWM	67
2.22.	Estructura del cromosoma empleado en B-TWM	68
2.23.	Estructura del cromosoma empleado en FP-TWM	69
2.24.	Estructura del cromosoma empleado en EFP-TWM	70
2.25.	Ejemplo áreas de enrutamiento EFP-TWM	71
2.26.	Grid-64 complejidad del cromosoma para varios TWM, KSP y distancia d	72
2.27.	Grid-64 convergencia del algoritmo evolutivo para FP-4-3-0 y EFP-4-3-3	73
2.28.	Mapas óptimos B-TWM para los experimentos de Madrid-Retiro	73
2.29.	Asignación de tráfico para los experimentos de Madrid-Retiro	75
2.30.	Comparativa de TTS para los distintos métodos de asignación (Madrid-Retiro)	76
2.31.	TTS frente tamaño del cromosoma para diferentes adherencias (Grid64)	77
2.32.	Comparación de tiempos de viaje individuales entre AON y TWM-4-3-3	78
2.33.	Modelo de elección de ruta multi-ITS	80
2.34.	Distribución estricta de la probabilidad de resistencia al cambio $Y_{bin} \rightarrow 0,75 * binary(0,6)$	88
2.35.	Distribución normal de la probabilidad de resistencia al cambio $Y_{norm} \rightarrow 0,75 * norm(0,6, 0,1)$	88
2.36.	Funciones de cuantificación <i>fuzzy</i> $[U_{TWM}, \bar{U}]$	89
2.37.	Madrid Las Tablas: evolución de la adherencia a TWM para diferentes valores de p_{max} con $Y_{norm}(p_{max}, 0,5, 0,1)$	91
2.38.	Madrid Las Tablas: evolución de TTS a TWM para diferentes valores de p_{max} con $Y_{norm}(p_{max}, 0,5, 0,1)$	92
2.39.	Madrid Las Tablas: comportamiento de los individuos 3241 y 5000 . .	93
7.1.	Alcalá de Henares: probabilidad de mejora del TTS en función de la adherencia a TWM	183
7.2.	Diagrama general de funcionamiento de <i>mutraff_simulator</i>	184
7.3.	Alcalá de Henares: Comparativa absoluta y relativa de métodos de asignación estática incluyendo TWM	185
7.4.	Madrid-LasTablas: adherencia a TWM en el tiempo para diferentes niveles de resistencia al cambio	187
A.1.	Distribución porcentual de la demanda de tráfico en los experimentos	224
A.2.	Red de tráfico Ortúzar-Willumsen	226
A.3.	Flujos de tráfico en Ortúzar-Willumsen	226
A.4.	Red de tráfico Paricio-LópezCarmona	228

A.5.	Flujos de tráfico en Paricio-LópezCarmona	229
A.6.	Red de tráfico Grid-64	230
A.7.	Flujos de tráfico en Grid-64	231
A.8.	Red de tráfico Grid-256 mostrando los TAZs, en una situación de congestión.	232
A.9.	Flujos de tráfico en Grid-256	233
A.10.	Flujos de tráfico en Radial-241	235
A.11.	Red de tráfico Madrid-Retiro	239
A.12.	Red de tráfico Madrid-Las Tablas	240
A.13.	Red de tráfico Madrid-Las Tablas	241
A.14.	Red de tráfico Madrid-Las Tablas	242
A.15.	Red de tráfico de Alcalá de Henares	245
D.1.	Diagrama general de funcionamiento de <i>mutraff_simulator</i>	263
D.2.	Diagrama general de funcionamiento de <i>mutraff_simulator</i>	264
E.1.	Mecanismo de toma de datos por crowd-sensing	272
E.2.	Selección de datos <i>crowd-sensing</i> para los experimentos de Alcalá de Henares	273
E.3.	Área <i>crowd-sensing</i> para los experimentos de Alcalá de Henares	274

Índice de tablas

1.1.	Taxonomía de métodos DTA y aplicabilidad TWM [122]	14
2.1.	Diagrama esquemático de las investigaciones realizadas	36
2.2.	Referencias a los escenarios experimentales en las publicaciones de la tesis.	37
2.3.	Alcalá de Henares, impacto de TWM para distintas adherencias	58
2.4.	Análisis de complejidad y eficiencia de los algoritmos para diversas configuraciones de Grid64.	74
2.5.	Eficiencia y diversidad de rutas en los algoritmos TWM(4) and KSP(3).	76
2.6.	R_3 regla principal de adopción de TWM.	85
7.1.	Alcalá de Henares: mejora del enrutamiento usando TWM	182
A.1.	Resumen de escenarios, complejidad y tipología de simulación.	222
A.2.	Agrupaciones de vehículos usados en los escenarios	223
A.3.	Distribución simplificada de flotas	224
A.4.	Ortúzar-Willumsen: O/D Matriz	227
A.5.	Paricio-LópezCarmona: O/D Matriz	229
A.6.	Grid-64: matriz de demanda de tráfico origen/destino.	231
A.7.	Grid-256: matriz de demanda de tráfico origen/destino.	234
A.8.	Radial-241: matriz de demanda de tráfico origen/destino.	237
A.9.	Flujos de tráfico de Madrid-Retiro	240
A.10.	Flujos de tráfico de Madrid-Retiro	243
A.11.	Descripción y uso de las TAZ	247
A.12.	Alcalá de Henares. Matriz de tráfico por TAZ origen/destino.	248
B.1.	Componentes del entorno de simulación SUMO.	252
C.1.	Weight categories for the fuzzy rules.	258
C.2.	Reglas de adopción de TWM.	259
E.1.	Medidas tomadas del crowd-sensing	273

Parte I

Motivación de la investigación y resumen
amplio de la Tesis

Introducción

En este capítulo introductorio, se realiza una breve introducción al marco conceptual de aplicación para la tesis, tras el cual se expone el planteamiento del problema objeto de la tesis, y la enumeración de los objetivos planteados junto a su relación con las publicaciones presentadas durante la investigación. A continuación, se muestra el esquema completo y se desarrolla el resumen amplio de la tesis. Este resumen amplio es un requisito establecido por la normativa del Programa de Doctorado en Tecnologías de la Información y las Comunicaciones de la Universidad de Alcalá.

1.1. Planificación del transporte, asignación de tráfico y mecanismos de enrutamiento

Existe un consenso generalizado a nivel internacional para considerar la congestión del tráfico en los entornos urbanos como un problema no sólo de movilidad de los ciudadanos, sino también económico, de desarrollo, medioambiental, y de salud pública [94, 37].

Se estima que en Estados Unidos, la reducción de congestión y las emisiones de gases y ruido asociadas podría conllevar el ahorro global de 277 billones de dólares [4]. En la misma línea, la Directiva «*Clean Transport, Urban Transport*» de la Unión Europea [127] identifica que la congestión en áreas urbanas tiene un coste anual acumulado de 100 billones de euros. El 60 % de la población europea se ubica en áreas urbanas de más de 10,000 habitantes. De igual manera, se estima que la movilidad urbana es causante del 40 % de emisiones de CO₂ y hasta el 70 % de otros contaminantes.

El estudio de la congestión de tráfico en redes urbanas ha sido objeto de investigación exhaustiva, tanto en su modelado matemático, como en la generación de propuestas y mecanismos de gestión, que se traducen en la implementación de sistemas inteligentes de gestión de tráfico (*Intelligent Transportation Systems, ITS*) que permitan gestionarla [54, 127].

La planificación del transporte es una problemática históricamente estudiada desde mediados del siglo XX con numerosos modelos y propuestas [94, 37, 113]. En la gran mayoría, se asume la hipótesis de que los patrones de tráfico son medibles, estables y predecibles, donde la demanda de transporte está directamente relacionada con la distribución e intensidad de sus usos en términos geográficos [28, 107]. Teniendo en cuenta esta hipótesis, se formula el modelo clásico de planificación de las redes de transporte en cuatro etapas [94] que se muestra en la figura 1.1:

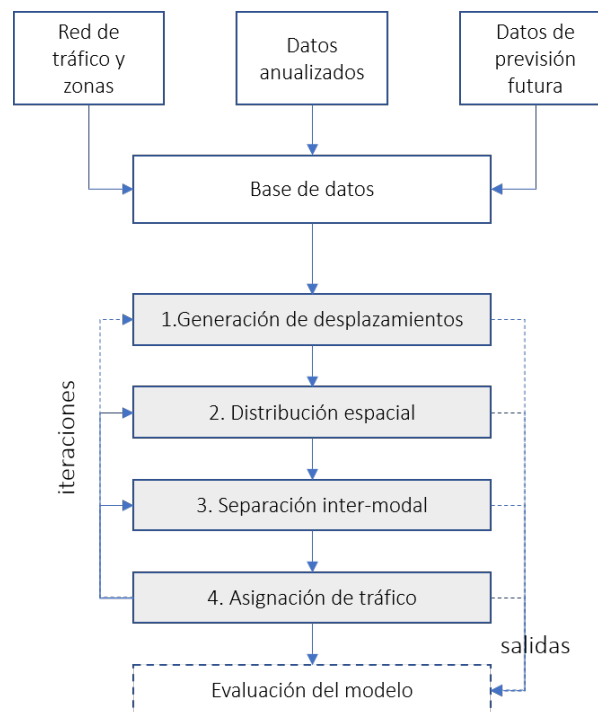


Figura 1.1.: El modelo clásico en cuatro etapas para la planificación del transporte [94].

1. **Generación de la demanda** de viajes, basado en los datos recogidos de las diferentes fuentes disponibles, y en los modelos predictivos de su evolución futura. Esta etapa produce las distribuciones de la demanda en volumen de viajes en función del uso previsto.
2. **Distribución espacial** de los trayectos generados, generando una matriz de desplazamientos entre los orígenes y los destinos. Los conceptos de origen y

destino pueden ser descritos tanto por ubicaciones espaciales concretas, como nodos de la red, como áreas de tráfico (*traffic area zones*, TAZ) que recogen conjuntos de nodos y enlaces, como centroides que agregan todos los orígenes de un zona.

3. **Separación inter-modal** de los viajes, combinando los diferentes modos de desplazamiento disponibles.
4. **Asignación de tráfico** a los diferentes medios de transporte, ya sean públicos o privados.

El concepto de asignación de tráfico se crea en los años 1940 y se desarrolla cuando comienzan a estar disponibles los primeros datos de analítica de demanda entre orígenes y destinos. La etapa de asignación de tráfico comprende el mecanismo de distribución de rutas a los vehículos que forman parte de una red de transporte [100]. Así, uno de los mecanismos básicos para aliviar la congestión consistirá en la correcta asignación del tráfico, indicando a los vehículos la ruta que deberán tomar teniendo en cuenta el origen, el destino, el estado previo de la red de tráfico, y la carga prevista en la red como consecuencia del enrutamiento de todos los vehículos.

El denominado **problema de la asignación de tráfico** (*Traffic Assignment Problem*, TAP) fue enumerado por Campbell [30] como el método de cálculo y entrega de rutas óptimas a los vehículos por parte de los ITS, de manera que se minimice el tiempo de viaje. Éste es un problema matemáticamente complejo, no derivable y convexo, caracterizado por Beckmann [15, 113], en que la decisión de cada conductor en cada momento, modifica las condiciones de trabajo de la red y afecta a las decisiones del resto de conductores quienes, a su vez, modifican las condiciones del sistema. Por este motivo, la resolución del TAP ha sido habitualmente aproximada mediante métodos heurísticos.

Así, los modelos de asignación de tráfico, tanto estáticos como dinámicos, permiten a los ITS establecer las recomendaciones de enrutamiento a los diferentes vehículos que usan la red. Los modelos estáticos asumen que la red es un conjunto de recursos que deben ser repartidos de forma óptima para su uso por parte de los vehículos, mientras que los modelos dinámicos además tienen en cuenta el factor tiempo en la gestión de los trayectos. A continuación repasamos algunos de los conceptos fundamentales:

- Principios básicos en la asignación de tráfico.
- Criterios de selección de la ruta óptima para un vehículo.
- Cálculo del coste de un enlace de tráfico.
- Situaciones de equilibrio en el tráfico de una red.
- Métodos de asignación estática y dinámica del tráfico.
- Implementación de los principios en los sistemas inteligentes de gestión del transporte.
- Caracterización de los escenarios de congestión.

1.1.1. Principios de asignación de tráfico

En 1952 Wardrop [132] formula sus dos conocidos principios de asignación de tráfico, que desde entonces forman la base de cualquier modelo de enrutamiento:

- El **Principio de Equilibrio de Usuario** (*User Equilibrium*, UE), que establece la red encontrará el equilibrio cuando ninguno de sus usuarios pueda mejorar su tiempo de viaje modificando su ruta. Así, los tiempos de viaje de todas las rutas utilizadas entre pares de igual origen-destino (OD) son iguales y mínimos, y por tanto todos los usuarios son iguales. De la misma manera, este principio asume que todos los viajeros conocen todo el estado de la red, tomando decisiones perfectas. Los viajeros podrán conocer de antemano el tiempo de viaje a usar. Considerando el concepto de utilidad, el principio de equilibrio de usuario implica que los usuarios buscan maximizar la utilidad de sus desplazamientos, no siendo posible mejorar la utilidad de ninguno de ellos en el momento en que se encuentra el equilibrio.
- El **Principio de Óptimo del Sistema** (*System Optimum*, SO), que establece que, en condiciones de equilibrio, las condiciones del tráfico se organizan de tal manera que el tiempo total de viaje es minimizado. Este principio asume la existencia de un ITS que planifica y que los usuarios de la red de tráfico aceptarán las recomendaciones del operador de la red.

Posteriormente, otros principios han ido incorporándose al corpus, entre los que merece la pena destacar:

- El **Principio de Equilibrio Estocástico de Usuario** (*Stochastic User Equilibrium*, SUE) [41], es similar al UE diferenciándose de él considerando la *percepción del tiempo de viaje*, por lo que se llegará al equilibrio cuando ningún usuario *considere* que puede mejorar su tiempo de viaje cambiando de ruta.
- El **Principio de Equilibrio Dinámico de Usuario** (*Dynamic User Equilibrium*, DUE) [58], parte igualmente de UE considerando los tiempos de partida de cada vehículo: para cada par OD las rutas utilizadas por los viajeros que parten al mismo tiempo deben tener un tiempo de viaje igual y mínimo. A las restricciones de UE se añade el conocimiento detallado de las horas de partida de la demanda de trayectos. A la hora de considerar la utilidad de una ruta, DUE considera un modelo de coste generalizado del trayecto (no sólo basado en el tiempo).
- El **Principio de Racionalidad Limitada del Usuario** (*Boundedly Rational User Equilibrium*, BRUE) [77], que establece que los viajeros con racionalidad limitada son los que siempre eligen rutas sin bucles, y consideran un cierto umbral de mejora antes de cambiar de ruta a una mejor. Es decir, no cambian de ruta si la nueva ruta no mejora significativamente su viaje.

En [130] se comparan diversos estudios relativos al equilibrio del tráfico, relacionando lo criterios individuales frente a los criterios de sistema resumida en la figura 1.2:

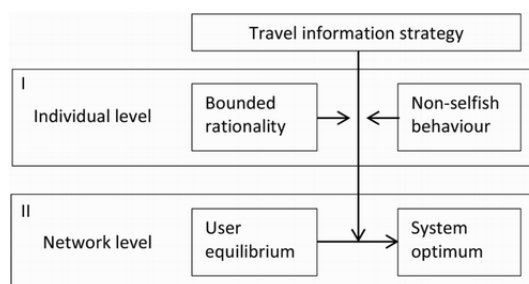


Figura 1.2.: El principio de racionalidad limitada del usuario en relación al equilibrio del tráfico [130].

Otros principios han sido propuestos considerando diferentes aspectos tales como la incertidumbre del enrutamiento, la utilidad para el usuario o la aversión al riesgo.

Szczeto et al. en su trabajo [122] ofrecen una excelente taxonomía de los diferentes principios.

1.1.2. Selección de la ruta óptima

Los primeros modelos de asignación de tráfico en la redes estaban basados en la caracterización de la red como un grafo de nodos y enlaces que los unen, donde el problema estaba centrado en la consecución del conjunto de caminos de mínimo coste para asignarlos como rutas a seguir por los vehículos. El algoritmo más conocido y usado es el de Dijkstra [45] y sus variantes [135], aunque también otros algoritmos son considerados como A* [67] o Hyperstar [17] y sus variantes.

La hipótesis de que todos los vehículos usarán el camino más corto con independencia del estado de la red (modelo todo-o-nada, AON) no resulta realista ya que los vehículos tomarán rutas alternativas en cuanto detecten congestión en alguno de los enlaces de la ruta que siguen. Por este motivo, se plantean los modelos de selección de los K caminos más cortos (*K-Shortest Paths*, KSP) [52], aunque el problema se traslada a la decisión del mecanismo de asignación de dichos caminos a los vehículos, bien por porcentajes, bien por congestión progresiva de los mismos o por otros criterios [59, 10]. De igual manera el concepto de KSP se amplía a los hyperpaths [106, 79]. En este último, cabe destacar la aplicación del mismo a la simulación de tráfico en la ciudad de Tokio referenciada por [60].

El cálculo y gestión de los KSP asociados a los trayectos de los vehículos no es suficiente para realizar una correcta asignación de tráfico, ya que es probable que la ruta más corta (0-SP) entre una tupla origen/destino y su siguiente mejor KSP (1-SP), apenas difieran unos pocos enlaces, o incluso sólo uno. Desde el punto de vista de la congestión, será importante considerar aquellos caminos KSP disjuntos entre sí [48, 114], donde se pueden valorar diversas métricas de solapamiento de caminos: % de número de enlaces en común, % de metros de ruta en común. No obstante, se abren nuevas dimensiones de análisis ya que no será lo mismo la coincidencia de ruta en inicio, en tránsito, en finalización de la ruta, e incluso la cuestión de cuánto es el porcentaje razonable de solapamiento de ruta para seleccionar un subconjunto de rutas. [74] muestra diversos factores de solapamiento (40 %, 50 % y otros).

1.1.3. Funciones de coste de los enlaces

La cuantificación del coste de un enlace entre dos nodos en una red de tráfico habitualmente está basada en su tiempo de tránsito, aunque en ocasiones se emplean modelos de coste generalizado que toman en cuenta otros parámetros tales como el coste económico del enlace.

Teniendo en cuenta exclusivamente el tiempo, el *coste básico de un enlace en circulación libre (free-flow travel time)* puede expresarse como $\beta_{i,j}^*$ (1.1), siendo $d_{i,j}$ la longitud del enlace y $s_{i,j}$ su velocidad máxima:

$$\beta_{i,j}^* = \frac{d_{i,j}}{s_{i,j}} \quad (1.1)$$

Sin embargo, la observación empírica del modelo pronto detectó que en realidad el coste del enlace dependía en gran medida de su ocupación, donde un enlace fuertemente ocupado dispara sus tiempos de tránsito. Así se formulan las funciones de coste de los enlaces, también conocidas como funciones de volumen-retardo (*Volume-Delay functions, VDF*), funciones de eficiencia de los enlaces (*link performance functions*) o funciones de tiempo de los enlaces (*travel time functions*). Estas funciones cuantifican la variación del tiempo de tránsito de un enlace en función del ratio de ocupación frente a su capacidad efectiva. Cuando un enlace comienza a estar congestionado, la acumulación de tráfico va incrementando exponencialmente el retardo de los vehículos que se encuentran en él.

Diversos factores forman parte de la caracterización de las funciones VDF:

- Tiempo de tránsito del enlace *free-flow*, β_{ij}^* .
- Volumen de vehículos en el enlace, w_{ij} , número de vehículos en el enlace.
- Capacidad efectiva del enlace, C_{ij} , medida como la máxima ocupación en vehículos. Esta capacidad se obtiene del diagrama fundamental del enlace, y suele estar normalizada en función del tipo de enlace: tipo de vía, número de carriles, y otros [23]. Según la Federal Highway Administration Office of Policy and Governmental Affairs (FHWA) [115]: «La capacidad de una instalación vial es la tasa máxima razonable por hora a la que se puede esperar que los vehículos atraviesen un punto o una sección uniforme de carril o calzada durante

un período de tiempo determinado en las condiciones de calzada, de tráfico y de control imperantes».

La función VDF más básica se describe en la expresión 1.2 que relaciona estos tres aspectos [119]:

$$\beta_{ij} = \beta_{ij}^* * \left(\frac{w_{ij}}{C_{ij}}\right) \quad (1.2)$$

Las mediciones empíricas de este valor hacen necesario su ajuste. Para ello, existen diferentes familias de funciones VDF, donde las más usadas son las definidas por el Bureau of Public Roads (BPR) [47, 94] y las cónicas propuestas por Spiess [119]. Se puede encontrar un análisis comparativo en [102, 109]. En la figura 1.3 se muestran las familias BPR y cónicas [119].




Figura 1.3.: Funciones VDF para los modelos BPR (a, b) y cónicos (c, d) para diferentes ratios v/c [119].

La función de coste definida por BPR se recoge en la expresión (1.3), donde k_1 y k_2 son constantes de ajuste empírico, igualmente tabuladas por BPR [47]. Los valores típicamente usados en ellas son $k_1 = 0,15$ y $k_2 = 4,0$.

$$\beta_{ij} = \beta_{ij}^* * (1 + k_1 * (\frac{w_{ij}}{C_{ij}})^{k_2}) \quad (1.3)$$

1.1.4. Métodos de asignación estática de tráfico

A la hora de calcular la asignación de tráfico para el escenario de equilibrio de usuario (UE) se suelen usar métodos aproximados mediante asignación estática, mientras que los mecanismos basados en óptimo del sistema (SO) suelen emplear métodos de enrutamiento dinámico [122]. Adicionalmente se suele usar el modelo original todo-o-nada (AON) como medida comparativa de cota superior.

Como ya se ha descrito anteriormente, el problema de asignación óptima del tráfico (TAP) para alcanzar el equilibrio de usuarios (UE) no puede ser resuelto de forma estricta, por lo que debe ser aproximado mediante algoritmos heurísticos, alguno de los cuales se describen someramente a continuación, dado que han sido empleados en el desarrollo de la investigación objeto de la tesis.

1.1.4.1. Asignación de Tráfico AON

El primer modelo de asignación de tráfico históricamente considerado está basado en el concepto de asignación todo-o-nada (*All-or-Nothing*, AON) [26, 47, 30], en el que se asume que los vehículos tomarán siempre la ruta de coste mínimo considerando para ello el coste de los enlaces de la red de tráfico. Este coste se calcula mediante alguna de las funciones VDF ya vistas, considerando los parámetros físicos del enlace, la capacidad del enlace y la cantidad de tráfico que soporta. En el modelo AON, únicamente se tienen en cuenta los enlaces usados por las rutas de coste mínimo, dejando el resto de enlaces sin considerar, lo cual hace que esta hipótesis sea poco realista. La utilidad del método AON proporciona una cota superior del tiempo de tránsito como veremos posteriormente en la sección 2.1.1.

1.1.4.2. Aproximación a la Asignación Óptima del Tráfico UE por acumulación de tráfico (CUM)

Este método heurístico, divide la demanda de tráfico en bloques iguales de tráfico que se cargan en la red por pasos incrementales sucesivos, recalculando en cada paso el peso de los enlaces.

En la primera iteración se considera una red de tráfico vacía ideal y se carga con el primer bloque de tráfico, calculando las rutas de mínimo coste mediante el enfoque AON. Así, las rutas seleccionadas utilizarán la máxima capacidad de los enlaces. En las siguientes cargas de bloques de viajes, los pesos de los enlaces para el cálculo de la ruta se actualizan aplicando la función VDF. En cada iteración se recalculan las rutas más cortas para cada bloque a enrutar.

El algoritmo genera diversidad de rutas, y su precisión depende del número y el tamaño de los bloques de tráfico. Los resultados pueden variar del orden de carga de los viajes y de la direccionalidad del tráfico.

1.1.4.3. Aproximación a la Asignación Óptima del Tráfico UE mediante medias sucesivas (MSE)

El algoritmo de medias sucesivas, a diferencia de CUM, utiliza un procedimiento iterativo considerando toda la demanda en cada paso.

Así, en el primer paso la red se carga mediante AON. En el siguiente paso, se retrae una porción de la demanda de tráfico, que es enrutada contra la red cargada con el volumen restante mediante la función VDF. Este proceso se repite en cada iteración dividiendo el último bloque enrutado en trozos cada vez más pequeños que son a su vez enrutados contra la red cargada con las divisiones anteriores.

Para mejorar la convergencia del algoritmo, en cada paso se reduce el tamaño de la división del tráfico. Como en el caso de CUM, el algoritmo genera diversidad de rutas, y su precisión depende del número y el tamaño de los bloques de tráfico. Los resultados pueden variar del orden de carga de los viajes y de la direccionalidad del tráfico.

1.1.4.4. Aproximación a la Asignación Óptima del Tráfico UE mediante aproximación por programación lineal (WEI-LP)

Wei et al. [133] han demostrado que la condición de optimización de la UE señalada por Beckmann et al. [15] puede calcularse eficientemente mediante funciones cónicas de segundo orden y métodos de programación lineal, manteniendo acotado el margen de error incurrido (precisión).

El algoritmo WEI-LP resuelve iterativamente el problema TAP considerando distribuciones progresivas de enrutamiento de tráfico. Comienza asignando una estrategia de enrutamiento AON a los vehículos basada en K caminos más cortos, y resolviendo el TAP calculando distribuciones de tráfico basados en pesos óptimos de los enlaces que se calculan mediante funciones de programación lineal. Así, usando dichos pesos, algunos vehículos podrían haber obtenido rutas de mejor coste, llevando el sistema a la siguiente iteración.

El proceso se repite resolviendo de nuevo el TAP para obtener la distribución de tráfico para este nuevo escenario de enrutamiento. Se repite hasta que hasta que no se puedan añadir más rutas de coste mínimo. Este algoritmo proporciona una interesante solución TAP estática que tiene en cuenta tanto el UE como el SO, aunque requiere calibración considerando la máxima ocupación de los enlaces.

1.1.5. Enrutamiento dinámico del tráfico

Szeto et al. [122] propone una interesante clasificación de los métodos de asignación dinámica de tráfico (*Dynamic Traffic Assignment*, DTA), reflejada en la tabla 1.1, a la que se ha añadido la posible aplicabilidad de la estrategia TWM objeto de la tesis. La asignación dinámica de tráfico tiene en consideración aspectos tales como:

- Los criterios de elección del conductor en relación a la ruta a tomar, su ajuste en el tiempo, así los instantes de tiempo de salida.
- La elasticidad de la demanda, conteniendo o permitiendo el ingreso de vehículos en el modelo.
- El ajuste dinámico del modelo intra-día o inter-días, así como en su consideración discreta o continua.

Dimensión	Criterios	Categorías de clasificación	TWM	
Elección del conductor	Elección de ruta e instante de salida	Selección exclusiva de instante de salida.	Sí	
		Selección exclusiva de ruta:	Ajuste reactivo en ruta	Sí
			Ajuste predictivo (fuera de ruta)	Sí
	Selección combinada de ruta e instante.	Sí		
	Elasticidad de la demanda	Demanda fija.		Sí
Demanda elástica.			Sí	
Franjas temporales	Horizonte de análisis	Intra-día	Sí	
		Inter-días	Sí	
	Modelo de asignación temporal	Tiempo continuo.	Sí	
		Tiempo discreto.	Sí	
Modelado matemático	Formulación de las variables de decisión	Flujo en los enlaces (<i>link-flow</i>).	Sí	
		Flujo en las rutas (<i>route-flow</i>).	Sí	
	Modelos de colas	Colas físicas.	Sí	
		Colas lógicas.	Sí	
	Número de clases de viajeros	Clase única	Sí	
		Múltiples clases.	Sí	
	Por la aproximación metodológica	Mediante simulación	Sí	
		Analíticas: NCP, VIP, MPP, FPP, OCP, CMP, etc.	A veces	

Tabla 1.1.: Taxonomía de métodos DTA y aplicabilidad TWM [122]

- Mediante modelos matemáticos: de sistema de colas de tráfico, de modelado lineal de los flujos en los enlaces y rutas, clases de tráfico, etc.

En la práctica totalidad de las aproximaciones la estrategia de enrutamiento mediante multi-mapas de tráfico presentada en la tesis, tiene aplicación.

En paralelo a las aproximaciones de asignación dinámica de tráfico DTA, existen numerosas aproximaciones heurísticas de enrutamiento de tráfico basadas en diversos criterios y algoritmos:

- Algoritmos basados en técnicas de decisión difusas (*fuzzy logic*) como los propuestos por [32, 22, 103, 124].
- Enrutamiento basado en la gestión de incentivos y penalizaciones (*toll-based*) [77, 120].
- Algoritmos de enrutamiento egoísta o cooperativos entre vehículos [57, 65].
- Enrutamiento de tráfico para redes ad-hoc vehiculares (VANET), que pueden ser redes vehículo-vehículo (V2V), redes vehículo-infraestructura (V2I) o redes

mixtas. Los algoritmos inspirados en la bio-diversidad como el *Ant-Colony* son habitualmente propuestos para este tipo de redes. En estos algoritmos, los vehículos dejan *feromonas* o trazas cuantificadas acerca de los caminos ya recorridos para informar tanto a la propia infraestructura como al resto de vehículos, para la selección dinámica de la mejor ruta a seguir [31, 29].

- Otros criterios inspirados en la biodiversidad para la optimización del enrutamiento, son los algoritmos evolutivos para la optimización del tráfico, como los propuestos por Bazaan, Chira y otros [14, 36, 35]. En la propuesta de Stolfi [121] dichos algoritmos se aplican a los sistemas de señalización de la infraestructura.

En todas estas aproximaciones, la propuesta de multi-mapas objeto de la tesis es susceptible de ser aplicada.

1.1.6. Sistemas inteligentes de transporte

El modelo clásico de planificación de las redes de transporte mostrado en la sección 1.1 (figura 1.1) es implementado mediante sistemas inteligentes de gestión del transporte (ITS) de diferentes tipologías: centralizadas, distribuidas e híbridas [37].

En el estándar del European Telecommunications Standards Institute ETSI-EN-302-665 [54] se propone una arquitectura de referencia para los ITS y sus modelos y sistemas de comunicaciones reflejada en la figura 1.4, donde se plantea una clasificación de los ITS en función de su modelo de comunicaciones y la ubicación de sus módulos funcionales: centralizados en una o varias estaciones base de control, distribuidos en las vías de circulación (*roadside*), personales en dispositivos de los usuarios o embarcados en los vehículos.




Figura 1.4.: Tipologías de ITS según ETSI EN 302-665.

Así, podemos encontrar propuestas de tipo centralizado como las descritas en [118, 24, 50, 96]. En algunos de ellos, como SCORPION y UCONDES, se adquieren y procesan periódicamente datos sobre la red y los individuos, detectando las condiciones del tráfico y generando rutas que se distribuyen a los vehículos. Esta información se obtiene mediante balizas que son emitidas periódicamente por los vehículos para su respuesta al ITS, quien la procesa mediante análisis de patrones vía redes neuronales, algoritmo evolutivos, sistemas de anticipación y negociación u otros [42, 40, 39]. La información de tráfico relevante se envía a los vehículos de la red, que deben decidir si siguen su ruta actual o calcular una ruta alternativa. Los mecanismos centralizados de ITS pueden saturar la red cuando hay una gran densidad de vehículos, y es necesario realizar mejoras adicionales para reducir el volumen de comunicaciones .

Alternativamente, se proponen diversos modelos de ITS distribuidos para resolver las limitaciones del modelo centralizado, tales como DIVERT [89, 95, 21, 65, 131]. Las propuestas distribuidas emplean de forma habitual técnicas multi-agente, con elementos bien en el vehículos, bien en los pasajeros, o en ambos. Así, los agentes en los vehículos recogen las observaciones e interacciones con otros agentes para descubrir las condiciones del tráfico y tomar las decisiones de enrutamiento. Por ello, los ITS cooperativos distribuidos no requieren habitualmente una infraestructura específica para la detección de la congestión. Sin embargo, los ITS distribuidos pue-

den sufrir problemas similares a los de los métodos centralizados en el intercambio ineficiente de información entre vehículos.

Existen propuestas orientadas al intercambio oportunista de contenidos como en [117], limitando la cantidad de interacciones mediante secciones críticas calculadas a priori por una parte de ITS centralizado (arquitectura híbrida). Podemos incluir también en esta tipología híbrida gran parte de las arquitecturas basadas en V2I [56, 121].

En los enfoques híbridos, la existencia de una parte ITS centralizada favorece el enfoque de enrutamiento por *hyperpaths* para abordar la incertidumbre y la variabilidad de la dinámica del tráfico, donde los agentes de tráfico individuales reciben para cada origen y destino un árbol de alternativas en lugar de una sola ruta [80, 17, 92, 33]. El *back-end* centralizado emplea los datos recibidos para discernir los distintos patrones de comportamiento del tráfico [78, 74, 60] y la generación de los árboles de rutas *hyperpaths* precisando grandes capacidades de computación.

Los enfoques de infraestructuras para las ciudades inteligentes [6, 12, 82], consideran fundamental la parte *back-end* de los ITS que aplican técnicas de *big data* al problema de la gestión del tráfico urbano, para resolver conjuntamente los objetivos globales y las necesidades específicas los conjuntos de los usuarios [53, 69, 44, 13, 110]. Los *back-ends* de *big data* requieren conjuntos de datos reales que se obtienen utilizando sensores de red y enfoques de detección colectiva. En estos últimos, tanto el agente del vehículo como el agente del conductor pueden recoger anónimamente los datos de tráfico y del estado de la red, mediante técnicas denominadas *crowd-sensing* [136, 105, 83, 71, 64] que se describen el apéndice E, y que se han empleado en la tesis.

La adopción real de un sistema ITS presenta numerosas limitaciones que se deben tener en cuenta:

- Habitualmente requieren que todos los vehículos de la red tengan operativos los correspondientes agentes de enrutamiento, además, independientemente de la tipología del vehículo y su agrupación por flotas.
- Se debe garantizar la compatibilidad entre los agentes.
- La adopción global de este tipo de métodos precisa el consenso de toda la industria y necesitaría la adopción de normas y estándares en todos los ámbitos,

a menos que que sean capaces de demostrar su eficacia en escenarios de baja adopción.

- Otro importante inconveniente de los ITS distribuidos es que dependen fuertemente de las comunicaciones y su disponibilidad, que a su vez depende de muchos factores: las capacidades reales de comunicación de los vehículos, las propiedades de la red radio, los efectos adversos de la meteorología (*fading*) e interferencias, los proveedores de servicios, las ofertas de conectividad y planes de suscripción.

1.1.7. La congestión de tráfico en ámbitos urbanos

El concepto de congestión de tráfico y su caracterización ha ido evolucionando con el tiempo, y por ello se encuentran diferentes definiciones que tienen en cuenta los tiempos de viaje de los usuarios, o la relación entre demanda de tráfico y capacidad de las vías [55]. En esta tesis emplearemos el concepto de congestión descrito en el informe 398 del *Transportation Research Board* [75], que ofrece una serie de definiciones que interrelacionan los aspectos mencionados anteriormente, considerando la movilidad de los viajeros, fiabilidad y predictibilidad de los tiempos de tránsito. Aprovechamos para ampliar y desarrollar algunos de dichos conceptos y añadir algún criterio adicional:

- **Congestión:** incremento en el tiempo de viaje real de los vehículos frente al tiempo de viaje ideal (*Free-Flow Travel Time, T_{FF}*). La condición de idealidad se corresponde con el escenario de libre circulación del vehículo (*Free-Flow Conditions, FFC*), que asume que el mismo puede circular a la máxima velocidad permitida en cada enlace sin paradas ni bloqueos.
 - **Congestión recurrente:** es aquella que se produce de forma periódica (cada día de la semana, los viernes, los fines de semana, etc) en el mismo lugar y a las mismas horas en general. La congestión recurrente está asociada a la demanda de tráfico observable de forma histórica en los períodos de tiempo definidos.

Esta demanda está formada en términos generales por la superposición de dos tipologías de tráfico en función de los patrones de origen/destino:

1. Tráfico proveniente de los flujos de tráfico identificables entre orígenes y destinos. Estos flujos suelen corresponderse con desplazamientos asociados a desplazamientos predecibles: trayectos laborales, colegios, fines de semana, rutas de distribución, y similares.
 2. Tráfico medio de fondo habitual en la red urbana de naturaleza aleatoria, cuyos orígenes y destinos no siguen un patrón distinguible y que se modelan con funciones de distribución.
- *Congestión no recurrente*: es la provocada por condiciones extraordinarias en la demanda o en la red, y que genera alteraciones apreciables en el tráfico.
 - *Congestión no recurrente aleatoria*: es la producida por un evento aleatorio: accidentes de tráfico, cortes en la vía, fenómenos atmosféricos, etc.
 - *Congestión no recurrente planificada*: es la producida por un evento planificado en la red o en el tráfico: cortes planificados, mantenimiento de la vía, obras, eventos deportivos, uso de las vías para eventos públicos, etc.
 - *Congestión aceptable*: la condición de idealidad de circulación de tráfico (FFC) no suele ser el escenario de circulación normal, dado que los enlaces de red presentan un cierto grado de ocupación que afecta a las condiciones de tráfico. En ese sentido, los conductores asumen de forma «normal» cierta desviación razonable ΔT en su tiempo de tránsito respecto al ideal, que se denomina *congestión razonable (asumible)*. Cuando la situación de tráfico se encuentra en niveles de congestión aceptable, podemos decir que la red se encuentra en condiciones de baja ocupación (*Traffic under Low-Occupation Conditions*, TLOC).
 - *Congestión inaceptable*, en general conocida simplemente como *congestión*: aquella en la que los parámetros de caracterización están por encima de los valores de baja ocupación (TLOC). En este caso se hablará de condiciones de congestión inaceptable (*Traffic under Congested Conditions*, TCC).

- *Congestión inevitable*, es aquella provocada por los vehículos de la red cuando circulan todos bajo condiciones de enrutamiento perfecto, es decir, cuando todos los conductores han sido capaces de lograr la ruta de menor coste en todo momento, en lo que se denomina equilibrio de usuario (*User Equilibrium*, UE). Se podría definir el concepto contrario, de *congestión evitable*, cuando ésta viene provocada por criterios de enrutamiento que no llevan al equilibrio de usuario.
- *Fiabilidad de los tiempos de viaje*: consecución de los objetivos de viaje en los límites de tiempo considerados aceptables.
- *Predictibilidad del tiempo de viaje*: capacidad de predecir el momento de llegada al iniciar un desplazamiento.

1.2. Planteamiento del problema

Como ya se ha visto, el problema de la mitigación de la congestión en los entornos urbano, requiere mecanismos de control, asignación y enrutamiento dinámicos que permita a los vehículos tomar rutas alternativas a los caminos de mínimo coste bajo situaciones ideales. Los principios de equilibrio nos permiten aproximar las situaciones ideales óptimas de la red, en base a funciones de coste homogéneas, ya se trate de un coste basado en funciones de volumen-retardo o en funciones de coste generalizado. Sin embargo, conducen a modelos que presentan distintas limitaciones y carencias entre las que se encuentran:

- **Congestión inducida por los ITS.** Hasta el momento, los sistemas actuales de guiado de vehículos se han basado en dos informaciones fundamentales: la red viaria y el estado de la red (estático o dinámico). Así, dado un conjunto de vehículos que quieren desplazarse en el mismo instante entre un mismo origen O y destino D, con el mismo nivel de información de estado de la red viaria, y usando el mismo sistema de guiado, recibirán la misma información de enrutamiento. Por tanto, podremos afirmar que la congestión en ciertas zonas y rutas es inducida por los propios sistemas de recomendación de tráfico inteligentes (ITS), provocándola en los enlaces que estén más cargados de la ruta. Esta restricción es igualmente aplicable a los sistemas de enrutamiento dinámico basados en comunicaciones inter-vehiculares.

- **Heterogeneidad de ITS.** Por otro lado, en los escenarios de enrutamiento real los conductores emplean diversos ITS de forma concurrente o alternativa (TomTom, GoogleMaps, Waze, navegadores de serie en los vehículos, etc) cuyas recomendaciones se basan en los mismos datos: la misma red de tráfico y el mismo estado del tráfico. Estos ITS no están interconectados entre sí, por lo que a igualdad de OD de un trayecto ofrecerán similares recomendaciones, generando igualmente congestión en las rutas más usadas.
- **Adherencia a los ITS.** No todos los conductores emplean ITS o sus recomendaciones por diversos motivos: indisponibilidad del mismo, falta de conectividad para actualizar el estado de la red, no uso, ignorar sus recomendaciones, y otros. En general, podemos asumir que el uso de un cierto ITS depende de su adherencia al mismo y de una función de uso estocástica.
- **Modelos no homogéneos de utilidad.** Cabe plantearse igualmente la validez del modelo de utilidad de los conductores, planteándose varias cuestiones: ¿todos los vehículos de una red de tráfico tienen las mismas características y necesidades? ¿Sus necesidades dependen del día de la semana, o de la hora del día? Llevándolo a casos concretos, es evidente que no tienen las mismas necesidades los vehículos privados, los vehículos eléctricos de flotas *car-sharing*, los vehículos de reparto comercial en sus horas de reparto, los taxis, los vehículos de flota VTC, los autobuses escolares e incluso el tráfico privado escolar en horas de entrada y salida de colegios, etc. Así podríamos establecer el tráfico en la red como la superposición de los tráficos de los diferentes grupos, denominados *flotas* en adelante.
- **Impacto en el sistema urbano.** De igual manera, tampoco es homogéneo el impacto que ejercen las diferentes tipologías de tráfico sobre el sistema en términos de emisiones o ruidos. Las necesidades de recomendación de rutas de los vehículos de bajas emisiones o los contaminantes tampoco son homogéneas.
- **Restricciones dinámicas en la red.** También la propia red tiene sus propios condicionantes que evolucionan por el momento de tiempo (no circular en ciertas horas), por eventos (salida del fútbol), por condiciones ambientales (alertas de contaminación), etc. En este caso, la aproximación de gestión tradicional radica en el uso de mecanismos viarios de señalización y aviso.

- **Dependencia de las comunicaciones.** Como ya hemos visto en la introducción, muchos de los planteamientos de ITS requieren una fuerte disponibilidad de infraestructuras de comunicaciones con importantes requisitos de ancho de banda y de prestaciones, asumiendo una importante adherencia de los vehículos a estas infraestructuras que suelen ser propiedad de múltiples operadores y que implican costes a sus usuarios.

Así, es necesario el planteamiento de métodos y estrategias alternativas de enrutamiento que permitan integrar las limitaciones anteriormente mencionadas, para conseguir mejores modelos de enrutamiento enfocados a la optimización de los distintos parámetros de la gestión del tráfico en las ciudades, con especial foco en la reducción de la congestión del tráfico. El éxito de estos nuevos modelos y técnicas depende de ciertas características:

- Deben ser efectivos bajo diferentes niveles de adherencia de los conductores.
- Deben considerar la concurrencia, simultaneidad y adopción de múltiples ITS.
- Deben poder combinar políticas y regulaciones centralizadas del operador de la red junto a la toma de decisión individual del vehículo.
- Deben permitir el despliegue de modelos de utilidad heterogéneos para las diferentes tipologías de vehículos y flotas.
- Deben ser compatibles con el despliegue de las redes VANET V2V y V2I .
- Deben hacer un uso racional de las redes de comunicaciones.
- Deben ser capaces de generar unos niveles óptimos de **diversificación de rutas** dado que es una de las claves de la mitigación de la congestión.

1.2.1. Enrutamiento mediante multi-mapas de tráfico

Todos los métodos de enrutamiento y de sistemas inteligentes de gestión del tráfico están basados en mayor o menor medida en las siguientes fuentes de información: el mapa de la red, el estado de la red, la demanda de tráfico y su previsión. Existe una aproximación al problema que no se ha abordado de forma sistemática: la

diferenciación entre la propia red física de tráfico y el mapa de la red como vista lógica.

El mapa de la red es sino una vista de la red. Los sistemas inteligentes de transporte y los sistemas de navegación de los vehículos usan una vista (mapa) para la toma de sus decisiones.

Podríamos considerar un mecanismo de generación y distribución de múltiples vistas de la red que fueran distribuidas a los vehículos de forma selectiva según ciertos criterios lógicos y temporales. No solamente eso, dichas vistas diferenciadas de la red podrían ser usadas por los ITS convencionales o por los sistemas de navegación de los conductores. Este mecanismo de enrutamiento del tráfico mediante múltiples mapas complementarios de la red lo hemos denominado **TWM -Traffic Weighted Multi-Maps-** puesto que su objetivo es la generación de mapas de tráfico con pesos modificados de tal manera que se adecuen a los casos de uso de los problemas de tráfico.

El modelo de enrutamiento TWM es especialmente apto para la gestión del tráfico urbano donde existen multiplicidad de caminos entre orígenes y destinos, y donde, además, existen numerosos casos de aplicación para ciertas problemáticas específicas. Entre dichos casos de uso se encuentran: reducción de la congestión en áreas urbanas, reducción de emisiones, enrutamiento diferencial por tipo de tráfico, enrutamiento diferencial por bloques horarios, respuestas dinámicas a incidentes, etc. Los casos de uso serán desarrollados en la sección 2.2.2.

La propuesta de TWM requiere:

1. La formalización de un modelo de generación y distribución de los mapas.
2. Un estudio de aplicación microscópico para analizar el impacto en sistemas reales de tráfico. Este estudio requiere la generación de herramientas de simulación microscópicas.
3. Un estudio de aplicación macroscópico para analizar la asignación de tráfico mediante TWM como mecanismo de planificación del tráfico. . Este estudio requiere la generación de herramientas de simulación macroscópicas.

4. Un mecanismo de generación de mapas TWM para el enrutamiento óptimo del tráfico, con sus correspondientes herramientas.
5. Un estudio macroscópico de la adopción del sistema por parte de los conductores considerando sus modelos de utilidad, y una implementación de dicho modelo.
6. El desarrollo detallado de algunos de los casos de uso identificados.

Todos estos puntos son objeto de la presente tesis, así como una valoración de los resultados obtenidos mediante simulación.

TWM se propone como un modelo innovador de enrutamiento de tráfico, por lo que la contribución del planteamiento es directa sobre los ITS actuales y los sistemas de navegación embarcados. A pesar de la sencillez de la propuesta y de su alto grado de aplicabilidad y de potencial integración en los ITS actuales, no hemos encontrado referencias previas a mecanismos con una propuesta similar, aunque curiosamente al poco tiempo después de la primera publicación de la propuesta ya ha aparecido algún trabajo en la misma dirección [34].

1.3. Objetivos y ámbito de las contribuciones

En este apartado se definen los objetivos de esta Tesis Doctoral, todos ellos encaminados a la definición y validación de la estrategia de enrutamiento multi-mapa TWM descrita.

1.3.1. Modelado, generación y distribución de TWM

Entre los primeros objetivos a abordar en la tesis, están: el estudio de la diferenciación de las capas física y lógica de los mapas de las redes de tráfico para la generación de multi-mapas, el estudio de cómo afectan las modificaciones en los mapas a la toma de decisión de los conductores, y el efecto que dicho enrutamiento provoca en el tráfico para los diversos casos de uso, donde el caso de uso de mayor importancia es el reducción de la congestión de tráfico.

En ese sentido, es preciso definir tanto un **modelo del sistema**, como los **criterios de generación** de los mapas de pesos de la red de tráfico, y los **criterios de distribución** de los mapas a los vehículos. Ambos criterios deberán ser adaptados a los diferentes.

Asimismo, es necesario definir igualmente los **indicadores de medición** para analizar la bondad de cada uno de los criterios de enrutamiento, así como identificar las variables independientes y dependientes del modelo para realizar los correspondientes análisis de sensibilidad.

Uno de los principales factores que se deben analizar en el comportamiento de una propuesta como TWM es el análisis del comportamiento bajo diferentes **niveles de adherencia de los conductores**, dado que es presumible que no todos los conductores vayan a ser usuarios del nuevo sistema, y que incluso siendo usuarios, no tengan en cuenta las nuevas recomendaciones de enrutamiento. En ese modelo de adherencia parcial, será preciso estudiar el efecto que tiene TWM en todos los vehículos de la red, tanto los usuarios como los no usuarios.

1.3.2. Asignación dinámica de tráfico por diversificación de caminos mediante TWM aleatorizados

Una de los mecanismos principales para la disminución de la congestión en las redes tráfico urbanos es la diversificación de rutas de los vehículos para evitar que se saturen los enlaces. Habitualmente esto se consigue mediante el cálculo de los *K-Shortest Paths* y teniendo en cuenta el estado y carga de los enlaces, junto a las funciones VDF que caracterizan su coste. Esto último requiere que cada vehículo disponga de información completa en tiempo real de la red.

Sin embargo, TWM nos permite diversificar las rutas con un mecanismo más sencillo asociado a las propias vistas de la red. Estas vistas pueden ser obtenidas de dos maneras:

1. Empleando información de estado de la red, o históricos de demanda. Así podremos generar conjuntos de mapas óptimos de la red, y distribuirlos con ciertos algoritmos.

2. Sin emplear información adicional de estado o demanda. En este caso, la diversificación puede lograrse generando y distribuyendo mapas TWM con pesos aleatorizados, de manera que cada vehículo realizará el cálculo de su ruta más corta empleando vistas distintas de la red y por tanto seleccionando diferentes rutas.

La asignación dinámica de tráfico usando TWM para reducir la congestión en la red, podrá efectuarse y medirse mediante simuladores microscópicos.

1.3.3. Simulación microscópica de escenarios de uso de TWM

Dado el carácter práctico y de aplicación de la propuesta TWM, será necesario hacer experimentos sobre escenarios de tráfico concretos. Dada la complejidad de aplicar un nuevo sistema de enrutamiento de tráfico a un problema real, se optará por la realización de **simulaciones** de problemas de tráfico. En ese sentido, los escenarios de **redes de tráfico de tipo sintético** (teóricas) nos permitirán orientar la simulación hacia aspectos específicos del problema y focalizar el análisis de sensibilidad frente a los problemas a resolver. Las redes sintéticas eliminan la complejidad y asimetría inherente a las redes tráfico reales que podría enmascarar en cierta manera los resultados de la aplicación de TWM.

Tras la experimentación con modelos, es preciso contrastar los resultados de las simulaciones con nuevos experimentos de **simulación sobre redes reales**, para los casos de uso objetivo. Es decir, si vamos a emplear TWM para la resolución de la congestión global, tras los escenarios sintéticos será preciso simular escenarios de redes de tráfico reales congestionadas.

Para cubrir el objetivo de definición, generación y distribución de mapas TWM, se optará por emplear simuladores microscópicos que permitan el análisis estadístico de los resultados tanto a nivel sistémico como a nivel individual (estadísticos pareados). Sin embargo, dado que TWM es una aproximación nueva, los simuladores actuales no soportan dicho modelo, por lo que es preciso construir la suite de **herramientas de simulación microscópica** que nos permitan acometer las simulaciones requeridas.

Como primer caso de uso objetivo, se tomará la reducción de la congestión empleando diversificación de caminos mediante **distribuciones TWM con mapas de pesos aleatorizados y asignación dinámica de rutas**.

El segundo caso de uso será la **gestión dinámica de incidentes** en la red mediante TWM diseñados al efecto.

1.3.4. Asignación estática de tráfico mediante TWM optimizados: caracterización del óptimo del sistema

Tras la definición, análisis y demostración del modelo de enrutamiento mediante multi-mapas TWM, y el uso de TWM para diversificación de rutas con mapas aleatorizados, la siguiente cuestión es directa: ¿cuál es la configuración concreta de TWM que entrega un enrutamiento óptimo? Este problema es análogo a la resolución del principio de asignación por óptimo del sistema, SO.

Según el modelo extendido de planificación del transporte definido en la sección 2.2.1, los mapas de tráfico son distribuidos por un ITS de forma centralizada (o que los vehículos acuden al mismo a consultar o actualizar dichos mapas). Por tanto, el ITS deberá ser capaz de generar los mapas adecuados en función de algún modelo de asignación que tenga en cuenta TWM. Así, tendremos que resolver dos problemáticas:

- Crear un modelo de asignación estática de tráfico mediante TWM, como paso previo para poder evaluar la calidad de dicha asignación (TTS).
- Crear algoritmos de cálculo de mapas de pesos óptimos para TWM, que posteriormente son evaluados por la asignación estática.

Si asumimos que la principal dimensión de análisis de la congestión de tráfico es el tiempo total de viaje de los vehículos en el sistema, entonces la resolución del conjunto de **TWM óptimo aportará un heurístico de cálculo del óptimo del sistema**, que podrá ser contrastado con otros modelos de resolución TAP. Dada la extensión del problema en todas sus variantes, circunscribiremos el problema a los escenarios de asignación estática de tráfico, aunque es directa su aplicación a otros modelos.

1.3.4.1. Asignación estática de tráfico mediante TWM

El objetivo aquí es analizar el comportamiento macroscópico de los ITS que realizan asignación de tráfico empleando TWM para lo cual será preciso definir el **modelo de asignación de tráfico que use TWM** y compararlo con otros modelos de asignación de tráfico existentes, para analizar su comportamiento en las situaciones de equilibrio UE y SO principalmente.

1.3.4.2. Algoritmos de generación de conjuntos de mapas TWM óptimos.

Asumiendo la validez de la propuesta de enrutamiento TWM y la posibilidad de realizar asignación de tráfico mediante esta técnica, la siguiente cuestión es directa: ¿cuál es la distribución de mapas TWM óptima para un caso de uso determinado, dado un escenario de tráfico concreto -red y demanda-? Y por otro lado, ¿qué algoritmos y procedimientos de cálculo de TWM podemos emplear?

Tomando nuevamente el escenario de congestión, es preciso cualificarla en sus indicadores para poder llevar a cabo su proceso de optimización mediante **métodos de cálculo de la distribución óptima de mapas y pesos TWM**. Dicho cálculo en realidad es equivalente a la resolución del problema de la asignación de tráfico en equilibrio (TAP) apuntado en la sección 1.1, en la que se describe su complejidad y la necesidad de métodos heurísticos de resolución. La inclusión de las dimensiones de análisis adicionales de TWM no hace sino incrementar dicha complejidad de cálculo.

En ese sentido, los métodos iterativos y evolutivos pueden aportar un mecanismo de medición y búsqueda de óptimos del sistema, por lo que se emplearán **algoritmos evolutivos (*genetic algorithms*, GA)** para el cálculo de las distribuciones de mapas y pesos óptimos.

1.3.5. Modelado de la experiencia de usuario en entornos complejos de múltiples ITS.

Ya hemos descrito cómo en las redes de tráfico urbano reales se usan de forma simultánea diferentes ITS con distintos criterios de enrutamiento simultáneos. La

introducción de sistemas basados en TWM que entregan diferentes vistas (mapas) de la red, incrementa la complejidad de la toma de decisión y de adherencia a los ITS. En ese sentido, es preciso definir un modelo de adopción de los vehículos a las recomendaciones de enrutamiento basado en su utilidad. Dicho modelo deberá ser multi-criterio teniendo en cuenta los diferentes aspectos valorables por los usuarios.

La toma de decisión del enrutamiento por parte de los conductores presenta diferentes planos: por un lado, la **valoración objetiva** de los parámetros considerados; por otro lado, la **cuantificación subjetiva** de dichos valores, y la aplicación de las reglas de decisión que los combinan; y por último, la consideración de la **toma de decisión como un proceso estocástico**.

Dado que la toma de decisión finalmente por parte de los conductores será la elección de una ruta concreta, podrá aplicarse un modelo de decisión discreta, mecanismo ampliamente estudiado en ámbitos económicos y aplicado al tráfico [8, 9, 18, 27], aunque el cálculo de la utilidad subjetiva de cada opción de enrutamiento deberá tener en cuenta mecanismos de valoración y razonamiento difuso e individualizado.

1.3.6. Dinámica de la adopción de TWM en sistemas complejos.

El último objetivo de alto nivel de la tesis consiste en el estudio de la evolución temporal de la adherencia a TWM. De esta manera, es preciso evaluar el modelo de experiencia de los usuarios, conforme ellos van usando el sistema en el tiempo, en secuencias inter-días, estudiando cómo evoluciona el mismo hacia modelos convergentes de promoción, hacia modelos oscilatorios, o incluso hacia modelos de detracción. En el caso de alcanzarse una convergencia, ésta marcaría el nivel del óptimo estable del sistema.

1.4. Estructura de la tesis

Con el objetivo de facilitar la lectura y comprensión de esta tesis ésta se ha estructurado en cuatro partes, nueve capítulos y dos apéndices, siguiendo la normativa del Programa de Doctorado de Tecnologías de la Información y las Comunicaciones de la Universidad de Alcalá (PDTIC-UAH) [128], que establece lo siguiente: *«la Tesis Doctoral podrá realizarse mediante el compendio de artículos del doctorando en publicaciones de reconocido prestigio. El número mínimo de artículos será de tres. La Tesis deberá incluir, además de los artículos, un resumen amplio que de coherencia al conjunto de la investigación, en el que se muestre la línea argumental de la misma, así como un capítulo de conclusiones».*

Parte I: Motivación de la investigación y resumen amplio de la tesis.

Esta parte de la tesis recoge tanto los objetivos de la investigación como un resumen de la misma.

Capítulo 1, Introducción. En ella se plantea el propósito de la tesis así como los objetivos de investigación. A tal fin, se inicia con un estudio previo del contexto y los trabajos precedentes en relación al tema, tras lo cual se expone el planteamiento de la investigación a desarrollar. Posteriormente se describen los objetivos, ámbito de estudio y las contribuciones esperadas. Por último, se expone la estructura de la tesis.

Capítulo 2, Algoritmos Multi-Mapa de Enrutamiento Dinámico de Trafico Vehicular. Este capítulo describe el resumen amplio de la tesis de manera estructurada, justificando en cada epígrafe el estado del arte que justifica cada una de las aportaciones realizadas, el análisis experimental que lo argumenta y las contribuciones del mismo. Adicionalmente, el capítulo incluye una relación de los casos de uso identificados donde TWM puede ser de aplicación. El capítulo incluye dos tablas sinópticas que resumen las contribuciones de cada publicación, así como los escenarios experimentales abordados en cada uno.

Parte II: Relación de artículos publicados que dan lugar a la tesis.

La segunda parte de esta tesis recoge las diferentes publicaciones realizadas en revistas de impacto JCR que cumplen con la normativa específica, incluyendo: una descripción de cada artículo, sus objetivos, contribuciones y resultados experimenta-

les, un breve esquema descriptivo que resume la publicación y su impacto, así como el texto íntegro de la publicación.

Capítulo 3, Urban Traffic Routing Using Weighted Multi-Map Strategies. El primer artículo describe el modelo de enrutamiento mediante mapas de tráfico con diferentes distribuciones de pesos (TWM), y su utilización para el enrutamiento diferencial de vehículos. La publicación aborda la asignación dinámica de tráfico por diversificación de rutas mediante mapas aleatorios, así como la generación dinámica de mapas para la gestión dinámica de incidentes en la red. Las simulaciones se realizan en una red urbana real (Alcalá de Henares) y se analiza tanto el efecto global como el efecto para cada individuo, para diferentes niveles de adherencia. El objetivo es la reducción de la congestión global.

Capítulo 4, Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment. El segundo artículo aborda la obtención de multi-mapas óptimos para los flujos de demanda de tráfico que generan de forma recurrente los escenarios de congestión. Se proponen diversos algoritmos genéticos combinados con mecanismos de asignación estática de tráfico. Las simulaciones empleadas se basan en escenarios sintéticos y en escenarios reales (Madrid-Retiro). El objetivo es el análisis de la calidad de los mapas TWM ofrecidos por su proximidad al óptimo del sistema (SO).

Capítulo 5, Modeling Driving Experience with Smart Traffic Routing Strategies: Application to Traffic Multi-Map Routing. El tercer artículo aborda el estudio de la convergencia en la adopción de rutas basadas en entornos de múltiples recomendadores, donde TWM es uno más entre ellos. Para ello se combinan los mecanismos de elección discreta basados en multinomial logit con reglas de decisión borrosa que modelan el comportamiento de los conductores. Cada conductor tomará sus decisiones de forma independiente en función de sus necesidades, experiencias anteriores y la valoración subjetiva de utilidad de cada alternativa disponible. El modelo se aplica de forma concreta a la decisión del uso de TWM. Los experimentos se realizan sobre redes sintéticas y redes reales (Madrid-Las Tablas). El objetivo es analizar dicha convergencia en el tiempo, en función del comportamiento de los conductores de los vehículos.

Capítulo 6, Otras publicaciones relacionadas. TWM fue presentado de forma preliminar en el congreso PAAMS'19 [99] como una propuesta experimental empleando mapas aleatorios sobre escenarios sintéticos, y se ha considerado de interés incluir la publicación que generó en el *Lecture Notes for Computer Science*.

Parte III: Conclusiones

El apartado de conclusiones recoge las contribuciones aportadas por los trabajos objeto de la tesis, los resultados ofrecidos y la difusión de los mismos. Asimismo se identifican futuras líneas de investigación y aplicación de las técnicas desarrolladas.

Capítulo 7, Discusión y conclusiones. En él se describe el nivel de consecución de los objetivos perseguidos y las contribuciones realizadas. El capítulo recoge una discusión de los resultados, revisando igualmente los escenarios de aplicación de la tecnología desarrollada.

Capítulo 8, Difusión de las contribuciones de la tesis. Describe los medios e impactos conseguidos por las contribuciones de la tesis.

Capítulo 9, Futuras líneas de investigación. En él se recogen las posibles líneas futuras de trabajo, así como otras líneas de aplicación de las aportaciones realizadas, incluso para otros ámbitos de estudio.

Parte V. Referencias.

Se incluye aquí tanto el glosario de términos y acrónimos empleado, como las referencias bibliográficas empleadas en el texto actual de la tesis. Con el fin de preservar la integridad del compendio, cada una de las publicaciones incluye su propio listado de bibliografía tal cual aparece en su publicación original.

Parte V. Apéndices.

Durante el desarrollo de la tesis se han utilizado datos sobre tráfico de vehículos y se han implementado herramientas concretas para poder llevar a cabo la investigación. En esta última parte se recogen los desarrollos realizados y los datos utilizados con el fin de garantizar la validación de los experimentos que validan las contribuciones de la tesis.

Apéndice A, Escenarios de análisis. En la tesis se emplean escenarios de tráfico tanto sintéticos como de escenarios urbanos reales. Los primeros son útiles como modelos simplificados donde desarrollar con efectividad los algoritmos, mientras que los segundos se emplearán como contraste y validación de los mismos. En el escenario de Alcalá de Henares se emplean datos modelados a partir de tomas reales de tráfico mediante mecanismos de *crowd-sensing* que se comenta en apéndice específico.

Apéndice B, Recursos y herramientas de investigación. En el trabajo de investigación se han empleado diversas herramientas de modelado y simulación de tráfico tanto microscópico como macroscópico. Para la implementación de los mecanismos de TWM ha sido preciso desarrollar un numeroso conjunto de herramientas tanto para los simuladores microscópicos, macroscópicos y de optimización.

Apéndice C, Reglas fuzzy del modelo de experiencia de usuario para TWM. Para el modelado de la experiencia de usuario se ha implementado un conjunto completo de reglas de razonamiento difuso sobre el espacio de variables considerado en el modelo de optimización.

Apéndice D, Relación de desarrollos y productos software generados. En el trabajo de investigación se han generado numerosos productos software y entornos de trabajo que simplemente son enumerados en el apéndice.

Apéndice E, Datos de Crowd-Sensing. El trabajo de investigación ha empleado como base datos reales de tráfico obtenidos mediante técnicas de *crowd-sensing* y donados por una compañía privada, por lo que se hace una somera mención a su proceso de obtención.

2

Resumen amplio: Algoritmos Multi-Mapa de Enrutamiento Dinámico de Tráfico Vehicular

Este capítulo recoge el resumen amplio de la investigación realizada en el que se muestran las distintas propuestas generadas, sus correspondientes desarrollos, los datos empleados, así como los resultados y conclusiones obtenidas. Se incluye igualmente su relación con los artículos que se recogen en los capítulos posteriores. En ese sentido, se ha optado por hacer una presentación cronológica de los trabajos que coincide igualmente con la secuencia de publicación de los artículos.

Dado que la tesis se presenta como compendio de artículos de investigación publicados, se adjunta la tabla esquemática 2.1 para ayudar al lector a la comprensión y seguimiento de los objetivos de investigación en las publicaciones efectuadas recogidas en los sucesivos capítulos, así como los escenarios experimentales recogidos.

Área temática	Urban Traffic Routing Using Multi-Map Strategies [98]	Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment [97]	Modeling Driving Experience in Smart Traffic Routing Scenarios: Application to Traffic Multi-Map Routing [2]
Caracterización de la congestión	x	x	x
Asignación de Tráfico		x	x
Modelo TWM	x	x	x
Estrategias de optimización de TWM		x	
Enrutamiento con mapas aleatorios	x	x	
Enrutamiento con mapas optimizados		x	x
Casos de uso: minimización de la congestión.	x	x	x
Casos de uso: respuesta dinámica a incidentes	x		
Modelo de experiencia de usuario			x
Simulación microscópica	x		x
Simulación macroscópica		x	x
Dinámica del sistema de tráfico	x		x
Escenarios sintéticos de aplicación	Grid64Radial16	Grid64	Grid64
Escenarios urbanos reales	Alcalá de Henares	Madrid-Retiro	Madrid-Las Tablas
Crowd-Sensing	x		

Tabla 2.1.: Diagrama esquemático de las investigaciones realizadas

Asimismo, en la tabla 2.2 se ilustra el esquema de escenarios y experimentos para cada una de las contribuciones que se adjuntan en la tesis. Conviene indicar que no todos los escenarios han sido publicados por mor de la concisión y legibilidad de las publicaciones.

Tipo	Escenario	Cap.3 [98]	Cap.4 [97]	Cap.5 [2]	Otros	Pend.Pub
Sintético	Ortuzar-Willumsen				[94, 14]	
	Paricio-LopezCarmona					x
	Grid-64	x	x	x		
	Grid-256				x	
	Radial-241	x			x	
Urbano real	Madrid-Retiro		x			
	Madrid-LasTablas			x		
	Alcalá de Henares	x				

Tabla 2.2.: Referencias a los escenarios experimentales en las publicaciones de la tesis.

2.1. Caracterización de la congestión de tráfico

En la sección 1.1.7 se ha descrito la congestión de tráfico en el ámbito urbano, siendo necesario caracterizarla. Así, consideraremos para cada vehículo k sus parámetros (tiempo de viaje, distancia recorrida y velocidad media) para el trayecto real (t^k, d^k, v^k) y del trayecto en condiciones de baja ocupación de red $(t_{LO}^k, d_{LO}^k, v_{LO}^k)$. La condición de congestión (2.1) se dará cuando:

$$t^k > t_{LO}^k \quad (2.1)$$

Esta condición de congestión puede ser asociada tanto a los tiempos de viaje extremo a extremo de los vehículos, como a los tiempos medios de tránsito de los enlaces de la propia red.

Los tres parámetros básicos para caracterizar la congestión de tráfico son la *intensidad*, la *extensión* y la *duración*, según el Transportation Research Board (TRB) [75]. A los parámetros indicados por el TRB, en la sección 2.2.3 añadiremos otros que estimamos necesarios para el manejo de propuestas de ITS que mitiguen la congestión.

A la hora de establecer criterios de medición viables, se suele rebajar la condición TLOC a la condición FFC, dado el alto nivel de subjetividad que el criterio de baja ocupación tiene (¿cuál es el umbral correcto? ¿es subjetivo de cada vehículo?). Así, aproximaremos $(t_{LO}^k, d_{LO}^k, v_{LO}^k) \leftarrow (t_{FF}^k, d_{FF}^k, v_{FF}^k)$.

1. Intensidad (cantidad de congestión), medible mediante varios criterios.

a) Tasa de retraso por congestión (*Congestion Delay Rate*, CDR en min/km) (2.2), diferencia entre el tiempo medio de circulación por kilómetro real y en baja ocupación.

$$CDR = \frac{\sum t^k}{\sum d^k} - \frac{\sum t_{LO}^k}{\sum d_{LO}^k} \quad (2.2)$$

b) Tiempo perdido por los vehículos (*Daily Vehicle-Hours of Delay*, DVHD) (2.3), diferencia entre los tiempos totales de tránsito reales y en baja ocupación.

$$DVHD = \sum t^k - \sum t_{LO}^k \quad (2.3)$$

c) Tiempo perdido por las personas debido a la congestión, añadiendo a DVHD la ocupación media por vehículo.

d) Índice de tiempo de viaje (*Travel Time Index*, TTI) (2.4), que compara los tiempos totales de viaje en períodos de congestión, con los tiempos totales que tendrían esos vehículos en condiciones FFC:

$$TTI = \frac{\sum t^k}{\sum t_{LO}^k} \quad (2.4)$$

- e) Penalización del tiempo de viaje (*Travel Time Tax*, TTT) (2.5), que compara los tiempos totales de viaje en períodos de congestión, con los tiempos totales que tendrían esos vehículos en condiciones FFC:

$$TTT = TTI - 1,0 \quad (2.5)$$

2. Extensión de la congestión (*Congested Area*, CA) (2.6), que cuantifica el porcentaje de red congestionada mediante el ratio de kilómetros de red que están congestionados en un área.

$$CA = \frac{\sum d_C^i}{\sum d^i}, \forall d_C^i, t^k > t_{LO}^k \quad (2.6)$$

3. Duración de la congestión, medida como la diferencia de tiempos entre la entrada y salida de las condiciones de congestión.

2.1.1. La congestión y los tiempos de viaje

La congestión tiene una relación intrínseca con los tiempos de viaje en sus diferentes escenarios, según se muestra en la Figura 2.1. Estas relaciones nos llevan a la enumeración de varios *lemas* que serán usados de forma implícita y explícita en el desarrollo de la investigación y sus propuestas.

Así podemos considerar las siguientes definiciones:

- *Tiempo de viaje ideal (Free-Flow Travel Time, T_{FF})*: tiempo de viaje que emplea un vehículo en recorrer el trayecto entre un cierto origen y destino en condiciones de red desocupada FFC (*Free-Flow Conditions*, FFC).

Lema 1. T_{FF} ofrece una cota inferior del tiempo de viaje de un desplazamiento.

Demostración. Si se considera que la red no tiene carga, es decir, todos los enlaces se pueden atravesar a su máxima velocidad, si asumimos que la función de coste de los enlaces de la red está formada por su tiempo de tránsito, cualquier algoritmo de cálculo de camino más corto (por ejemplo Dijkstra [45]), nos entregará la ruta formada por la sucesión de enlaces de menor coste.

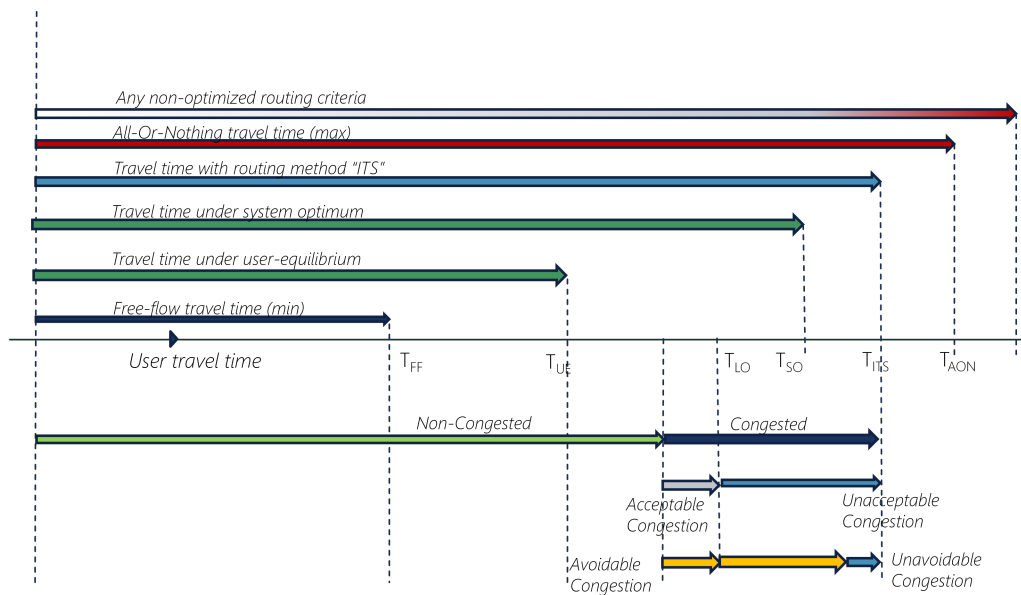


Figura 2.1.: Estimación de tiempos de viaje individuales y criterios de congestión.

T_{FF} estará formado por la suma de las duraciones de los trayectos en dichos enlaces. □

- **Tiempo de viaje todo-o-nada (All-Or-Nothing Travel Time, T_{AON}):** es el tiempo de viaje que emplearía un vehículo bajo las condiciones todo-o-nada (*All-Or-Nothing conditions*, AON), es decir, tomando sus decisiones de enrutamiento óptimo usando una red cargada sin observar el estado de la red, o sin tener en cuenta el cambio de condiciones inducido por la ocupación de la red.

Lema 2. T_{AON} ofrece una cota superior del tiempo de viaje de un desplazamiento en condiciones de enrutamiento óptimo..

Demostración. Bajo la condición AON, el vehículo toma sus decisiones de enrutamiento sobre condiciones de red ideal (FFC) sin tener en cuenta el cambio de coste de los enlaces por existir carga en la red, así asumirá que el mejor camino es aquel que «sobre el plano» es el mejor. Si encontrara una ruta más pesada que este camino óptimo ideal, dejaría de estar fuera de las condiciones de optimalidad de la hipótesis.

Obviamente, el lector puede aducir que la cota superior del tiempo de viaje puede ser infinita, sin más que el vehículo se dedique a dar vueltas. Estamos

suponiendo que, en todo momento, el conductor del vehículo tiene interés en obtener la «mejor ruta» para su desplazamiento. \square

- *Tiempo de viaje en condiciones de equilibrio del usuario (User Equilibrium Travel Time, T_{UE}):* tiempo de viaje que emplea un vehículo en recorrer el trayecto entre un cierto origen y destino en condiciones de equilibrio de usuario (*User-Equilibrium, UE*). El principio de UE considera que, en función del contexto encontrado por el usuario, éste irá cambiando su ruta hasta que no pueda ser optimizada de otra manera (comportamiento egoísta, aunque no beneficie al sistema en conjunto). Conviene recordar que este tiempo se corresponde con una situación teórica ideal.

Lema 3. El tiempo de viaje T_{UE} se encontrará entre los valores T_{FF} y T_{AON} :

$$T_{FF} \leq T_{UE} \leq T_{AON} \quad (2.7)$$

Demostración. Efectivamente, por los lemas 1 y 2. \square

- *Tiempo de viaje en condiciones de óptimo del sistema (System Optimum Travel Time, T_{SO}):* tiempo de viaje que emplea un vehículo en recorrer el trayecto entre un cierto origen y destino en condiciones de óptimo del sistema (*System Optimum, SO*). El principio de SO considera que, el sistema evolucionará en conjunto hasta que su comportamiento ofrezca un mínimo global (comportamiento macroscópico, aunque perjudique a alguno de sus miembros individualmente para ello). Conviene recordar que este tiempo se corresponde con una situación teórica ideal.

Lema 4. El tiempo de viaje T_{SO} de un vehículo será igual o superior a T_{UE} :

$$T_{UE} \leq T_{SO} \leq T_{AON} \quad (2.8)$$

Demostración. Efectivamente, por los lemas 1 y 2, y considerando que la condición de equilibrio de usuario hace que ningún vehículo pueda mejorar su ruta, no será posible encontrar ninguna ruta en condiciones de óptimo del sistema que mejore la ruta de cada vehículo en particular. \square

- *Tiempo de viaje empleando un cierto sistema de enrutamiento inteligente ITS (ITS Routing Travel Time, T_{ITS}):* tiempo de viaje que emplea un vehículo

en recorrer el trayecto entre un cierto origen y destino con la ayuda de un cierto ITS.

Lema 5. *El tiempo de viaje T_{ITS} entregado por un ITS cuyo objetivo sea la minimización del tiempo de tránsito, se encontrará entre los valores T_{UE} y T_{AON} (2.9).*

$$T_{UE} \leq T_{ITS} \leq T_{AON} \quad (2.9)$$

Demostración. Efectivamente, por los lemas 1 y 2, y considerando que la condición de equilibrio de usuario hace que ningún vehículo pueda mejorar su ruta, no será posible encontrar ninguna ruta en condiciones de óptimo del sistema que mejore la ruta de cada vehículo en particular. \square

El parámetro $OTTD_{UE}$ (*Optimal Travel Time Deviation respect UE*) (2.10) es un indicador de la desviación porcentual del tiempo de viaje individual respecto al tiempo teórico de equilibrio de usuario (no mejorable).

$$OTTD_{UE} = \frac{T_{ITS} - T_{UE}}{T_{UE}} \quad (2.10)$$

El parámetro $OTTD_{SO}$ (*Optimal Travel Time Deviation respect SO*) (2.11) es un indicador de la desviación porcentual del tiempo de viaje individual respecto al tiempo teórico obtenido para el óptimo del sistema:

$$OTTD_{SO} = \frac{T_{ITS} - T_{SO}}{T_{SO}} \quad (2.11)$$

- Tiempo de viaje en baja ocupación T_{LO} (2.12): es el tiempo de tránsito en el que el conductor es capaz de asumir la *congestión aceptable*, como cierta desviación razonable ΔT respecto al ideal T_{FF}

$$T_{LO} = T_{FF} + \Delta T \quad (2.12)$$

2.2. Enrutamiento del tráfico urbano mediante multi-mapas TWM

Todos los ITS y los propios agentes de enrutamiento individuales emplean al menos dos datos fundamentales: uno es la red de tráfico y otro es el estado del tráfico en la misma.

Respecto al estado del tráfico, se trata de un dato dinámico y en función del modelo empleado se puede cuestionar incluso su disponibilidad (véase el enrutamiento AON), ya que no podremos asegurar que todos los conductores tengan visibilidad completa del estado de toda la red.

Respecto a la red de tráfico, el conductor a la hora de planificar su ruta (estática o dinámica), el conductor emplea un mapa de la red, que no deja de ser una vista de la misma.

De la misma manera, el mapa de la red de tráfico contiene dos tipos de información (figura 2.2): a) información topológica de la red relativa a los nodos, enlaces y carriles e interconexiones; y b) información lógica de uso de la red, relativa a los sentidos del tráfico, velocidades máximas, restricciones, etc.



Figura 2.2.: Composición básica del mapa de la red de tráfico.

Para revisar la diversidad de intereses y necesidades de las flotas de vehículos, podríamos hablar de **diferentes clases de servicio de tráfico**, de forma análoga a como se plantea el tráfico en las redes de comunicaciones. Así, para las diferentes clases de servicio, podríamos establecer diferentes criterios de enrutamiento, o lo que es lo mismo, podríamos **colorear el tráfico vehicular** según dichas clases. Ahora la pregunta sería, ¿cómo gestionar dichas clases? Actualmente, dicha gestión se realiza de diferentes formas: mediante restricciones las vías (prohibido el paso a camiones de más de T toneladas, restricciones de uso de carriles, restricciones de velocidad por tipo de vehículo, etc), mediante señalización viaria dinámica (paneles), o mediante alertas radio, pero estos mecanismos son apenas flexibles y adaptables, siendo reemplazados por mecanismos basados en sistemas de alerta y navegación en tiempo real.

Considerando las diferentes clases de servicio y la necesidad de generar variedad en las rutas que siguen los vehículos, se podría realizar un enrutamiento diferencial usando para ello diferentes variaciones del mapa de la red de tráfico. Estos mapas serían idénticos en la topología física pero variando la capa lógica adecuándola a las diferentes casuísticas y flotas, según se ilustra en la figura 2.3. El desarrollo de esta estrategia de enrutamiento es original en la tesis partiendo de algunos desarrollos experimentales previos encaminados a la simulación microscópica [5], habiéndose denominado **enrutamiento por multi-mapas de tráfico** (*Traffic Weighted Multi-Maps*, TWM).

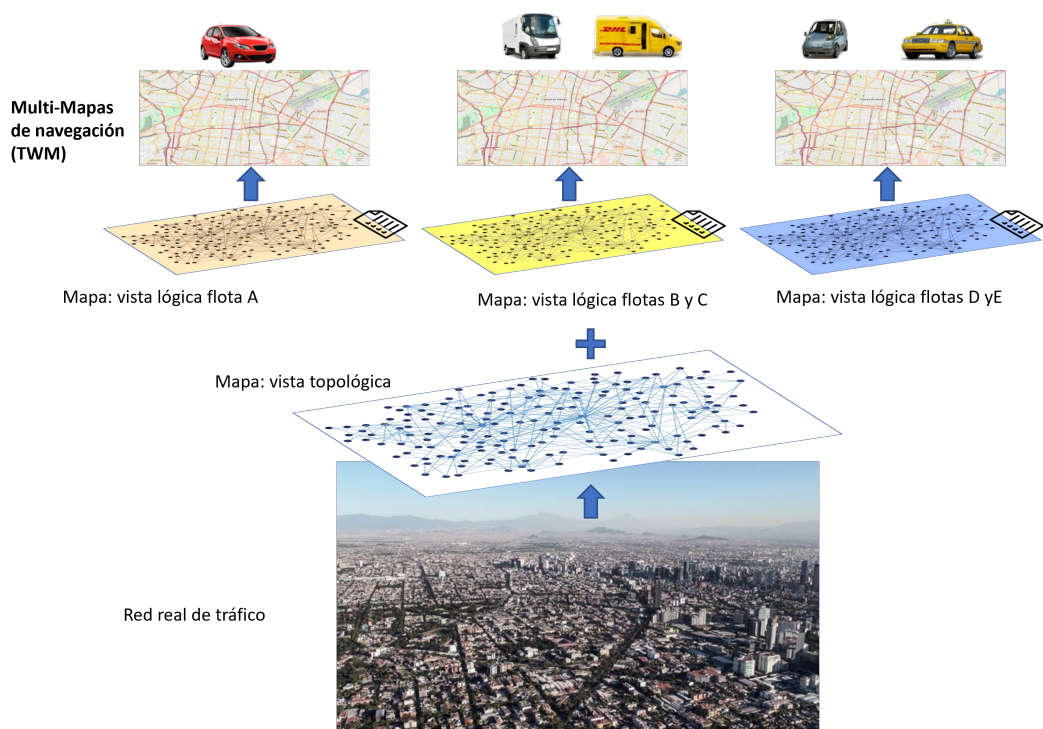


Figura 2.3.: Multi-mapas de la red de tráfico.

La generación de la capa lógica de los mapas se realiza modificando los pesos de los enlaces mediante funciones de coste que respondan a diferentes casos de uso. Dado que todos los ITS y sistema de navegación individuales emplean mapas de la red de tráfico, esta técnica TWM puede ser fácilmente implementada en los propios sistemas servidores de mapas que alimentan dichos elementos.

2.2.1. Asignación de tráfico mediante multi-mapas TWM

El uso de TWM conlleva una fase adicional en el modelo de cuatro fases de planificación del transporte, entre la distribución inter-modal del tráfico y la asignación de rutas (figura 2.4). Esta fase TWM está compuesta por las siguientes sub-etapas:

1. Generación de los mapas TWM, dedicada a la creación de la distribución necesaria de mapas para las configuraciones de red y demanda.

2. Asignación de los mapas TWM a los diferentes vehículos de la demanda de tráfico según los criterios objetivo y el caso de uso objetivo.
3. Distribución de los mapas TWM a los vehículos .
4. Aplicación del modelo de adherencia y uso por parte de los conductores, teniendo en cuenta los principios de equilibrio SUE y BRUE (decisión estocástica y racionalidad limitada) por los que los vehículos toman sus decisiones de uso (o no) de las recomendaciones efectuadas.

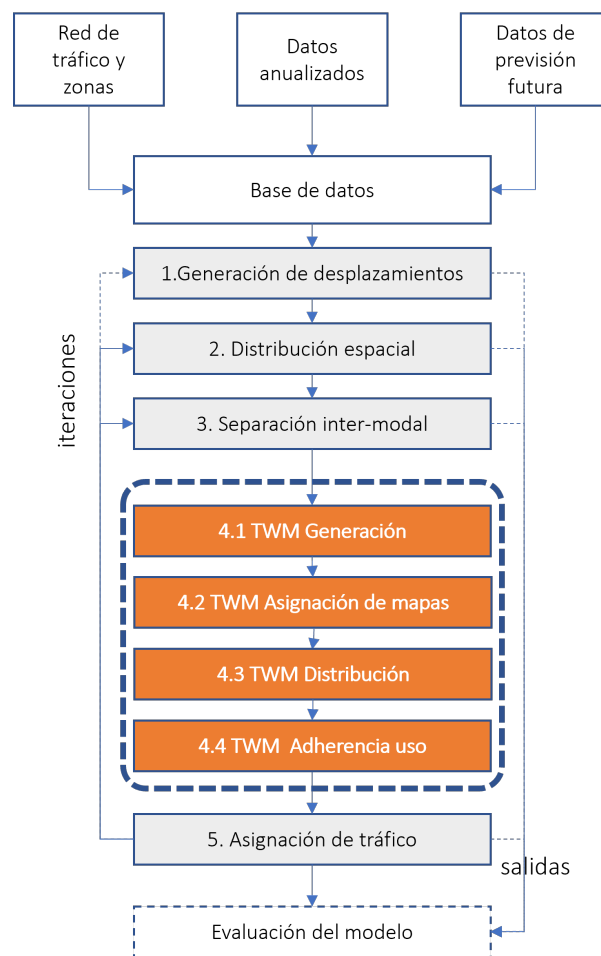


Figura 2.4.: Inclusión de TWM en el modelo de planificación del transporte.

Como podemos comprobar, la inclusión de TWM en el modelo de 4 etapas nos permite aplicar los mismos criterios de equilibrio de los conductores y por tanto las funciones de cálculo de ocupación de los enlaces VDF descritas en la sección 1.1.3.

El uso de TWMM no debe entenderse en términos estáticos, ya que los mapas pueden ser generados y distribuidos de forma dinámica a los diferentes elementos que conforman la red de tráfico, en función de las diferentes condiciones del tráfico. La etapa inicial del modelo de planificación nos permite la definición de diferentes conjuntos de mapas para los distintos escenarios y momentos temporales, que pueden ser distribuidos de forma selectiva a los vehículos en función del estado de la propia red. De la misma manera, los mapas pueden ser generados ad-hoc en tiempo real para tener respuesta a los diferentes escenarios de tráfico.

Atendiendo a los distintos niveles de adherencia de los vehículos a TWMM, la propia variación de las rutas seleccionadas por los vehículos que adoptan el sistema hará que se descongestionen parcialmente las rutas que usan el resto de vehículos no usuarios. Este es el denominado *efecto de la liberación de rutas*.

Una **función de generación/asignación** de multi-mapas Π (2.13) toma como entrada la representación topológica de una red de tráfico Θ , una serie de agrupaciones de vehículos usuarios denominados *flotas* $[\Omega_k]$, un conjunto de restricciones temporales $\Gamma_{k,m}$ y una descripción de la demanda de tráfico Φ en el tiempo, para obtener una serie de vistas de dicha red (mapas) $[\mu_{k,m}]$. La vista física de la red la denominaremos μ_0 .

$$\Pi : \Theta, [\Omega_k], [\Gamma_{k,m}], \Phi \rightarrow [\mu_{k,m}] \quad (2.13)$$

Así, cada agrupación de tráfico Ω_k podrá disponer de un conjunto específico de mapas $[\mu_{k,m}]$ representando la red de tráfico Θ , para ser empleados bajo ciertas restricciones temporales $[\Gamma_{k,m}]$, que pueden ser planificadas o eventuales.

La red urbana de tráfico Θ (2.14) se representa mediante un grafo dirigido de nodos $[\eta_m]$ conectados por enlaces $[\epsilon_{i,j}]$, que representan los caminos físicos unidireccionales de los vehículos (calle, carreteras, etc) y los nodos representan las intersecciones, conexiones y cruces.

$$\Theta = \{[\eta_m], [\epsilon_{i,j}]\} \quad (2.14)$$

El enlace $\epsilon_{i,j}$ conecta los nodos η_i y η_j siendo caracterizado principalmente por su longitud $d_{i,j}$, su velocidad máxima $v_{i,j}$ y su capacidad $c_{i,j}$, siendo la capacidad del nodo una variable adimensional que indica la cantidad de tráfico que puede soportar. Habitualmente esta capacidad está tabulada en función del tipo de vía. Ya hemos visto en la sección 1.1.3 las funciones de cálculo de coste del enlace que nos entregan un valor del coste $\beta_{i,j}^{k,m}$ de usar dicho enlace que denominaremos *peso del enlace*. Así, en todo momento el enlace quedará caracterizado por (2.15):

$$\epsilon_{i,j} = (\eta_i, \eta_j, \beta_{i,j}^{k,m}) \quad (2.15)$$

Cada mapa $\mu_{k,m}$ perteneciente al TWM será el conjunto de pesos $[\beta_{i,j}^{k,m}]$ correspondiente a los enlaces $[\epsilon_{i,j}]$ de la red, obtenido mediante la función de cálculo Π . Estas funciones de cálculo se deben diseñar acorde a los casos de uso que se deban resolver, sean de optimización, de aplicación de políticas, de respuesta a eventos, etc.

En la figura 2.5 se ilustra el funcionamiento general de la asignación de mapas TWM mediante la suite de herramientas MuTraff desarrolladas en la tesis:

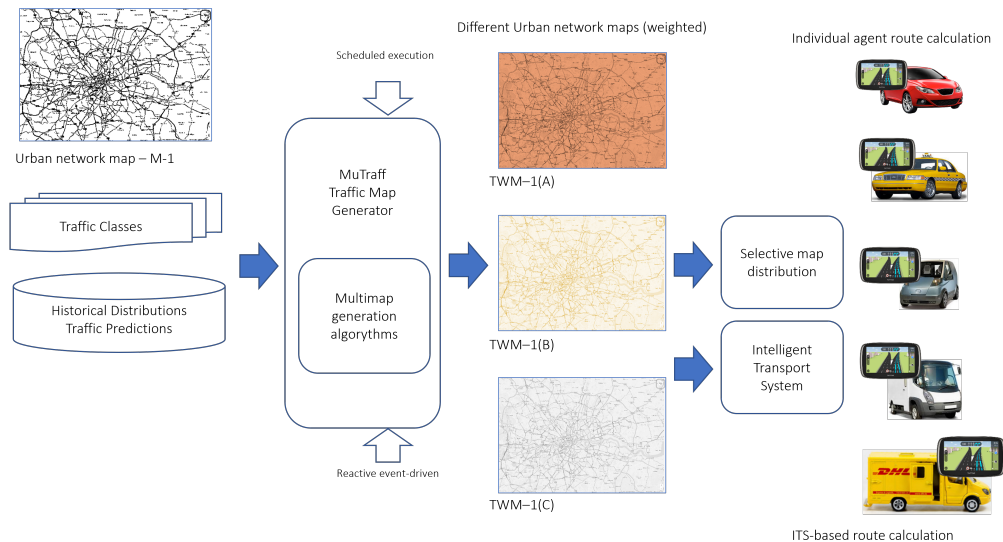


Figura 2.5.: Diagrama general de funcionamiento de MuTraff para TWM.

2.2.2. Casos de uso de TWM

TWM permite su aplicación a diferentes casos de uso entre los que podemos encontrar:

- **Reducción de la congestión**, mediante la generación de mapas con diferentes pesos aleatorizados que provoquen la variedad de rutas necesarias para los conductores.
- **Reducción de las emisiones urbanas**, aplicando diferentes pesos a los enlaces de los mapas en función de las zonas con mayor o menor densidad de contaminación y capacidad de renovación del aire.
- **Enrutamiento diferencial por flotas**, promocionando áreas geográficas específicas para los diferentes conjuntos de vehículos, por ejemplo, incentivando áreas de tráfico preferente para vehículos eléctricos frente a vehículos contaminantes.
- **Enrutamiento diferencial por ventanas temporales**, incentivando o penalizando la circulación del tráfico de reparto comercial o de acceso a centros escolares en ciertos horarios de la semana.
- **Zonas restringidas o desincentivadas de tráfico**, por ejemplo para zonas reservadas a ciertos tráficos, para zonas desincentivadas o incentivadas.
- **Generación de corredores ad-hoc liberados de tráfico**, por ejemplo para sistemas de evacuación o de flujos incentivados.
- **Respuesta a eventos planificados en la red**, generando mapas que desincentiven la circulación en áreas afectadas por eventos tales como eventos deportivos, culturales, sociales, etc.
- **Respuesta a incidentes no planificados** en la red tales como accidentes, eventos meteorológicos o similares.

Evidentemente, podrán encontrarse nuevos escenarios a los que esta técnica podría ser empleada dado su carácter generalista. En la presente tesis, nos

limitaremos a algunos de los casos de uso descritos dada la alta aplicabilidad del modelo.

2.2.3. Indicadores de medición de efectividad del ITS (TWM)

En este apartado comentaremos los diferentes indicadores considerados para analizar la efectividad de un ITS, particularizados al caso de TWM (adicionales a los descritos en la sección 2.1. A la hora de analizar los resultados aportados por TWM es preciso distinguir entre los estadísticos globales de la red, que nos darán una medida general de su comportamiento, de los estadísticos individuales (*paired stats*) que son los que nos darán la visión microscópica del impacto de la propuesta. La importancia de esta visión radica en la importancia de la adherencia al ITS por parte de los conductores. Ésta adherencia evoluciona en el tiempo en base a las tomas de decisiones de los conductores que en gran medida se fundamentan en experiencias individuales de los conductores, convirtiéndoles en promotores o detractores del sistema. Por este motivo los estadísticos individualizados son de máximo interés.

Al analizar la efectividad de un ITS, consideraremos estadísticos asociados a períodos temporales acotados ya que, por ejemplo, en situaciones de congestión se deben considerar las demanda de tráfico completadas y las que están pendientes de completarse.

Indicadores globales^{1,2}

1. **Velocidad media en la red, MS** (*Mean Speed*), velocidad media de los vehículos en la red.
2. **Adherencia / Adopción al ITS, ψ** (*ITS Adherence*), porcentaje de vehículos de la demanda total que emplean el ITS (TWM) en el período considerado.

¹Marcamos con * aquellos que pueden aplicarse igualmente a la red o a sus enlaces de forma individual.

²En la aproximación de TLOC a FFC, usaremos un cierto umbral Δ_{TLOC} que aproximaremos al 10 % por simplificación: $\Delta_{TLOC} = 0,1$.

3. **Tiempo Total de Transito/Viaje**, TTS^t (*Total travel time*), tiempo total invertido por los vehículos en la red de tráfico. En los modelos de asignación estática, este valor se corresponde con tiempos totales de viaje, pero en modelos de tiempo acotados, este tiempo incluye también los tiempos de los vehículos que todavía están en tránsito al terminar el período de estudio. Esta última característica sólo puede ser estudiada en simulaciones microscópicas. Este parámetro se usa habitualmente para evaluar la asignación de tráfico y comparar los diferentes modelos de asignación.
4. **Tiempo Total de Congestión**, THS^t (*Total Halting Time (Congestion Time, Waiting time)* (*)), suma de los tiempos totales de paradas de los vehículos en la red (por debajo de cierta velocidad mínima, aproximando TLOC).
5. **Tráfico cursado**, DTD^t (*Dispatched Traffic Demand*), porcentaje de vehículos que completan su trayecto en el período considerado frente al total de demanda de tráfico planteada a la red.
6. **Tráfico cursado usuario de TWM**, DTD_{TWM} (*Dispatched Traffic Demand by the ITS*), porcentaje de vehículos que usan el ITS (TWM) y completan su trayecto en el período considerado frente al total de demanda de tráfico planteada a la red.

$$DTD^t = \sum DTD_i \quad (2.16)$$

7. **Tráfico Congestionado**, NHD^t , (*Number of Halted Demand (vehicles)* (*)), como la suma de vehículos detenidos en los enlaces la red.
8. **Ratio de enlaces congestionados**, NHL (*Number of Halted Links*), como el ratio entre número de enlaces de la red congestionados frente al total.
9. **Distancia Total Recorrida**, VKT, VMT^t (*Total Distance Traveled*) suma de la distancia total recorrida por los vehículos en la red, tanto los que completaron el trayecto como los que aún no lo han hecho.
10. **Distancia Promedio Recorrida por vehículo**, $AVKT, AVMT^t$ (*average VKT/VMT*), como la división del total de distancia recorrida entre el número de vehículos.

Otros muchos parámetros pueden ser considerados aunque no los tendremos en cuenta en la tesis:

- *Métricas de tráfico por enlace* (*): volumen medio de vehículos por kilómetro de enlace, velocidad media efectiva en los enlaces, ocupación de los enlaces, etc. [37, 94, 113, 66]
- *Gas Emissions* (*): emisiones de CO, CO₂, HC, PM_x, NO_x de los vehículos. [68, 51, 73, 90, 116]
- *Consumption* (*): combustibles, electricidad.[51, 88]
- *Noise emissions* (*).

Indicadores individuales

- **Ratio de mejora individual en el tiempo de tránsito usando ITS**, TTC_{rel}^k (*Individual relative travel time change*) porcentaje de mejora en el tiempo de tránsito individual del vehículo que usa el ITS (TWM) respecto al tiempo originalmente previsto en congestión.
- **Ratio de mejora individual en la distancia recorrida usando ITS**, RLC_{rel}^k (*Individual route length relative change*) porcentaje de mejora en la distancia recorrida individualmente por el vehículo que usa el ITS (TWM) respecto a la ruta de camino más corto bajo condiciones AON.
- **Ratio de mejora individual en el consumo individual usando ITS**, FCC_{rel}^k : en combustibles o electricidad.

En general, estos ratios pueden agregarse bajo una única función de coste asignando pesos a cada parámetro, pero el interés que tienen en su gestión desagregada es el impacto que tienen por separado en los criterios de toma de decisión que afectan a la adherencia, como veremos en la sección 2.7.2.

2.3. Asignación dinámica de tráfico mediante TWM aleatorizados

Una de las características fundamentales del enrutamiento de tráfico urbano para minimizar la congestión es el uso de rutas alternativas a las rutas de coste mínimo ofrecidas por la vista física de la red (diversificación de rutas). En la sección 1.1.4 ya hemos visto cómo los mecanismos de asignación estática de tráfico permiten hacer aproximaciones a las distribuciones óptimas de tráfico, cuando las demandas de tráfico son conocidas de antemano. De igual manera, existen diversos métodos para realizar asignación dinámica de tráfico cuando se conocen dichas demandas en el tiempo y se conoce en todo momento todo el estado de la red.

Sin embargo, TWM ofrece la posibilidad de generar múltiples trayectos diferenciales y de generar diversidad de caminos sin conocer ni la demanda a priori, ni el estado en tiempo real de la red. Esto se consigue generando mapas aleatorizados que se asignan a las diferentes flotas $[\Omega_k]$.

La función más trivial de generación de pesos es Π_{std} (2.17) que realiza una transformación estrictamente lineal sobre los enlaces seleccionados, añadiendo un sobre coste fijo k_2 a un escalado con factor k_1 al peso original:

$$\Pi_{std} : [\epsilon_{i,j}], [\Omega_k], [\Gamma_{k,m}] \rightarrow [\mu_{k,m}] | \beta_{i,j}^{k,m} = k_1 * S_{i,j} + k_2 \quad (2.17)$$

La aleatorización de los pesos de los enlaces propuesta inicialmente se consigue añadiendo un factor aleatorio δ obtenido de las funciones de distribución normal y uniforme $\delta_{normal} = normal(a, b)$:

$$\Pi_{\delta} : [\epsilon_{i,j}], [\Omega_k], [\Gamma_{k,m}] \rightarrow [\mu_{k,m}] | \beta_{i,j}^{k,m} = k_1 * S_{i,j} * (1 + \delta) + k_2 \quad (2.18)$$

Este planteamiento genera la diversidad de caminos necesaria para que los vehículos obtengan diferentes rutas de mínimo en base a la vista que obtienen de la red. Esta aleatorización permite que el tráfico se distribuya entre los enlaces de la red.

Las estrategias de mapas TWM aleatorios que se han empleado se caracterizan por los siguientes parámetros:

- Número de mapas empleados (1,2,4,8,16, etc).
- Procedimiento y función de aleatorización de los pesos de los enlaces, más los parámetros específicos de cada función.
- Procedimiento de distribución de los mapas: asignación fija, aleatoria, FIFO, etc.

Los experimentos de simulación de los mapas aleatorios se han realizado sobre los escenarios sintéticos Grid64, Grid256 y Radial241, así como el escenario urbano real de la ciudad de Alcalá de Henares, todos ellos descritos en el apéndice A.

Para analizar los efectos de TWM con mapas aleatorios nos centramos en el experimento de la red real de Alcalá de Henares con simulación microscópica descrito en el apéndice A, con 16-TWM, generación de mapas con aleatorización uniforme y distribución aleatoria. Si nos fijamos en los indicadores globales recogidos en las figuras 2.6, 2.7 y 2.8, vemos cómo todos los parámetros globales se ven mejorados, siendo mayor la mejora conforme mayor es el número de vehículos que adopta el sistema.

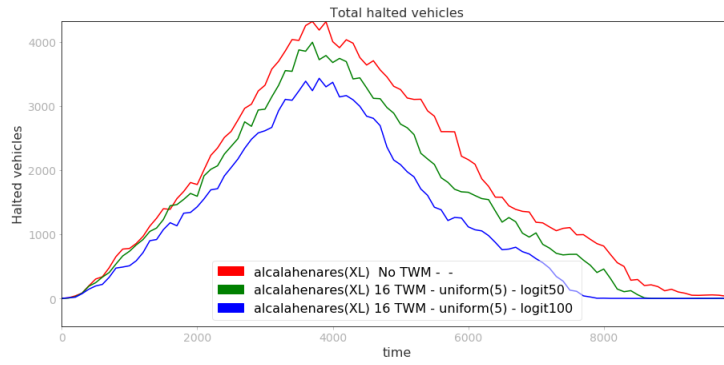


Figura 2.6.: Alcalá de Henares. Indicador de congestión NHD.

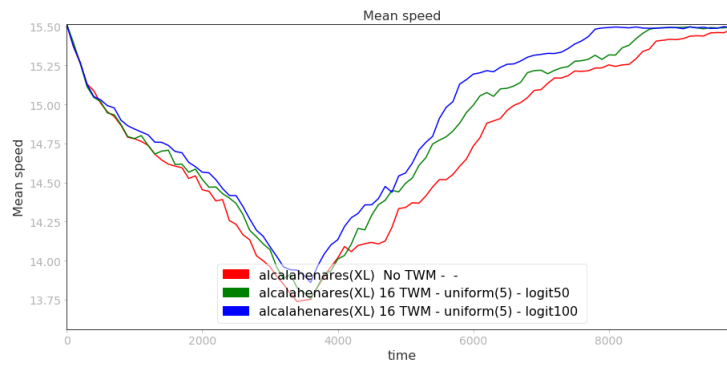


Figura 2.7.: Alcalá de Henares. Indicador de congestión MS.

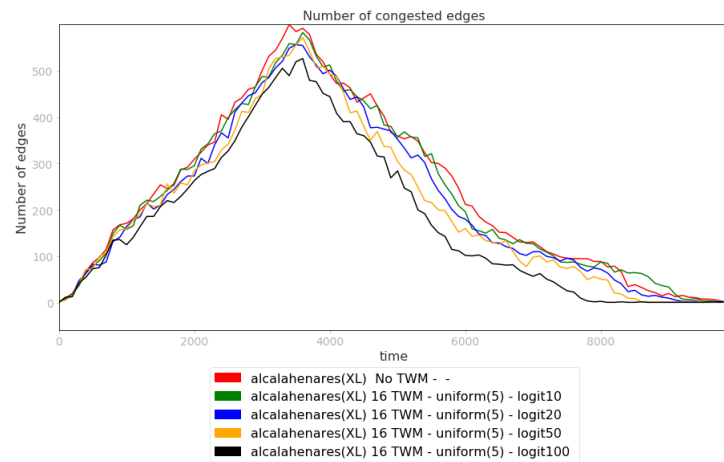


Figura 2.8.: Alcalá de Henares. Indicador de congestión NHL.

En las figuras se pueden observar la mejora de todos los índices de congestión conforme la adherencia al uso del sistema se incrementa.

Respecto al análisis de los indicadores individuales, en la figura 2.9 se muestran los histogramas de distribución de la duración de tiempos de viaje para el experimento de tráfico urbano de Alcalá de Henares descrito en el apéndice A. El primero muestra la comparativa absoluta de la mejora entre los trayectos sin usar TWM y los mismos trayectos usando TWM (pesos aleatorizados, distribución aleatoria, 16 mapas). Dado que los vehículos tienen distintos trayectos y duraciones de viaje por tanto, en la ventaja de uso de TWM vendrá dada en función de dichas duraciones. Por este motivo, al analizar la variación porcentual individual sobre los tiempos de viaje, encontramos que:

1. Una parte importante de los vehículos apenas ha sido afectado por la aplicación de TWM (distribución alrededor del valor 0, que indica ni pérdida ni ganancia con cierto valor de tolerancia).
2. Sin embargo el lado derecho de la gráfica muestra cómo un porcentaje muy alto de los conductores ha mejorado su experiencia de forma muy significativa, con un máximo alrededor del 20 %, y con fuertes frecuencias de mejora que llegan hasta el 200 % de mejora de tiempo de viaje. Este grupo conforma el bloque de los promotores del sistema.
3. Un porcentaje pequeño pero no desdeñable de conductores (lado izquierdo) está siendo penalizado en sus rutas, debido a la desviación del tráfico desde las rutas más cargadas. Este grupo conformará el bloque de los detractores del sistema. Este efecto se denomina **efecto de las rutas injustas** (*route unfairness effect*, RU) que se detallará en la sección 2.6.2, pero que ya anticipamos que es inherente a cualquier sistema orientado al SO y ha sido descrito en numerosos trabajos [11, 108].




Figura 2.9.: Alcalá de Henares. Mejora individual relativa de los tiempos de viaje empleando TWM.




Figura 2.10.: Alcalá de Henares. Histograma comparativo de tiempos de viaje empleando TWM.

En la figura 2.10 se muestran los histogramas de los tiempos de viaje individuales junto a sus valores de media y mediana (tabla 2.3) que muestran la mejora individual en los tiempos de viaje comentados empleando la configuración TWM descrita. El empleo de mapas aleatorizados aplicados a una red real, en este escenario mejora hasta un 35 % la congestión total.

16 maps - uniform05		No TWM	10 %	20 %	50 %	100 %
Traffic	Demand	18694	18694	18694	18694	18694
	Using TWM	0	1846	3731	9385	18694
	Routed	17895	17667	18067	18042	18447
	% Routed, DTD	-	-1.27 %	0.96 %	0.9 %	3,08 %
Travel time TT	Mean		-3.41 %	-4.75 %	-9.17 %	-19.60 %
	Median		-2.93 %	-7.25 %	-21.28 %	-34.70 %
Route Length RL	Mean		1.10 %	0.73 %	1.59 %	1.90 %
	Median		0.00 %	0.00 %	2.27 %	2.27 %

Tabla 2.3.: Alcalá de Henares, impacto de TWM para distintas adherencias

2.3.1. Impacto de la adherencia al uso de TWM

En [41, 62, 126] ya se describió el carácter subjetivo de la toma de decisión y de seguimiento de las recomendaciones de enrutamiento de tráfico plasmados en los principios SUE y BRUE. Así, se puede esperar que solo un cierto porcentaje de conductores empleen el sistema TWM, lo cual reducirá la efectividad del sistema. Sin embargo, el uso parcial de los ITS por parte de la población de los conductores contribuye a la mejora de todos ellos. Este es el *efecto de la liberación de rutas* por el los conductores adheridos a TWM liberan las rutas congestionadas, facilitando al resto de vehículos su conducción en sus rutas habituales. Adicionalmente, conforme se incrementa hasta el 100 % la adherencia, se corre el riesgo de saturar las vías alternativas.

Los efectos de la aplicación de TWM para minimizar la congestión se pueden observar en la distribución de probabilidad acumulada de la mejora relativa de tiempos de viaje, como la mostrada en la figura 2.11 para el escenario urbano de Alcalá de Henares mostrado en el apéndice A. Podemos observar cómo en bajos niveles de adopción la mejora apreciada crece lentamente, mientras que la probabilidad de mejora se incrementa de forma muy sensible para el escenario de alta adherencia. La evolución de la adopción de TWM (y en general de un ITS) sigue un patrón no-lineal.




Figura 2.11.: Alcalá de Henares. Distribución de probabilidad acumulada al aplicar TWM.

2.4. Aplicación de TWM a gestión de incidentes en la red de tráfico

Otro de los casos de uso identificados para la aplicación de TWM es la resolución de la congestión asociada a incidentes en la red de tráfico, bien sean planificados o aleatorios. En este caso de uso se generan mapas TWM ad-hoc que son distribuidos en tiempo real a todos los vehículos desincentivando la zona afectada por el incidente durante un cierto período de tiempo (planificado o estimado), tras el cual se restauran las distribuciones de mapas habituales. En la figura 2.12 se muestra el modelo de gestión de la aplicación de TWM a la gestión de incidentes:

1. Detección del incidente y ubicación del mismo.
2. Determinación de la zona de impacto del incidente para aplicar TWM: identificación de los nodos y enlaces afectados, así como establecimiento del perímetro de actuación. Estimación de la duración de la gestión ad-hoc.
3. Generación de mapas TWM ad-hoc para la demanda de vehículos que desincentiven la circulación por la zona de influencia afectada durante el período de tiempo estimado.

4. Asignación de los mapas a los vehículos. Esta etapa permite gestionar de forma selectiva por clases de servicio (por ejemplo, permitiendo vehículos de servicio público pero desincentivando los privados).
5. Distribución de los mapas.
6. Generación de los modelos de adherencia, ya que no todos los vehículos son usuarios de TWM o hacen efectivas sus recomendaciones.
7. Enrutamiento y asignación del tráfico.
8. Monitorización del estado del tráfico, por si es preciso revisar o rediseñar las zonas o tiempos de impacto para generar los correspondientes mapas TWM.
9. Restauración de los mapas TWM de funcionamiento normal.

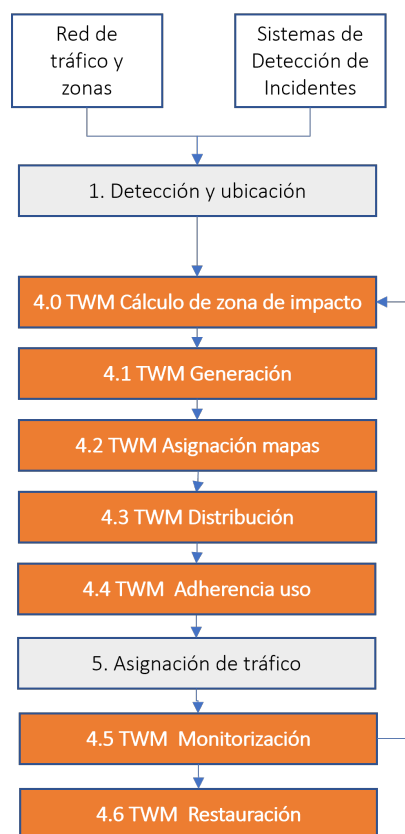


Figura 2.12.: Modelo de gestión de incidentes TWM

El modelo de gestión de incidentes con TWM requiere establecer una política de penalización de áreas entre las que podemos encontrar:

- **Penalización lineal**, aplicando un sobrecoste con una función lineal $\beta_{i,j}^{k,m} = a + b * S_{i,j}$ a todos los enlaces que conectan los nodos a distancia R_x de la zona de incidente.
- **Penalización aleatoria**, aplicando un sobrecoste aleatorio (uniforme, normal, gaussiano, etc) a todos los enlaces que conectan los nodos a distancia R_x de la zona de incidente.
- **Penalización diana**, aplicando un sobrecoste gradual por anillos (diana) fijo a todos los enlaces que conectan los nodos a distancia R_x de la zona de incidente.

La figura 2.13 muestra un escenario de incidente para el entorno urbano Alcalá de Henares descrito en el apéndice A, junto a la configuración del TWM y el generador de mapas *mutraff_mapgen* para una penalización lineal.

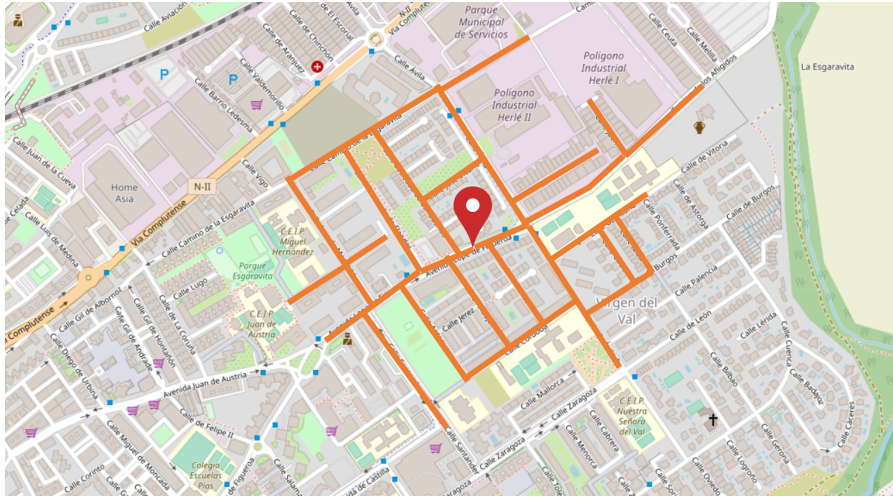


Figura 2.13.: Alcalá de Henares: incidente temporal y radio de impacto $R_x = 5$ para TWM

```
<?xml version="1.0" encoding="UTF-8"?>

<maps>
  <map tag="car" prob="1" file="alcalahenares.taz5-taz508.incident3x1.join_map_1.xml" />
  <map tag="taxi" prob="1" file="alcalahenares.taz5-taz508.incident3x1.join_map_1.xml" />
  <map tag="motorcycle" prob="1" file="alcalahenares.taz5-taz508.incident3x1.join_map_1.xml" />
  <map tag="bus" prob="1" file="alcalahenares.reference.mapR.xml" />
</maps>
```

Figura 2.14.: Alcalá de Henares. Estructura TWM para gestión del incidente

```
<?xml version="1.0" encoding="UTF-8"?>

<config>
  <gmb>
    <mode value="penalty"/>
    <net_file value="xml_maps/alcalahenares.net.xml"/>
    <output_prefix value="map.alcalahenares.taz5-taz508.incident3x1"/>
    <output_dir value="./alcalahenares.maps"/>
    <!-- <weight_factor value="abs(1+numpy.random.uniform(0, 5))"/> -->
    <weight_factor value="5"/>
    <weight_add value="20"/>
    <num_maps value="1"/>
    <begin value="0"/>
    <end value="10000"/>
    <join_map value="alcalahenares.maps/map.alcalahenares.reference.mapR.xml"/>
    <join_option value="max"/>
    <!-- Set incident point in the highest occupancy edges -->
    <pen_edges value="151292453#1"/>
    <pen_edges_steps value="5"/>
  </gmb>
</config>
```

Figura 2.15.: Alcalá de Henares. Configuración *mutraff_mapgen* para la gestión del incidente

Los resultados obtenidos se puede observar en las figuras 2.16, 2.17, 2.18, 2.19 que reflejan el estado del tráfico (congestión) antes de la aplicación de TWM y posteriormente a su aplicación para diferentes niveles de adherencia de los conductores.




Figura 2.16.: Alcalá de Henares. Congestión tras incidente. NHD.

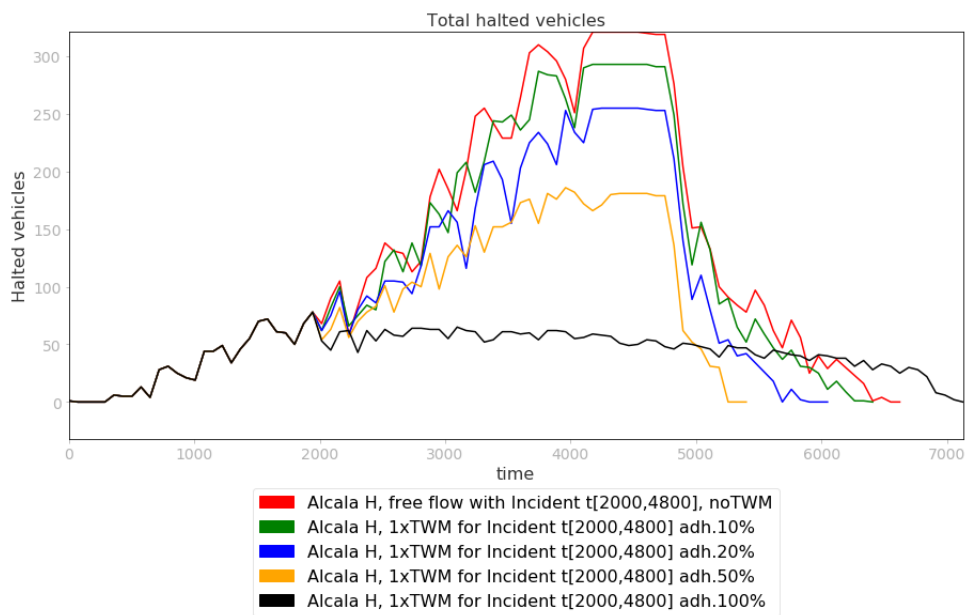


Figura 2.17.: Alcalá de Henares. Gestión de incidentes. Congestión. NHD.

En las figuras se pueden observar la mejora de todos los índices de congestión conforme la adherencia al uso del sistema se incrementa.

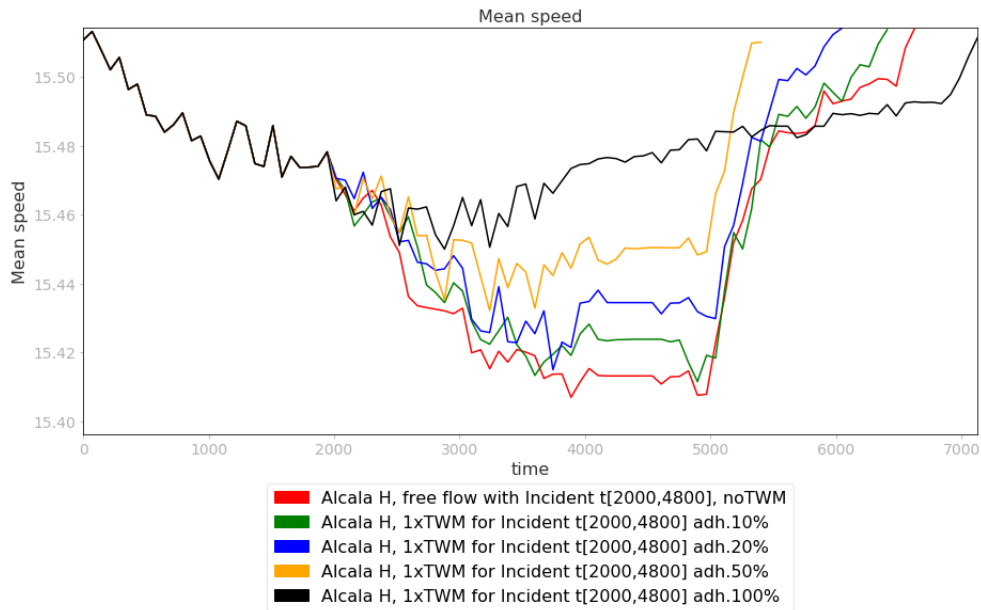


Figura 2.18.: Alcalá de Henares. Gestión de incidentes. Congestión. MS.

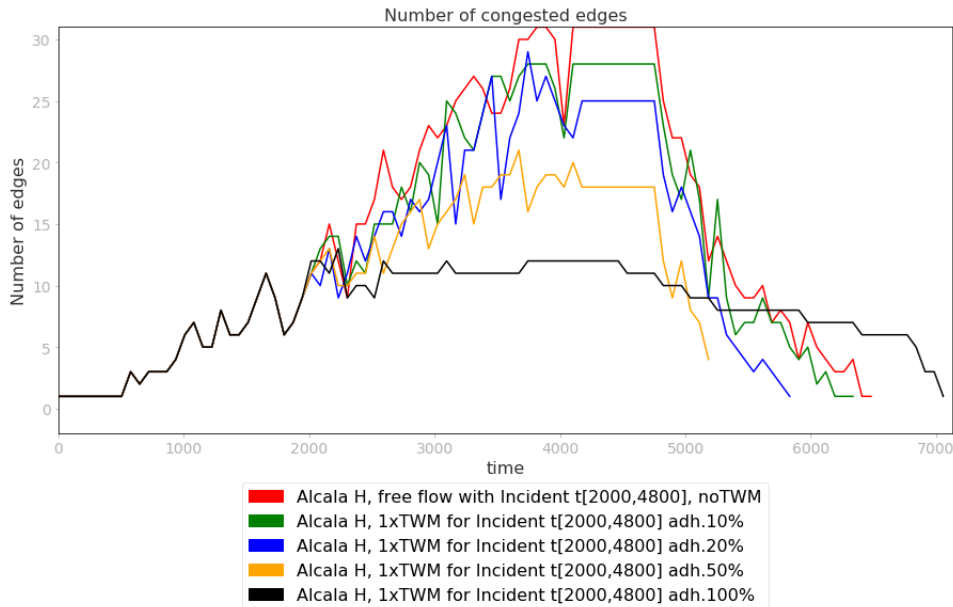


Figura 2.19.: Alcalá de Henares. Gestión de incidentes. Congestión. NHL.

En la figura 2.20 se muestra asimismo la función de distribución de probabilidad de mejora de tiempo de viaje acumulada, al aplicar TWM a la gestión de incidentes para diferentes niveles de adherencia de los vehículos, en la que podemos observar cómo al aplicar el mapa, aumenta enormemente la probabilidad de mejora del tiempo de viaje.

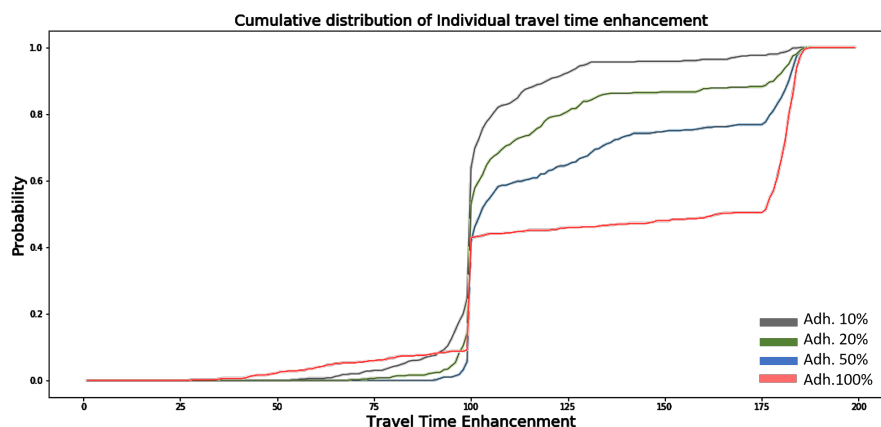


Figura 2.20.: Alcalá de Henares. Distribución de probabilidad acumulada en la gestión del incidente con TWM.

2.5. Diseño de multi-mapas TWM óptimos

La complejidad de encontrar la distribución óptima de mapas de pesos TWM es similar a la de resolución del problema de asignación del tráfico (TAP). Por ello es preciso acudir a algoritmos heurísticos que busquen soluciones aproximadas al problema con un cierto grado de precisión. Se han analizado dos conjuntos de algoritmos, uno basado en *Particle Swarm* (o análisis por bandada) [129] y otro basado en *algoritmos genéticos (GA)*. En el primer caso, la complejidad del problema hacía que los tiempos de convergencia del algoritmo fueran muy largos en los experimentos realizados, por lo que finalmente se ha optado por los genéticos, quienes han sido objeto de publicación.

En el caso de los algoritmos GA, se analizan de forma iterativa diferentes conjuntos posibles de soluciones (población) que difieren entre sí por los elementos que las componen. Estos elementos se agrupan en forma de cromosoma, y la variedad en dichos elementos se produce mediante operadores de evolución: mutación, selección y entrecruzamiento [84]. En cada iteración (generación) se evalúan las soluciones objetivo, se descartan ciertos individuos y se generan nuevos que responden mejor a la función de evaluación. El algoritmo termina según diversos criterios posibles: cuando se encuentra una solución razonable al problema (no se puede mejorar más de un cierto umbral), por número máximo de generaciones o por tiempo.

En el caso concreto de la optimización de TWM hay dos elementos principales: la composición del cromosoma y la función de evaluación de las soluciones. Para la confección del cromosoma se han evaluado dos posibles aproximaciones, una enfocada hacia la etapa de generación del TWM y otra enfocada hacia la etapa de distribución de los mapas:

1. **Estrategias de generación de mapas: codificación de pesos de los mapas:** dados ciertos flujos de tráfico en una red, obtener la codificación óptima de los pesos de los mapas que minimizan la función objetivo. El cromosoma estará formado por los pesos de los enlaces para los diferentes mapas.
2. **Estrategias de distribución de mapas: codificación de la distribución de flujos:** dada una cierta distribución de mapas, obtener la distribución de flujos óptima. El cromosoma estará formado por las distribuciones de los flujos a los mapas. Los mapas a emplear pueden ser: aleatorios, o basado en los K *shortest-paths* u otros criterios.

Se ha optado por emplear el primer modelo dado que responde mejor a la filosofía objetivo de TWM. El modelo de flujos es similar en conceptualización al modelo de optimización de K *shortest-paths* descrito en [14]. La estrategia de codificación de flujos será objeto de futuros análisis.

Para la función de evaluación de una demanda de tráfico para una asignación concreta de mapas podemos emplear las funciones de asignación estática de tráfico descritas en la sección 1.1.4. Podemos usar el método AON (asignación de peor caso) puesto que nuestros vehículos no usarán el mismo mapa todos ellos, sino su mejor mapa posible. Así en cada iteración del algoritmo se generarán las poblaciones con las distribuciones de mapas TWM, se distribuirán a los individuos y se evaluará el objetivo global.

El objetivo global evaluado es el TTS, el tiempo global de viaje, como medidor del nivel de congestión, aunque es claro que se pueden evaluar otros indicadores ya descritos en la sección 2.1 o combinaciones multi-criterio.

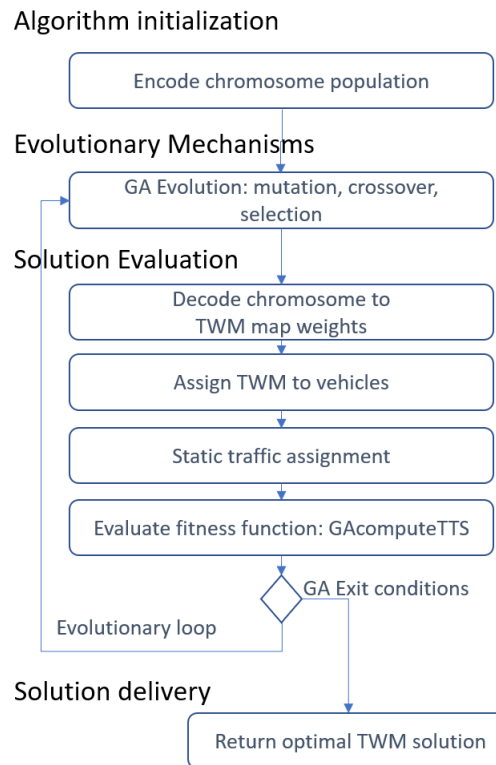


Figura 2.21.: Algoritmo genético empleado en B-TWM, FP-TWM y EFP-TWM

En la figura 2.21 se muestra el esquema común de dichos algoritmos: se confeccionan los cromosomas con las distribuciones de pesos aplicando los operadores evolutivos, se distribuye el cromosoma a los mapas TWM, se realiza la asignación de mapas, se realiza la asignación de tráfico correspondiente y se evalúa la función objetivo. Esta situación se repite hasta encontrar la distribución óptima de pesos. Aunque los vehículos emplean su mapa-vista de la red para diseñar sus rutas, el cálculo de la asignación se realiza sobre la vista física de la red.

En todas las asignaciones de tráfico se ha usado la función VDF descrita por el BPR en la ecuación 1.3 para la estimación de los tiempos de viaje en los enlaces.

Los diferentes algoritmos de optimización sobre GA variarán inicialmente en la confección del cromosoma y su asignación a los mapas TWM. Para la asociación del cromosoma al TWM se emplearán funciones de codificación/decodificación entre ellos.

Emplearemos la nomenclatura AAA-M-K-D, donde AAA indica el algoritmo, M indica el número de mapas que componen el TWM, K indica el número de *shortest-paths* a usar, y D indica la distancia a los nodos del *shortest-path*.

2.5.1. Algoritmo de optimización B-TWM

En el algoritmo B-TWM (TWM básico) el cromosoma está compuesto por la linealización de los pesos de los enlaces tal y como se muestra en la figura 2.22.

Para la función de codificación del cromosoma desde el TWM, los enlaces son ordenados por algún criterio (típicamente por su identificador único en el mapa de red original) y se genera una lista ordenada con sus pesos formando un bloque. Se forman tantos bloques como mapas distintos compongan el TWM. Posteriormente, el cromosoma se forma por la concatenación de todos los bloques de pesos de los mapas 1 a N.

Una vez aplicados los operadores evolutivos sobre un cierto cromosoma, la función de decodificación seguirá el proceso inverso al descrito: división en bloques para cada mapa, y extracción de los genes como pesos de cada uno de los enlaces.

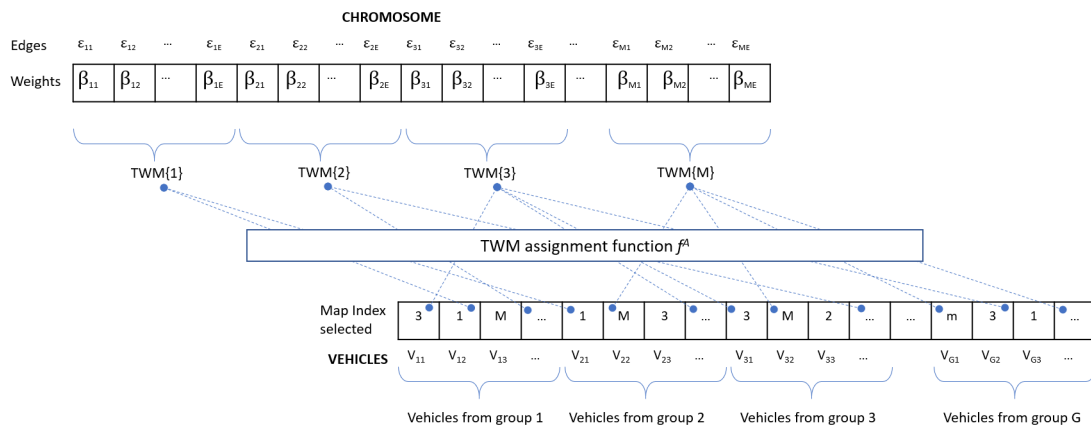


Figura 2.22.: Estructura del cromosoma empleado en B-TWM

El algoritmo B-TWM es excesivamente básico, generando cromosomas muy largos y por tanto de una complejidad de cálculo.

2.5.2. Algoritmo de optimización FP-TWM

Es posible aligerar mucho la complejidad del cromosoma y por tanto, mejorando la eficiencia de cálculo de la solución, si nos enfocamos en la utilidad a-priori de los enlaces: en las redes de tráfico no todos los enlaces tienen la misma utilidad, y en una gran proporción, ni siquiera se considerarán para el enrutado de las demandas de tráfico planteadas. Por ello, ¿para qué incluir elementos poco útiles en la búsqueda de la solución?

La utilidad apriorística de los enlaces nos la puede proporcionar el cálculo de los K *shortest-paths* de la demanda de tráfico. Así, si restringimos el cálculo de los pesos óptimos a exclusivamente los enlaces que forman parte de los KSP obtendremos mapas TWM optimizados para las rutas precualificadas.

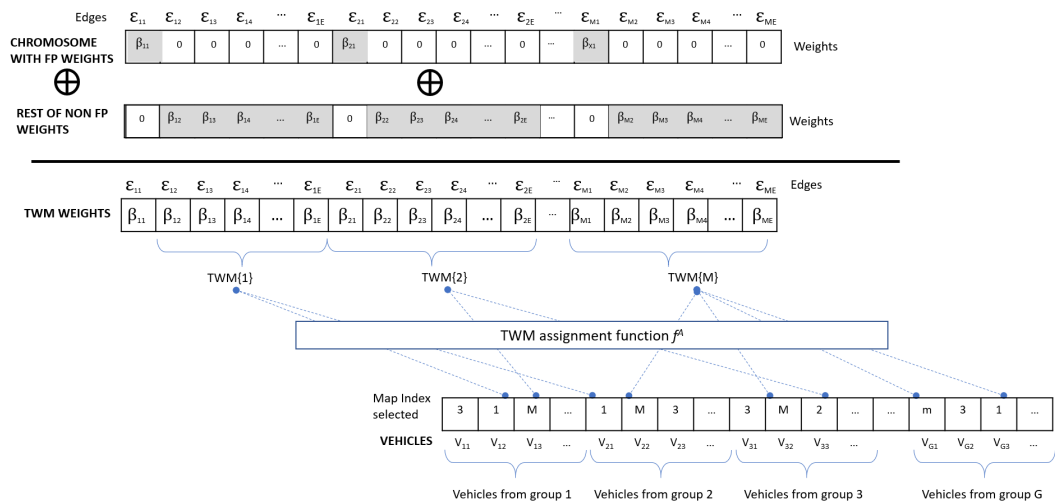


Figura 2.23.: Estructura del cromosoma empleado en FP-TWM

Este es el algoritmo FP-TWM descrito en la figura 2.23 donde el cromosoma contiene sólo los enlaces precualificados por los KSP por bloques para cada mapa TWM de forma análoga a B-TWM. En la decodificación del cromosoma, los mapas TWM estarán formados por copias del mapa de red físico, reemplazando los correspondientes pesos de los enlaces codificados en los bloques del cromosoma.

2.5.3. Algoritmo de optimización EFP-TWM

La restricción de los KSP añadida en FP-TWM es demasiado estricta ya que linealiza en exceso la selección de enlaces en favor de enrutamientos lineales. No debemos perder de vista que estamos optimizando mapas (áreas geográficas) y no rutas. En este sentido, podemos cualificar mejor el subconjunto de enlaces a considerar en el cromosoma, si consideramos los KSP como centroides de sus rutas, es decir, que definen áreas de enrutamiento preferente.

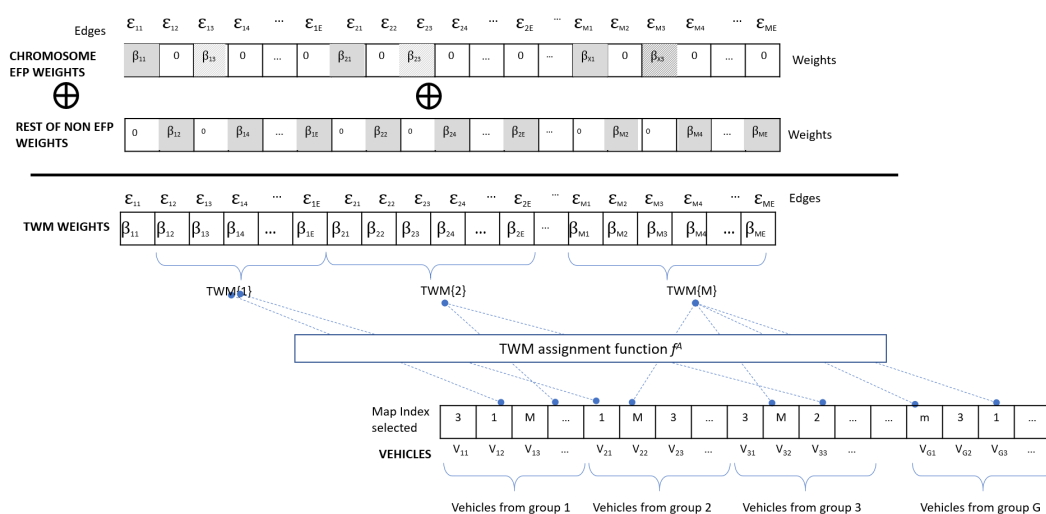


Figura 2.24.: Estructura del cromosoma empleado en EFP-TWM

El algoritmo Extended FP (EFP-TWM) tiene en cuenta los enlaces que forman parte de los enlaces en los KSP, y también todos aquellos enlaces que conectan los *nodos del KSP con todos aquellos nodos accesibles a una distancia d*. El mecanismo se describe en la figura 2.24. En realidad, EFP-TWM considera los KSP como las mejores áreas de enrutamiento, generando mapas adecuados para ellas.

La figura 2.25 esquematiza un escenario EFP-TWM en el que para un único flujo de tráfico entre dos ubicaciones urbanas (Madrid) se seleccionan 3 KSP alrededor de los cuales se generan las áreas de enrutamiento empleadas en el cromosoma para los mapas de pesos.

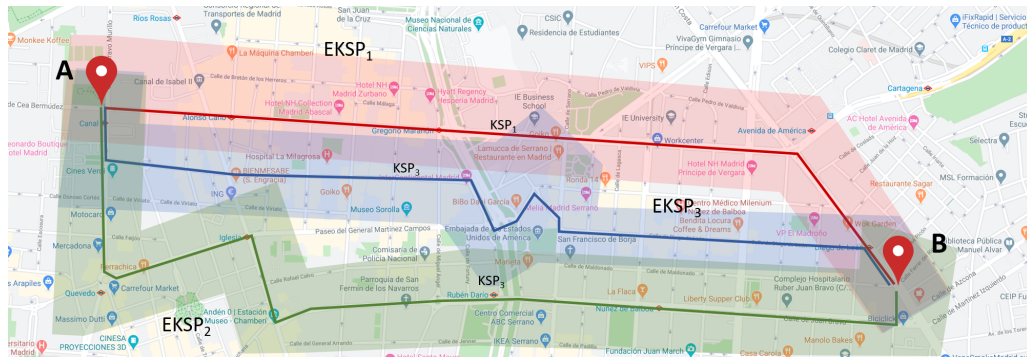


Figura 2.25.: Ejemplo áreas de enrutamiento EFP-TWM

En esta tesis no se han tenido en cuenta los efectos de los caminos disjuntos (*disjoint paths*) descritos por [48, 114], y que serán objeto de futuros trabajos.

2.5.4. Complejidad y rendimiento de los algoritmos

Consideramos una red de tráfico formada por N enlaces, usando una distribución de M mapas TWM. En el enrutamiento se emplearán K *shortest-paths* que seleccionan L enlaces, y se define el área de enrutamiento a una distancia d entre nodos que seleccionan Q enlaces. La dimensión del cromosoma define el volumen de variables a resolver por el algoritmo. En general:

- La dimensión del cromosoma B-TWM será $N \cdot M$.
- La dimensiones del cromosoma FP-TWM será $L \cdot M$, con $L < N$.
- La dimensión del cromosoma EFP-TWM será $Q \cdot M$, con $L < Q < N$.

En la figura 2.26 se muestran los diferentes tamaños de cromosoma para EFP-TWM el escenario Grid64 con diversos valores de los parámetros M , K y d .

La complejidad del algoritmo no sólo viene dada por el tamaño del cromosoma: éste tiene impacto directo en el tamaño de la población a considerar puesto que a mayor número de variables mayor tamaño deberá tener la población a evolucionar. Y ello también condiciona el número de iteraciones que serán necesarias para obtener la solución.

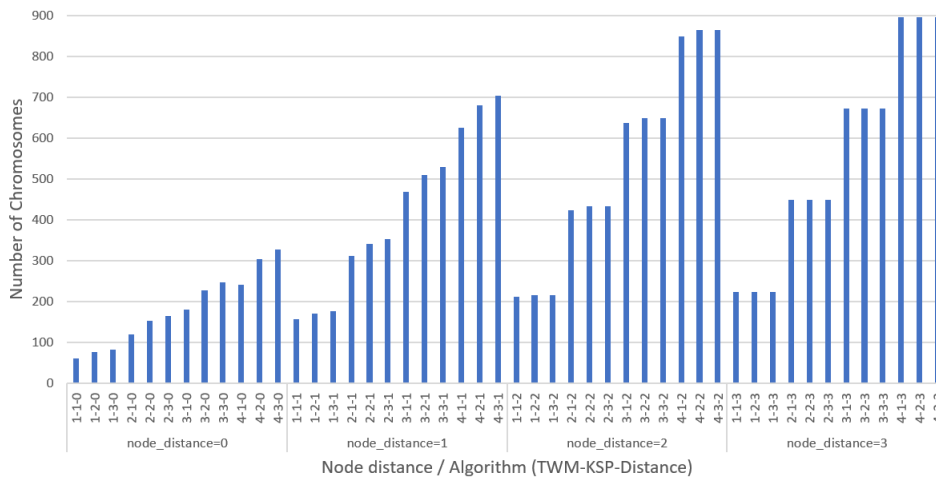


Figura 2.26.: Grid-64 complejidad del cromosoma para varios TWM, KSP y distancia d

Por cada cada elemento de la población se deberá realizar una asignación de tráfico, que a su vez, está condicionado por el tamaño de la demanda (número de vehículos a enrutar) por lo que éste determina el número de asignaciones, que es una operación costosa en tiempo de cálculo.

Dado que el tamaño de la demanda no se puede modificar puesto que viene dado, el tamaño del cromosoma usado en cada algoritmo determinará en definitiva la complejidad total del cálculo. Éste está determinado por el número de enlaces seleccionados cuyos pesos deben ser optimizados y el número de mapas que componen el TWM.

Se han realizado diversos experimentos para analizar el comportamiento de los algoritmos, tanto con redes sintéticas más sencillas de analizar (Grid64) como con redes reales (Madrid-Retiro) ambos descritos en el apéndice A.

La figura 2.27 muestra un ejemplo de convergencia del GA para el escenario experimental Grid64 en el que se puede ver cómo el algoritmo es capaz de encontrar rápidamente una configuración de TWM óptimo para la demanda configurada.




Figura 2.27.: Grid-64 convergencia del algoritmo evolutivo para FP-4-3-0 y EFP-4-3-3

En la tabla 2.4 se muestran diversas configuraciones de Grid64, el tamaño de los cromosomas, los tiempos de procesamiento del algoritmo, así como el indicador *Total Travel Time (TTS)* obtenido en la asignación. Se puede comprobar la relación esperada entre el número de enlaces seleccionados y el tiempo de ejecución.

En la figura 2.28 se muestra la distribución de pesos para el mapa de red original y su descomposición en un 4-TWM mediante B-TWM para el escenario Madrid-Retiro descrito en el A .

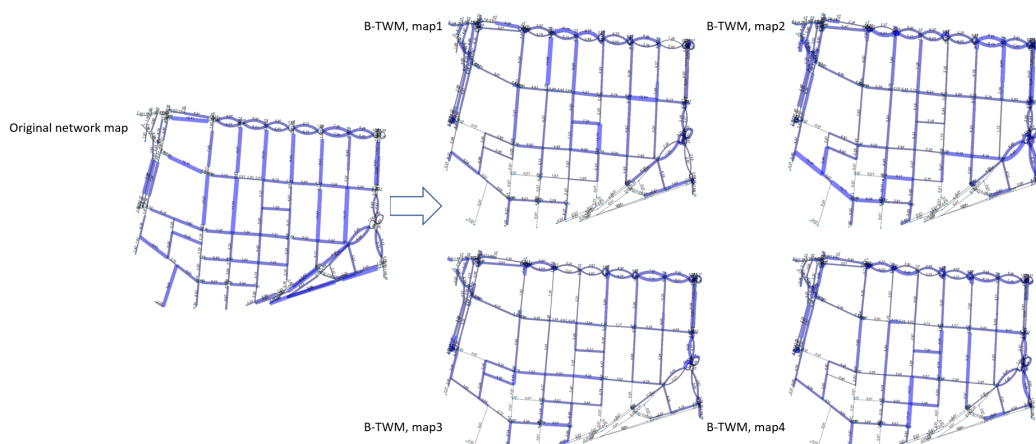


Figura 2.28.: Mapas óptimos B-TWM para los experimentos de Madrid-Retiro

Method	TWM	Nodes	Links	Genes	Coverage
Random	4	64	224	-	-
B-TWM	4	64	224	896	100 %

Method	TWM	KSP	d	Nodes	Links	Genes	Coverage
FP-TWM	3	2	0	27	76	304	34 %
EFP-TWM	3	2	1	51	170	700	78 %
EFP-TWM	3	2	2	62	216	864	96 %
EFP-TWM	3	2	3	64	224	896	100 %

Method	TWM	KSP	d	Nodes	Links	Genes	Coverage
FP-TWM	4	3	0	28	82	328	37 %
EFP-TWM	4	3	1	52	176	704	79 %
EFP-TWM	4	3	2	62	216	864	96 %
EFP-TWM	4	3	3	64	224	896	100 %

Method	d	Routes	Total TT (s)	Mean TT. (s)	Execution (s)
Random		24	9,181,913	2040	0.17
B-TWM		24	523,876	116	503.97
FP-TWM	0	24	611,805	136	149.17
EFP-TWM	1	24	543,542	121	316.63
EFP-TWM	2	24	573,904	128	696.90
EFP-TWM	3	24	627,819	140	492.52

Tabla 2.4.: Análisis de complejidad y eficiencia de los algoritmos para diversas configuraciones de Grid64.

2.6. Asignación estática de tráfico mediante multi-mapas óptimos

Para comparar la calidad de las soluciones aportadas por los diferentes algoritmos de TWM (aleatorios, óptimos) empleamos las técnicas de asignación estática de tráfico. descritas en la sección 1.1.4: asignación todo-o-nada AON; asignación UE aproximada por los métodos CUM, MSE y de programación lineal propuesta (WEI-LP); y técnicas de asignación por TWM con mapas aleatorios y mapas óptimos. Ya hemos visto que la asignación UE nos da un valor teórico óptimo, por lo que al compararla con TWM optimizado podremos valorar la calidad de su solución al problema. La inclusión de la solución de mapas aleatorios nos permite analizar cuál sería el impacto por el mero hecho de generar variedad de rutas.

El cálculo final de la asignación de tráfico se realiza una vez distribuidos los correspondientes mapas TWM a sus usuarios, y en nuestro caso empleamos una asignación de caso peor AON para ver la mejora mínima esperable. En ese sentido, si se consideran F flujos de tráfico y M mapas TWM, se generarán $F \cdot M$ mejores rutas que son las serán objeto de uso por los usuarios. Ante la posibilidad de usar otra asignación distinta a AON, se generarían N rutas adicionales para cada combinación por lo que número total de rutas en el sistema sería de $F \cdot M \cdot N$ y se mejoraría considerablemente el TTS en el sistema. Como hemos indicado, nos quedaremos con la situación de caso peor para ver la ganancia mínima del mecanismo. Podemos comparar el volumen de rutas generadas por cada algoritmo con las generadas por TWM (tabla 2.5).

En la figura 2.29 podemos observar la distinta distribución de rutas al usar asignación mediante los métodos descritos, usando FP y EFP con distintas métricas. Se observa cómo TWM genera la diversidad de rutas requerida con la dimensión $F \cdot M$ comentada. La calidad de las rutas generadas depende del coste de los enlaces de cada vista TWM, de la ocupación final de los enlaces y de la función VDF empleada 2.5.

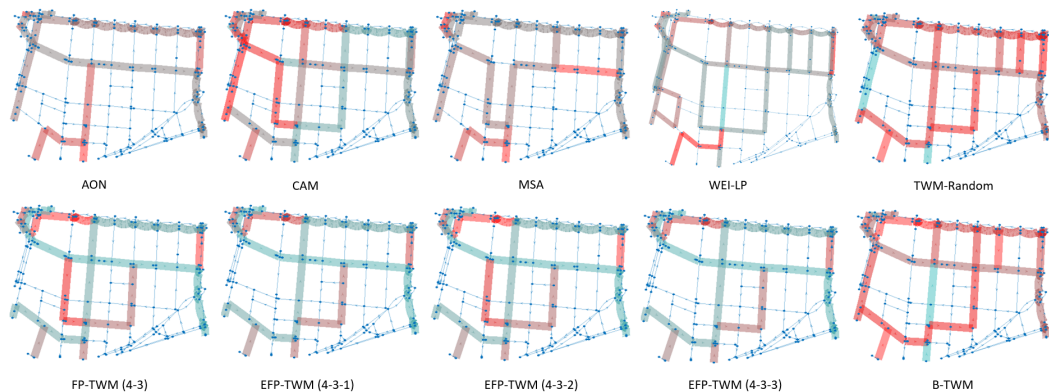


Figura 2.29.: Asignación de tráfico para los experimentos de Madrid-Retiro

Method	d	Routes	Total TT.	%AON	Mean TT.	Execution
AON		8	19,382,773		2,423	0.12
CAM		55	7,801,697	59.75 %	975	7.51
MSA		8	7,743,361	60.05 %	968	6.75
WEI-LP		22	7,365,860	62.00 %	847	41,05
Random		32	12,593,118	35.03 %	1,574	0.25
B-TWM		32	8,099,209	58.21 %	1,010	631.00
FP-TWM	0	32	7,967,106	58.90 %	996	685.48
EFP-TWM	1	32	8,045,973	58.49 %	1,006	586.33
EFP-TWM	2	32	8,028,827	58.58 %	1,004	722.89
EFP-TWM	3	32	8,051,164	58.46 %	1,006	1,112.75

Tabla 2.5.: Eficiencia y diversidad de rutas en los algoritmos TWM(4) and KSP(3).

Si comparamos el indicador objetivo (TTS) para las distintas mediciones, mostrado en la figura 2.30, nos encontramos que AON, el caso peor aún buscando rutas de mínimo coste, triplica las diferentes estimaciones de asignación para UE. Sin embargo, el conjunto de rutas de TWM óptimos provoca una asignación de tráfico realmente similar a dicha asignación UE, obviamente fruto del proceso de optimización.

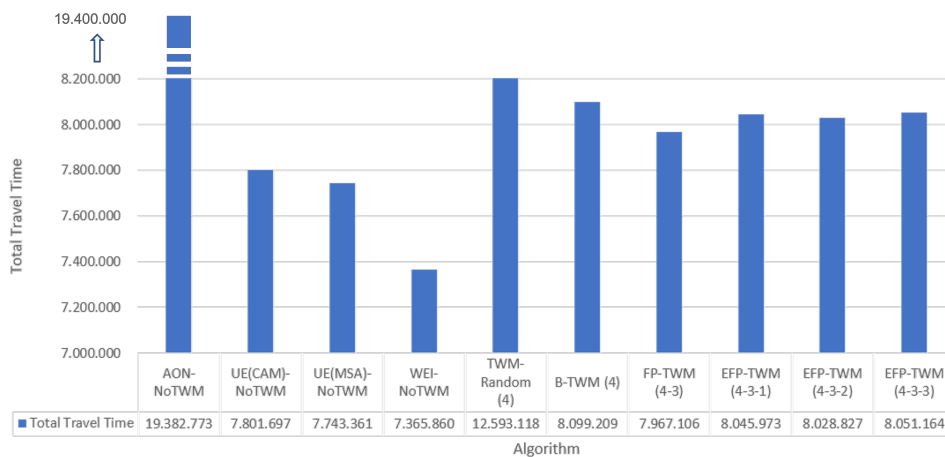


Figura 2.30.: Comparativa de TTS para los distintos métodos de asignación (Madrid-Retiro)

La aportación de TWM es significativa: mientras que los métodos de estimación de la asignación de tráfico en equilibrio están basados en modelos matemáticos,

TWM está basado en un modelo práctico de generación y distribución de mapas, realizable y compatible con los sistemas existentes.

2.6.1. Efecto de la adherencia de los conductores

Como ya hemos visto anteriormente, la efectividad de un ITS depende en gran medida del grado de adopción del mismo por parte de los vehículos. Así, tras la generación y adopción de los TWM óptimos, se debe considerar su impacto según la adherencia (figura 2.4). En la figura 2.31 se muestran los resultados experimentales en Grid64 de la variación del TTS para diferentes adherencias y diversas configuraciones de optimización representadas por el tamaño del cromosoma: en un escenario de baja adherencia (10 %) el TTS sigue siendo muy alto, aunque mejora de forma drástica en cuanto ésta aumenta, llegando a un punto en que con el 50 % de adherencia ya se obtiene el 80 % del beneficio. Este es el *efecto de la liberación de rutas* por el los conductores adheridos a TWM liberan las rutas congestionadas, facilitando al resto de vehículos su conducción en sus rutas habituales. Conforme la adherencia se incrementa hasta el 100 % pasan a saturarse las vías alternativas.

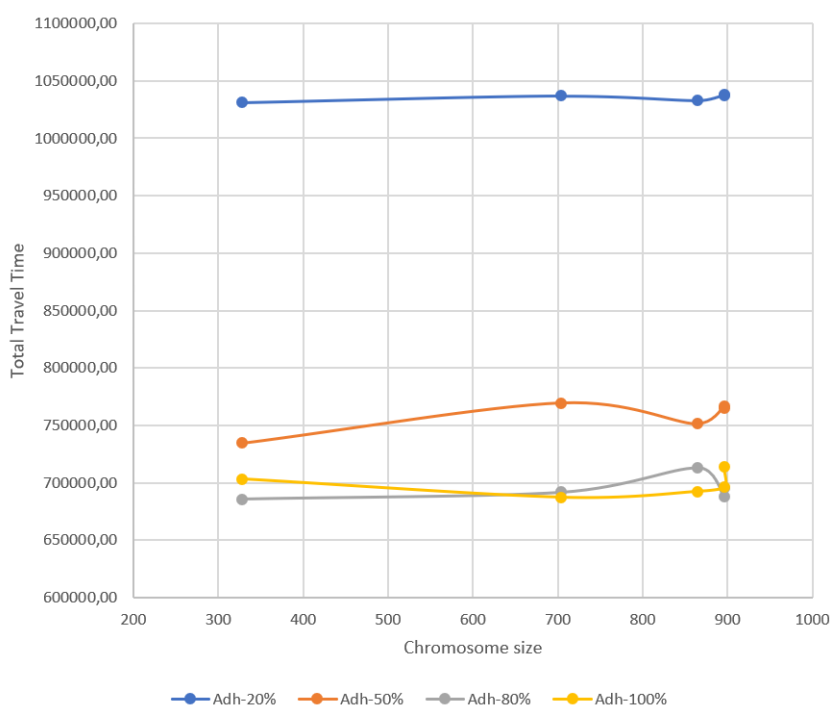


Figura 2.31.: TTS frente tamaño del cromosoma para diferentes adherencias (Grid64)

2.6.2. Efecto de las rutas injustas (*route unfairness*)

Ya ha sido identificado en trabajos previos [11, 108, 111] el denominado efecto de las rutas injustas (*route unfairness*, RU) por el que la optimización de un sistema de tráfico provoca que algunos conductores se vean negativamente afectados por rutas peores. Es decir, que la propia optimización del sistema genera *detractores* y *promotores* al mismo.

Así en la figura 2.32 se comparan los tiempos de viaje individuales entre la asignación AON y TWM-4-3-3 en un entorno de adherencia completa. Podemos observar como en las comparativas absolutas y relativas, un volumen significativo de vehículos (5 %) obtiene una penalización relevante (40 %), lo cual generará situaciones de posible retracción entre sus usuarios.

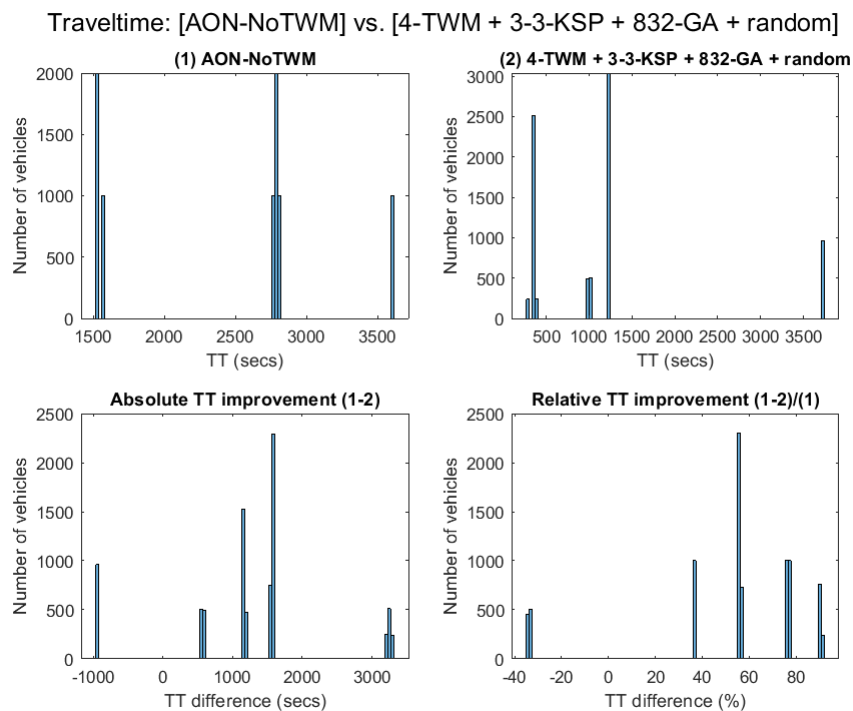


Figura 2.32.: Comparación de tiempos de viaje individuales entre AON y TWM-4-3-3

2.7. Modelado de la experiencia de usuario en entornos multi-ITS

Con el despliegue masivo de dispositivos conectados tanto a nivel de vehículo como de ocupantes, la primera decisión que un conductor debe tomar a la hora de elegir la ruta de su desplazamiento, ya no es la ruta en sí misma, sino el ITS que empleará para escogerla en base a su utilidad percibida.

El ecosistema de ITS es heterogéneo y no integrado en el sentido de que emplea datos de red y de estado del tráfico, pero no entre ellos no comparten datos en tiempo real, desvirtuando la toma de decisión “óptima”. Lejos de ser interoperables, los ITS además interfieren entre sí [63, 20]. Y la utilidad percibida es una variable de alta componente subjetiva donde las previas experiencias del usuario, su escala de valoración, la confianza en los resultados, y la influencia social social [126, 3] son factores clave.

Adicionalmente, hemos visto en la sección 2.6.2 cómo los ITS orientados a la optimización del sistema generan escenarios de rutas injustas para un cierto porcentaje de los conductores, lo que posiblemente los convertirá en detractores.

Existen diversos métodos para abordar la elección de ruta mediante modelos de utilidad, empleándose en numerosas ocasiones los modelos de elección discreta para ello [94, 8]. Las decisiones individuales de ruta se toman después de considerar y comparar las utilidades de cada alternativa, bajo la hipótesis de tomar decisiones mutuamente excluyentes.

Para llegar a la toma de decisión es preciso haber identificado previamente las posibles alternativas y calculado su utilidad. Este es un proceso subjetivo basado en modelos de creencias, obligaciones, intenciones, deseos e impacto social (BOID+S) que son eminentemente difusos, tanto en su valoración como en la lógica de interacción y condiciones entre los distintos factores [25]. El modelo nos permite combinar el criterio SO con los criterios BRUE y SUE.

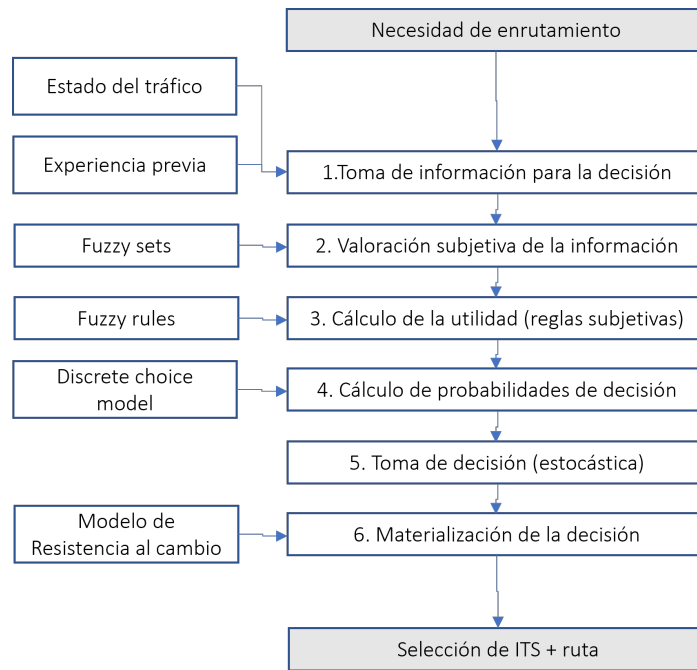


Figura 2.33.: Modelo de elección de ruta multi-ITS

En la figura 2.33 se describe el modelo de toma de decisión estrategia de enrutamiento propuesto en la tesis, y cuyos pasos son:

1. Recoger las observaciones necesarias para las variables variables contabilizadas.
2. Valoración subjetiva de estas variables mediante funciones de pertenencia difusas.
3. Cálculo de las utilidades de las diferentes opciones de enrutamiento (ITS) mediante la aplicación de un conjunto de reglas de comportamiento difuso. La utilidad de cada una se obtiene una función de agregación de los resultados de las reglas.
4. Aplicación de un modelo de elección discreta para obtener la probabilidad de uso de cada estrategia de enrutamiento.
5. Toma de una decisión estocástica en la que el conductor selecciona qué estrategia de enrutamiento va a utilizar.

6. Aplicación de un modelo de resistencia al cambio, para diferenciar la selección de la mejor opción de enrutamiento, frente a la decisión efectiva de uso. Se modela mediante un proceso estocástico.

El modelo BOID+S propuesto (*Belief, Obligations, Intentions, Desires and Social*) requiere la definición de:

- Las variables de entrada $[X_i]$ a considerar y sus funciones *fuzzy* de valoración.
- Las variables de salida (utilidades) $[U_n]$ a considerar, e igualmente sus funciones *fuzzy* de valoración.
- Las reglas de composición de la utilidad $\{R_r\}$, sus pesos, y sus políticas de evaluación y agregación $[\mathcal{F}, \mathcal{Q}]$.
- El modelo de elección discreta.
- Y finalmente, del modelo de resistencia al cambio Y .

El modelo asume que el usuario se enfrenta no sólo a una decisión de elegir ruta, sino a una elección de método de enrutamiento entre los \mathbb{R}_k (diferentes ITS) que tiene disponible: usar el ITS_A , el ITS_B , no usar ninguno, etc.

La generalidad y flexibilidad de nuestro modelo BOID+S permite introducir nuevas variables, reglas y criterios, así como cualquier ITS a considerar. Aunque inicialmente la investigación se centra en los factores relacionados con el tiempo de viaje, ya que es el usado como criterio de optimización, pero se pueden añadir directamente otros parámetros, como:

- Coste del viaje, comparando el uso o no de \mathbb{R}_k , tanto en experiencias a corto como a medio plazo.
- Estrés de la carga en vehículos eléctricos.
- Puntos y duración de las detenciones (congestión, semáforos y otros).
- Y cualquier otro parámetro.

2.7.1. Modelo de utilidad

Dado un cierto trayecto, las utilidades $[U_n]$ que pueden presentar las diferentes opciones de enrutamiento (usar un cierto ITS concreto o incluso no usar ninguno) para un usuario concreto, la cuantificaremos como el resultado de aplicar una serie de reglas *fuzzy* $\{R_r\}$ sobre ciertas variables subjetivas $[X_i]$.

Como pueden existir multitud de reglas *fuzzy* y sólo se puede tener un valor de utilidad por cada opción considerada, es preciso emplear una función de agregación de utilidades (*fuzzy wrapper*) con cierta política [61]. Las utilidades de salida son evaluadas por las correspondientes categorías $[C_U]$ (asumiremos una evaluación homogénea a todas ellas):

$$C_U \in \{“Low”, “Mid”, “High”\} \quad (2.19)$$

Así, por ejemplo, en el problema de un vehículo concreto que quiere ir del punto A al punto B, y tiene que escoger si seguir la recomendación del navegador X, o del navegador Y, o del copiloto experimentado Z, o incluso no hacer caso de ninguna recomendación externa (no), cada una de estas opciones le ofrecerá un valor subjetivo de utilidad $(X, Y, Z, no) \leftarrow (0,5, 0,7, 0,1, 0,4) \leftarrow (“mid”, “high”, “low”, “mid”)$. En este caso, no evaluaremos directamente a que el conductor elegirá la estrategia «Y» sino que ésta será la más probable en el conjunto.

2.7.2. Variables de entrada del modelo de experiencia de usuario

Cada variable de entrada $[X_i]$ es definida por su objetivo, su función de cálculo y sus categorías $[C_i]$ de valoración *fuzzy*. El modelo inicialmente considera las siguientes variables:

- *Similitud del último tiempo de viaje respecto al free-flow* (X_{FF-TTS}^t), que representa la calidad experimentada en el último de viaje respecto al

mínimo tiempo de viaje por la ruta de mínimo coste (ratio entre ambos tiempos 2.20) (2.21).

$$X_{FF-TTS}^t = \frac{TT_k^{FF}}{TT_k^t} \quad (2.20)$$

$$C_{FF-TTS} \in \{\text{"Optimum"}, \text{"Acceptable"}, \text{"Bad"}\} \quad (2.21)$$

- *Experiencia del usuario respecto del último tiempo de viaje* (X_{LT-TT}^t) representa la experiencia de viaje más influyente a corto plazo, comparando las dos últimas experiencias y comprobando si la última decisión ha merecido la pena. Compara la mejora del último viaje TT_k^t con respecto al anterior TT_k^{t-1} . La mejora (2.22) es efectiva cuando su valor supera un determinado umbral subjetivo δ , con el que se modela el criterio BRUE.

$$X_{LT-TT} = \left(TT_k^t < TT_k^{t-1} * (1 - \delta) \right) \quad (2.22)$$

$$C_{LT-TT} \in \{\text{"Yes"}, \text{"No"}\} \quad (2.23)$$

- *Consideración Individual del ITS R_k* (X_{RU-K}^t), refleja si un usuario es activo en el método de encaminamiento \mathbb{R}_k . El conocimiento activo puede medirse por el estado de registro del vehículo en la aplicación de enrutamiento, o por el indicador de memoria individual que registra que si ha utilizado alguna vez.

$$C_{RU-K} \in \{\text{"NoUser"}, \text{"PotencialUser"}, \text{"ActiveUser"}\} \quad (2.24)$$

- *Experiencia del tiempo medio de viaje individual utilizando ITS R_k* (X_{MTT-K}^t), que refleja la percepción individual a medio plazo sobre el uso de R_k . Se evalúa por el ratio de viajes que mejoraron su tiempo de viaje utilizando R_k en las últimas m ejecuciones (2.25).

$$X_{MTT-K}^t = \frac{\sum_i X_{LT-TT}^i}{m}, i \in [t - m, t] \quad (2.25)$$

$$C_{MTT-K} \in \{\text{"Improved"}, \text{Neutral"}, \text{"Worsened"}\} \quad (2.26)$$

- *Uso del ITS en el último viaje* $\mathbb{R}_k (X_{LTU-K}^t)$. La última experiencia de trayecto es crítica, por lo que es necesario evaluar el método de enrutamiento que se ha utilizado para tomar la siguiente decisión. Se mide como una opción sí/no para los métodos de enrutamiento \mathbb{R}_k (2.27).

$$C_{RU-K} \in \{“Yes”, “No”\} \quad (2.27)$$

- *Influencia Social del ITS* $\mathbb{R}_k (X_{SOC}^t)$, que refleja la influencia de la comunidad de conductores sobre la decisión individual. Este parámetro agrega todos los factores de influencia social. Puede abordarse inicialmente como el coeficiente de adopción del método de encaminamiento en la población global (2.28): porcentaje de conductores que utilizan \mathbb{R}_k , donde N es el número de conductores.

$$X_{SOC}^t = \frac{\sum X_{LTU-K}^t}{N} \quad (2.28)$$

$$C_{SOC} \in \{“Low”, “Mid”, “High”\} \quad (2.29)$$

2.7.3. Reglas de utilidad

El modelo de evaluación de la utilidad de cada opción de enrutamiento se implementa mediante reglas de decisión *fuzzy*. Cada regla evalúa la utilidad de cada posible decisión. Así dado un conjunto de variables *fuzzy* a considerar y una serie de reglas de evaluación, el razonador evalúa la utilidad de cada posible decisión de salida para cada regla (2.30). En la tabla 2.6 se ilustra un ejemplo:

Dado que es preciso para integrar las utilidades devueltas por todas las reglas evaluadas es preciso unificar sus resultados mediante una función agregación (*fuzzy wrapper*) (2.31) que tiene en cuenta tanto las utilidades devueltas con el peso de cada regla.

$$R_r : [u_n]_r \rightarrow \mathcal{F}([x_i]) \quad (2.30)$$

Rule	Trigger condition	
R_3	WHEN	The free-flow individual travel time similarity IS <i>bad</i> (very long travel time compared to free-flow) AND The driver IS an <i>unregistered TWM user</i> AND TWM popularity IS <i>high</i>
Weight	Evaluation	
WEIGHT=0.5	THEN	Utility of TWM routing IS <i>high</i> AND Utility of standard routing (non-TWM) IS <i>low</i>

Tabla 2.6.: R_3 regla principal de adopción de TWM.

$$[u_i] \rightarrow \mathcal{Q}([u_n]_r, w_r), \forall R_r \quad (2.31)$$

2.7.4. La elección del enrutamiento a seguir

Una vez obtenidas las utilidades de las distintas alternativas, se procede a la toma de decisión de cuál de ellas elegir. Es posible aplicar un modelo de elección discreta utilizando la teoría de la utilidad aleatoria bajo los siguientes supuestos [18, 19, 94]:

- Los individuos pertenecen a una población homogénea en cuanto a objetivos (principalmente reducir el tiempo de viaje), utilizan información perfecta sobre el estado del tráfico y sus experiencias previas, y toman decisiones racionales (reglas de comportamiento).
- Existe un conjunto predefinido de alternativas de ruta ITS que pueden expresarse mediante atributos evaluables en la toma de decisión de cada individuo.
- La utilidad percibida por cada conductor k sobre cada alternativa de enrutamiento se expresa mediante la expresión 2.32 que combina la evaluación sistemática de los atributos y un error de observación ε_n^k :

$$u_n^k = v_n^k + \varepsilon_n^k \quad (2.32)$$

$$v_n^k = \sum \beta_{ij} * x_{ij}^k \quad (2.33)$$

- Los viajeros seleccionan la alternativa de máxima utilidad cuando $v_n^k - v_m^k \geq \varepsilon_m^k - \varepsilon_n^k$ y entonces la probabilidad de elegir la alternativa n es:

$$P(u_n^k) = Prob \left\{ \varepsilon_n^k \leq \varepsilon_m^k + (v_n^k - v_m^k), \forall U_m \right\}$$

Si los errores de observación ε_n^k son independientes y con igual distribución, se puede utilizar la distribución Weibull/Gumbel (Extreme Vale Tipo I) y se puede aplicar el Modelo Logit Multinomial (MLM) [87] que proporciona una expresión simplificada para calcular las probabilidades $P(u_i^k)$ de que un conductor utilice un método de encaminamiento del tráfico \mathbb{R}_i en un cierto instante (2.34):

$$P(u_i^k) = \frac{\exp(u_i^k)}{\sum_k \exp(u_k^k)} \quad (2.34)$$

Utilizaremos el enfoque MLM para la toma de decisión en nuestro modelo.

2.7.5. Modelo de resistencia al cambio

Además de los parámetros mencionados, las utilidades obtenidas y la decisión tomada, es preciso considerar la actitud personal frente al cambio de método de enrutamiento [38, 7].. La resistencia individual al cambio (X_{RC}) se modela sobre la población de vehículos, asignando a cada vehículo una determinada probabilidad para X_{RC} con una probabilidad máxima p_{max} .

Se pueden emplear varias distribuciones de probabilidad entre las que hemos usado:

- El modelo estricto donde el usuario simplemente acepta o rechaza la decisión de enrutamiento con probabilidad $Y_{bin} : p_{max}, m \rightarrow p_{max} * binary(m)$ donde $binary(m)$ es un experimento $[0, 1]$ sobre el porcentaje m de vehículos. En la figura 2.34 se muestra el histograma de valores de probabilidad X_{RC} para toda la población, donde sólo el 60% de los

vehículos tienen una probabilidad de resistencia al cambio de 0.75. Los valores se asignan aleatoriamente a los vehículos.

- El modelo normal en el que la disposición al cambio se modela con la distribución normal $Y_{norm} : p_{max}, m, d \rightarrow p_{max} * norm(m, d)$, donde $norm(m, d)$ es la distribución normal de media m y desviación estándar d . En la figura 2.35 se muestra el histograma de Y_{norm} , para $p_{max} = 0,75, norm(0,6, 0,1)$.

Así en cada decisión de enrutamiento, si la decisión resultante es un cambio de criterio, se efectuará un experimento probabilista con la probabilidad individual X_{RC} para decidir si se cambia o no.




Figura 2.34.: Distribución estricta de la probabilidad de resistencia al cambio $Y_{bin} \rightarrow 0,75 * binary(0,6)$




Figura 2.35.: Distribución normal de la probabilidad de resistencia al cambio $Y_{norm} \rightarrow 0,75 * norm(0,6, 0,1)$

2.8. Simulación de la dinámica de adopción de TWM

El modelo de experiencia de conducción descrito puede ser aplicado al proceso de adopción de la estrategia de enrutamiento mediante TWM considerando como alternativas el uso o no-uso por parte de los vehículos. Este modelo nos habilita el estudio de la dinámica y evolución de la adherencia a TWM en una

población, habiendo visto ya que su uso genera una mayoría de promotores, pero una minoría de detractores por el efecto del *route unfairness*. Igualmente, también hemos contrastado los efectos de los distintos niveles de adherencia en el TTS global.

Para la aplicación del modelo usamos las dos opciones de enrutamiento mencionadas $[U_{TWM}, \bar{U}]$ y sus criterios de cuantificación *fuzzy* ilustrados en la figura 2.36:

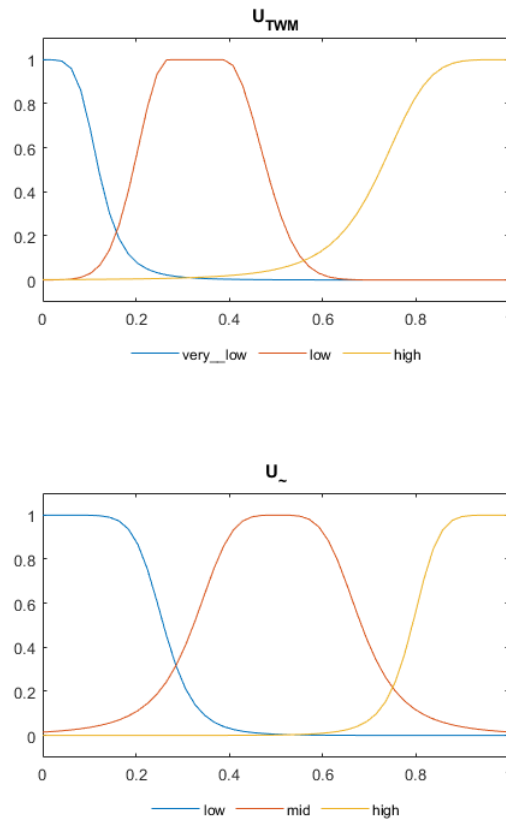


Figura 2.36.: Funciones de cuantificación *fuzzy* $[U_{TWM}, \bar{U}]$

Según la expresión (2.34), la utilidad de usar TWM vendrá dada por:

$$P(U_{TWM}) \rightarrow \frac{\exp(U_{TWM})}{\exp(U_{TWM}) + \exp(\bar{U})} \quad (2.35)$$

Respecto a las reglas de decisión sobre las variables indicadas en la sección 2.7.2, se identifican varios grupos en función del comportamiento de los

usuarios. El detalle de las reglas puede verse en el apéndice C, Las reglas se agrupan por su comportamiento similar en los siguientes conjuntos de reglas:

1. **Comportamiento de los no usuarios de TWM (reglas 1-5):** cuando el conductor NO es usuario de TWM, dependiendo de lo valiosa que sea la experiencia del último viaje en comparación con las condiciones de conducción en flujo libre, y de la aceptación social de TWM, las utilidades $[U_{TWM}, \bar{U}]$ variarán. La utilidad de la TWM condiciona la política de los nuevos adoptantes.
2. **Comportamiento de los usuarios de TWM teniendo en cuenta la experiencia a corto plazo (reglas 6-15):** cuando el conductor SI es usuario de TWM (usuario registrado o lo ha utilizado alguna vez), la experiencia del último viaje condiciona si ha merecido la pena el uso de TWM o no, considerando si el tiempo de viaje ha mejorado o no. La aceptación social de la TWM es menos importante aquí. Este conjunto de reglas controla si el conductor sigue utilizando TWM o rechaza su uso en función de las experiencias de tráfico cuando la adherencia aumenta y las condiciones de congestión evolucionan.
3. **Comportamiento de los usuarios de TWM teniendo en cuenta la experiencia a medio y largo plazo (reglas 16-19):** cuando el conductor SI es usuario de TWM, la experiencia a medio y largo plazo utilizando TWM es valiosa para representar la confianza del conductor en el método de encaminamiento. Independientemente de lo que haya ocurrido en el último viaje del conductor, éste aprende de otras experiencias anteriores. Estas reglas limitan también las oscilaciones en el proceso de decisión.

El origen de las reglas es un modelo ad-hoc adaptado al caso de uso de TWM en base a los comportamientos de promoción/detracción esperados. Este modelo debería ser generado desde un trabajo de campo previo basado en encuestas a la población de conductores y desde un trabajo comparativo de comportamientos en el tiempo. El objetivo de la investigación es el propio modelo de gestión BOID+S, que es general y permite añadir fácilmente nuevas reglas referidas a las variables difusas existentes o a nuevas adiciones.

Es importante resaltar que **el modelo se basa en el razonamiento y comportamiento individual**, e implica una memoria de corto plazo sobre la última

ejecución, y también una memoria generalista (estadísticos) sobre el pasado próximo.

El modelo ha sido aplicación a simulaciones sobre en redes sintéticas y sobre redes urbanas reales complejas.

2.8.1. Evolución de la adherencia

En la figura 2.37 se puede ver en el experimento Madrid-Las Tablas descrito en el apéndice A, cómo la adherencia de la red evoluciona en el tiempo para diferentes niveles de rechazo al cambio. Inicialmente muy pocos conductores conocen y usan TWM pero los resultados son de su interés por lo que se convierten en promotores, usando el sistema de forma habitual. Aleatoriamente van incorporándose nuevos conductores teniendo en cuenta la resistencia al cambio, incluyendo el incentivo social (marketing o redes). Aquellos conductores que obtienen peores resultados algunas veces cambian, otras no, aunque el cambio muchas veces les hace volver a valores peores, por lo que rápidamente vuelven al uso de TWM.




Figura 2.37.: Madrid Las Tablas: evolución de la adherencia a TWM para diferentes valores de p_{max} con $Y_{norm}(p_{max}, 0, 5, 0, 1)$

En dicho experimento, vemos cómo evoluciona el indicador TTS (*Global Travel Time*) junto a la adherencia (figura 2.38) para varios niveles de resistencia al cambio. Aquí observamos con nitidez cómo a pesar de tener bajos niveles de adherencia en condiciones de alta resistencia al cambio, el sistema evoluciona hacia una drástica reducción de la congestión. El sistema tiene una evolución convergente hacia valores estables de óptimo. La diferencia entre los escenarios más pesimistas y optimistas no es excesivamente acusada, convergiendo rápidamente en el tiempo, y ofreciendo una mejora muy importante en el TTS.




Figura 2.38.: Madrid Las Tablas: evolución de TTS a TWB para diferentes valores de p_{max} con $Y_{norm}(p_{max}, 0, 5, 0, 1)$

Podemos analizar individualmente la secuencia de decisiones de cada uno de los individuos en cada una de las etapas de evolución del sistema, y entonces nos encontraremos que cada uno toma sus propias decisiones, en el uso o desuso de TWB en función de sus propios condicionantes (cada uno tiene su propia ruta y su propia experiencia). En la figura 2.39 se muestra a título ilustrativo la evolución de los individuos 3241 y 5000, donde cada uno toma sus decisiones (reglas) de forma particular y diferente.

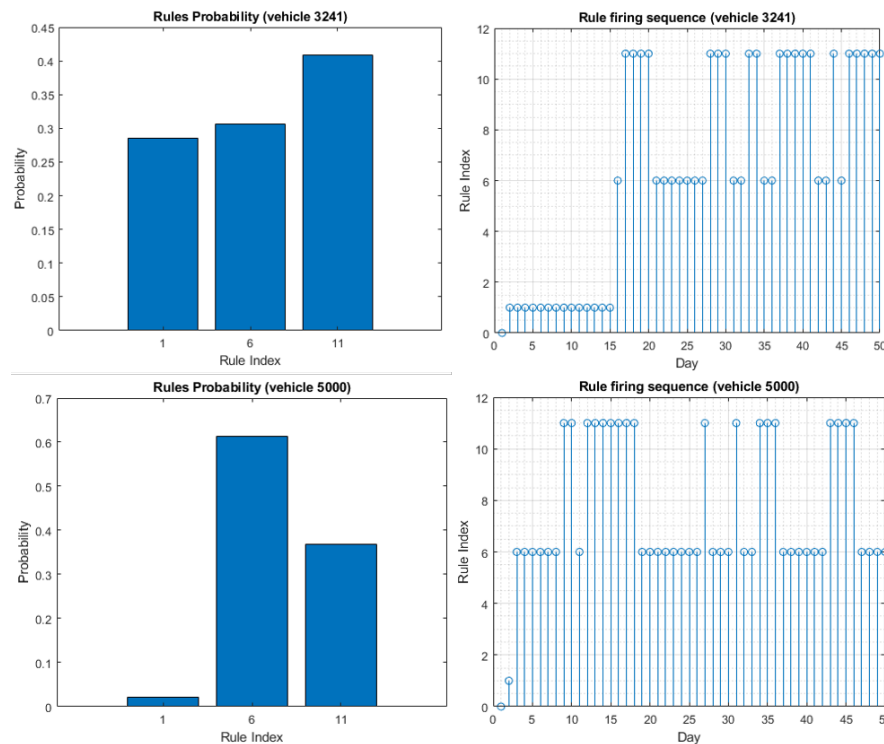


Figura 2.39.: Madrid Las Tablas: comportamiento de los individuos 3241 y 5000

2.9. Simuladores de tráfico para TWM

A la hora de realizar la simulación de los entornos de tráfico que usan TWM ha sido preciso desarrollar varias herramientas de aplicación de TWM compatibles con el simulador microscópico SUMO [76]. El conjunto de todas ellas forman el paquete MuTraff desarrollado, detallado en el apéndice D.

Entre las herramientas generadas se encuentran:

- **Simuladores microscópicos para la asignación dinámica de tráfico usando TWM** y el estudio de la respuesta individual. Se ha diseñado la herramienta *mutraff_simulator* como simulador de TWM complementario al simulador microscópico SUMO.
- **Simuladores macroscópicos para la planificación de la red mediante TWM** y realizar la asignación estática del tráfico con los mapas de pesos optimizados. Tras evaluar la ampliación y desarrollo de varios simuladores

opensource disponibles, finalmente se han implementado como cuadernos de experimentación de la herramienta MatLab [86] empleando el módulo MatLab Genetic Algorithms [85].

- **Simulador macroscópico para la evaluación de modelos de experiencia de usuario** con toma de decisión y valoración subjetiva de utilidades. Se ha implementado como cuadernos de experimentación de la herramienta MatLab [86], empleando el paquete adicional MatLab FuzzyLogic Toolbox [61].
- **Generadores de mapas TWM** para las distintas estrategias de enrutamiento:
 - Mapas de pesos aleatorizados para diversificación de rutas. Componente MuTraff: *mutraff_genmaps* sobre python.
 - Mapas de pesos optimizados para la gestión dinámica de incidencias, con gestión del tiempo. Componente MuTraff: *mutraff_genmaps* sobre python.
 - Mapas de pesos selectivos para las diferentes agrupaciones de tráfico (flotas). Componente MuTraff: *mutraff_genmaps* sobre python.
 - Mapas de pesos para escenarios específicos de demanda, optimizados para minimización de la congestión. Componente MuTraff: *mutraff_optimizer* sobre MatLab.

Para el análisis de resultados de aplicación práctica de TWM se ha empleado simulación microscópica con la herramienta SUMO descrita en el apéndice B así como la herramienta Mutraff y el resto de aplicaciones generadas en la tesis descritas en el apéndice D.

La simulación microscópica de los entornos TWM se realiza con *mutraff_simulator* que nos permite cargar escenarios de tráfico, realizar la asignación de mapas TWM de forma dinámica a los vehículos, hacer la reasignación de rutas dinámicamente en el tiempo, simular incidentes y restauraciones en la red, la interacción con otros simuladores microscópicos como SUMO, y la extracción de datos y resultados. En el apéndice D se puede encontrar mayor detalle.

Parte II

Artículos publicados que dan lugar a la
tesis

3

Urban Traffic Routing Using Weighted Multi-Map Strategies

En este capítulo se muestra el artículo publicado “Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment”. Tras una breve resumen de este, se muestran los datos sobre la publicación y su relevancia. Por último, se ha incluido una copia de la versión publicada del artículo.

3.1. Introducción

El principal factor de impacto en la movilidad de las personas en las áreas urbanas y metropolitanas, es la congestión del tráfico en sus vías de comunicación. Dicho impacto se traduce, entre otros efectos, en una reducción del tiempo global de tránsito y en un aumento de los niveles de emisión de gases y ruidos. Por ese motivo, se han dedicado numerosos estudios de investigación al modelo, caracterización, planificación y diseño de las vías urbanas, y a la propuesta de modelos para la gestión activa de dicha congestión.

La mayoría de los modelos implican la regulación del tráfico mediante señalización en la vía, la recomendación de rutas en función del estado del tráfico actual y en la proyección y predicción del mismo. Otros modelos implican la comunicación entre vehículos para el enrutamiento dinámico. En todos los casos, hay varios factores fundamentales comunes a todos ellos:

- La diversificación de las rutas seguidas por los vehículos para adecuar el uso a la capacidad teórica de las vías.

- La adherencia de los vehículos a los diferentes mecanismos de optimización.
- La disponibilidad o no de sistemas centralizados de control.

La estrategia de generación de diversidad de rutas mediante la distribución de diferentes conjuntos de mapas, TWM *Traffic Weighted Multi-Maps*, fue inicialmente presentada en el congreso PAAMS'19 (17th International Conference on Practical Applications of Agents and Multi-Agent Systems) [99]. Dicho congreso permitió la discusión y validación de la idea, que fue posteriormente desarrollada y completada en el estudio.

El artículo desarrolla la formulación completa del modelo TWM que se usará posteriormente en toda la investigación realizada, así como el catálogo de parámetros de análisis. TWM básicamente genera vistas de la red viaria del tráfico, desacoplándolas de la propia red. Se asume la existencia de un Centro de Control de Tráfico (TMC) que genera dichas vistas con arreglo a diferentes criterios. El artículo explora la asignación dinámica de tráfico mediante mapas TWM aleatorizados, y los efectos de obtener múltiples rutas en función del mapa seleccionado. La aleatorización se aplica a los pesos de los enlaces en la red, y para ello se emplean escalados lineales de los pesos aplicando distribuciones uniformes y normales.

En el artículo se analiza el impacto que tiene TWM sobre parámetros individuales y globales, así como su evolución en el tiempo. Entre los parámetros globales está el tiempo total de tránsito en la red, la distancia total recorrida por los vehículos, los niveles de emisiones de gases, los niveles de emisiones ruido, la evolución temporal del número de enlaces congestionados, la evolución temporal de vehículos congestionados, o la evolución de la velocidad media en la red. Entre los parámetros individuales se estudia principalmente el efecto sobre la mejora o empeoramiento del tiempo de viaje individual tanto para los vehículos que emplean TWM como para los que no lo hacen.

En función de la parametrización de los mapas, el nivel de congestión y el nivel de adherencia a TWM de los vehículos, se obtienen unas mejoras entre el 20 % y el 50 % de los parámetros considerados. No obstante, al aplicar criterios de SO, algunos vehículos salen perjudicados en beneficio de los demás, efecto conocido (*route unfairness*) y descrito anteriormente por [108, 11].

La publicación analiza también el caso de uso de aplicación de TWM a la resolución de la congestión provocada por incidentes en la red de tráfico.

El análisis de resultados de las estrategias TWM se realiza mediante simulación microscópica con el simulador SUMO [16] en escenarios de tráfico urbano real sobre la red de Alcalá de Henares descrita en el anexo. El artículo analiza también el caso de uso de la respuesta rápida a incidentes en la red mediante la redistribución de mapas que incluyan sobre el enrutamiento de los vehículos.

Los resultados obtenidos muestran cómo TWM puede ser empleado con éxito para la eliminación de congestión en redes urbanas tanto en escenarios de congestión estructural mediante mapas aleatorizados, como ante escenarios concretos con mapas específicos.

3.2. Relevancia de la publicación

Título	Urban Traffic Routing Using Weighted Multi-Map Strategies		
Autores	Paricio, A. y Lopez-Carmona M.A.		
Estado	Publicado	Fecha	10/feb/2019
		publicación:	
DOI	https://doi.org/10.1109/ACCESS.2019.2947699		
	Nombre	IEEE Access	
Revista	Editorial	IEEE - Institute of Electrical Electronics Engineers Inc.	
	País	EE.UU.	
	Revista (*)	Índice de Impacto:	3,745 / 4,076 (5 años)
Relevancia		JCR (2019):	Q1 (35/156)
	Artículo	Lecturas:	514
		Citas:	4

(*)IEEE Access tiene un factor de impacto de 3.745, un factor de impacto a 5 años de 4.076, un Eigenfactor de 0.08130, y una puntuación de influencia de artículos de 0.642 (Índice JCR-2019).

Fuente: IEEE Access <https://ieeaccess.ieee.org/about-ieee-access/frequently-asked-questions/>.

Calificación FECYT para IEEE Access disponible en <https://apps.webofknowledge.com/>.

3.3. Artículo

Received September 8, 2019, accepted October 6, 2019, date of publication October 16, 2019, date of current version October 31, 2019.

Digital Object Identifier 10.1109/ACCESS.2019.2947699

Urban Traffic Routing Using Weighted Multi-Map Strategies

ALVARO PARICIO^{ID} AND MIGUEL A. LOPEZ-CARMONA^{ID}

Departamento de Automática, Escuela Politécnica Superior, Universidad de Alcalá, Campus Universitario, 28871 Alcalá de Henares, Spain

Corresponding author: Alvaro Paricio (alvaro.paricio@uah.es)

This work was supported in part by the Spanish Ministry of Economy, Industry, and Competitiveness under Grant TIN2016-80622-P (AEI/FEDER, UE) and Grant TEC2013-45183-R (AEI/FEDER, UE).

ABSTRACT Urban traffic routing has to deal with individual mobility and collective wellness considering citizens, multi-modal transport, and fleet traffic with conflicting interests such as electric vehicles, local distribution, public transport, and private vehicles. Different interests, goals, and regulations, suggest the development of new multi-objective routing mechanisms which may improve traffic flow. In this work, *Traffic Weighted Multi-Maps (TWM)* is presented as a novel traffic routing mechanism based on the strategic generation and distribution of complementary cost maps for traffic fleets, oriented towards the application of differentiated traffic planning and control policies. TWM is built upon a centralized control architecture, where a Traffic Management Center generates and distributes customized cost maps of the road network. These maps are used individually to calculate routes. In this research, we present the TWM theoretical model and experimental results based on microscopic simulations over a real city traffic network under multiple scenarios, including traffic incidents management. Experimental evaluation takes into account driver's adherence to the system and considers a multi-objective analysis both for the global network parameters (congestion, travel time, and route length) and for the subjective driving experience. Experimental results deliver performance improvements from 20% to 50%. TWM is fully compatible with existing traffic routing systems and has promising future evolution applying new algorithms, policies and network profiles.

INDEX TERMS Dynamic traffic assignment, traffic control, traffic simulation, vehicle routing, traffic big data, decision making, multi-agent systems, multi-map routing, TWM.

I. INTRODUCTION

Modelling and design of traffic management systems and services have still important challenges to address, such as matching multi-objective demand and resources in an optimal and automated way. In one side *Traffic Control Systems (TCS)* measure and react over the traffic network (resources) to coordinate traffic demand by means of signaling systems, traffic information panels, and regulatory policies and restrictions [36]. In the other side, we have vehicles represented by their traffic agents, that plan routes dynamically, and react in real time to traffic data input: traffic network status, signaling directives and congestion information [35].

The need of individual route generation and dynamic re-planning from a TCS has been addressed by many different approaches and commercial proposals [1], [2], [5], [30].

The associate editor coordinating the review of this manuscript and approving it for publication was Longxiang Gao^{ID}.

Many of them require complex architectures and intense computing resources, raising as well important privacy concerns.

From the driver perspective, the main objectives are to reduce and minimize travel time and route cost, considering risk-aversion and time-bounding (predictability). New mobility paradigms for smart-cities and Urban Computing concept [51] also focus on collective objectives considering citizens, multi-modal mobility, and conflicting group interests: safety, electric mobility, car-sharing, air pollution, noise footprint, special fleets requirements, scheduled traffic constraints, geo-fenced policies, event planning and fast reaction, and public transportation.

Optimal traffic planning in TCS must consider and handle all these factors, implementing new multi-objective cost functions and the corresponding control models. This smart mobility management may be enabled by the use of big data techniques [25], [26] that handle the dynamic generation of tons of information from city sensors and mobile agents on devices.

Our research is based on the fact that a traffic map is not the same as the traffic network but just a representation of it, a view. This view describes both physical features (lanes, distances, lat/long, etc) and logical features that are conventions (lane directionality, speed, time-restrictions, weights, etc). We propose a novel traffic route guidance model called *TWM -Traffic Weighted Multimaps-* based on the generation and distribution of complementary cost maps for traffic collectives (vehicles groups and/or fleets), oriented towards the application of differentiated traffic planning and control policies. TWM takes into account that traffic collectives may have different interests, policies, and constraints, so it makes sense to offer them differentiated network views (maps).

TWM proposes the distribution of multiple maps with different link weights, based not only on speed but also on the result of applying a multi-objective cost function. Optimization in TWM is achieved by a) finding the optimal weight values and map sets for the defined traffic groups, and b) considering that only a percentage of drivers are going to use or follow the recommendations. Individuals belonging to the same group (fleet) share a group of maps. This group and time assignment reduces the computational complexity of the approach. There is a trade-off between individual optimal route and global objectives fulfillment. In our research we show how the aggregation of individual decisions tends to satisfy the predefined control policy.

Traffic Weighted Multimaps approach is shown to be technically feasible and easy to deploy, being compatible with current platforms and navigation systems. It requires few resources to be implemented, and preserves individual's privacy. Compatibility with existing routing frameworks based on route-queries for origin/destination (O/D) is obvious, as TWM can be applied at the TCS back-end when the user asks for a route or an hyper-path.

Global traffic optimization may be then achieved by means of TWM generation algorithms, based on data-driven with machine learning approaches and predictive control techniques. In this paper we focus on the effects of multimaps on travel time and route length using randomly generated weights for traffic dispersion in real urban traffic network. We study both global effects and individual perceptions.

The main contributions of this paper include: (1) a novel traffic route guidance model based on multimap distribution that enable differentiated route selection for individuals and collectives; (2) a microscopic simulation framework for TWM evaluation and algorithm comparisons; (3) impact analysis of TWM in congestion scenarios; (4) TWM usage proposal for incident management, and (5) experimental results based on simulations over a real urban network. The research has promising future evolution applying TWM calculation algorithms, distribution policies and network profiles.

The paper is organized as follows: first we review previous studies and similar references, then we present the conceptual framework that we will use throughout the paper. After that, we present a real traffic network (Alcala de Henares,

a Spanish mid-size city) with real multi-fleet demands. The experiments show the TWM positive effects on global network congestion indicators, and on individual driving experiences. To conclude, the paper analyses simulations of traffic incidents in real city scenarios and how they are addressed by ad-hoc multi-maps to avoid congestions and enhance end-user experience. Finally we present our conclusions and show future research lines on the TWM topic.

A. BACKGROUND

We introduced TWM in [38] as a very preliminary proof of concept of congestion mitigation mechanism for a synthetic 16x16 grid network. TWM are created by a *TMC (Traffic Management Center)*, which enables intelligent congestion control as a global concern together with individual routing needs.

Global parameters such as pollution level, noise footprint, prioritization of vehicle type, contingency plans, etc, are well described in [8], [9]. Individual intention-aware routing proposals can be found at [13] and [46], that are sometimes used for predictive routing [12] and [16]. There are other works that propose collaborative RGS (Routing Guidance Systems) systems fed by a traffic control center using Big Data mechanisms to compute mobility management policies in both distributed and centralized schemes [27], [40], [44]. They usually require permanent inter-connectivity between vehicles and authorities.

In the same way, there are many multi-agent traffic management proposals such as those reviewed in [7], [10], [35]. They use different approaches such as automatic negotiation, distributed optimization, predictive routing, predictive control, and others [31], [32]. Genetic algorithms are also used for cooperative vehicle coordination as described in [14], [15]. Electric vehicles and their concerns related to charging stations, receive specific attention and several works deal with them [44], [48].

TWM is fully compatible with the hyper-path concept, where individual traffic agents receive for each origin and destination not a single route but a tree of alternatives [11], [23], [34], [41]. Hyper-path route calculus considers the uncertainty and variability of traffic dynamics, and uses mainly historical data as traffic behavior patterns where different analysis methods can be applied [19], [29], [33]. Hyper-path calculus to synthesize the pre-trips require a lot of back-end computing while receiving data streaming for the network and the mobile agents, and also en-route distribution is required to the distribution servers. TWM is complementary to hyper-paths providing different network views for the individuals of any traffic class. This network view can be used for the hyper-path calculus. TWM is multi-purpose and combines individual, group and global policies, in contrast with hyper-path that is conceived for individual risk-averse policies design (minimizing travel-time variance).

TWM relies on a traffic control system architecture which may implement a distributed control in closed loop of routes for the vehicles [30], [37], with capacities of planning

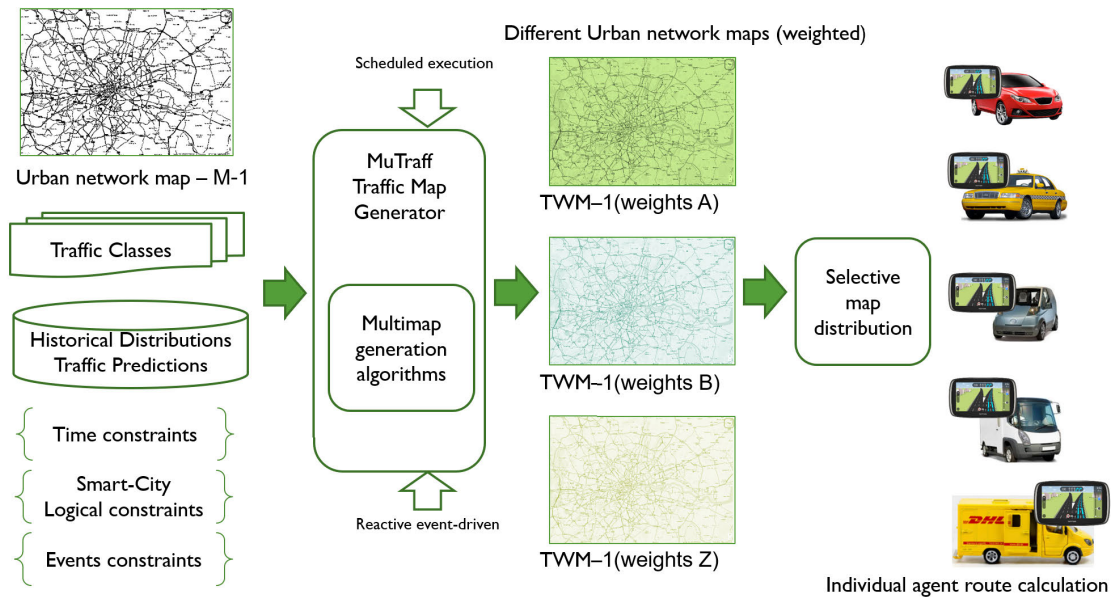


FIGURE 1. Overview of TWM generation and distribution model.

and re-planning. There is no individual feedback about selected route or current trip (no microscopic feedback) but there is mesoscopic feedback collected through standard sensors and cameras that provide measures about traffic congestion and speeds.

Most of the navigation systems (RGS) that operate today suggest the shortest route and hyper-path, derived from real-time traffic density information and historical data [1], [2], [5], [6]. Traffic agents use these recommendations to make their individual decisions based on this common information: they use the same network view and the same traffic data. Agents that are traveling from similar origin/destination or just share common paths will take very similar decisions, causing traffic congestion to be transferred. This is the so-called “*common resource distribution problem*”, from which the so-called “*Minority Game*” or “*Farol Bar Problem*” [43] derives. It is therefore clear that there is a need for more precise control of vehicle routes, that requires precise individuals feedback and/or highly distributed sensor networks [24], [42], [50]. This control could be exercised through individualised management at the microscopic level of each route. However, microscopic control entails problems of scalability, deployment and privacy, so TWM proposes an alternative, scalable, non-disruptive control and management methodology with low communication load, limited feedback and thus fewer implications for users’ privacy.

Similar strategies have been used with IP routing protocols (MSTP) and SDN networks [18], [22], [28], [39]. These IP traffic engineering techniques assume that the network operators modify link-weights dynamically to achieve routing paths that obtain the required traffic goals (such as latency and congestion).

Our architecture proposal uses a big-data module based on data lake pattern where all the activity is stored in a log-oriented basis. It enables inference of historical traffic patterns that are used to calculate and design TWM. References [17], [21], [45] have recently proposed similar approaches for data-clustering and pattern detection.

II. DEFINITIONS

A. TWM - TRAFFIC WEIGHTED MULTIMAPS

A TMC can generate differentiated network maps for every traffic group of agents (fleets), using cost functions that assign weights to the links of the network, just altering the max speed concept (that is in fact a fixed cost function). Moreover, it could provide time-dependent maps valid only for certain time frames.

These maps can be created considering several sources: historical data, real-time traffic data, real-time events affecting mobility (non-traffic data, but affecting the demand, such as sport events, critical incidents and others), and of course, synthetic data extracted from big-data sources. Figure 1 illustrates the basics for TWM generation.

Instead of having a heavy set of regulation, signaling, geo-fenced constraints that every individual should process, evaluate, and execute, it is easier to have them collected into traffic map collections that are used by the individuals for route selection.

TWM generation is executed in two possible time-policies: 1) in a scheduled way following traffic density loads (daily and hourly in a typical configuration), 2) in a reactive way, conditioned by events (incidental or planned ones).

These multimaps provide a different routing weights set for each fleet at each edge. For instance, a city center will have different network map sets for the fleets taxi,

electric vehicles, logistic distributions, and conventional cars. The edge weights will be different for each fleet, promoting or penalizing traffic for each edge. Of course, these maps can be static or time-dynamic, depending on multiple strategies.

O/D route calculation can be generated by the individuals using the network maps and the navigation application, but also can be generated by a TCS that receives the origin-destination requests for route and delivers a set of possible routes [30]. In both cases, multimap approach is valid as it considers optimal route evaluation against a weighted map. It is always the individual who decides which route/path to use.

As stated above, traffic classes are subsets of mobile elements (that we will call fleets) that share similar a) traffic goals, b) network constraints, c) regulations, d) traffic indicators and e) individual behaviors.

Privacy and data protection are main concerns in modern routing systems [20]. TWM prevents individual data exposure, as the traffic agent self-qualifies for a fleet that is used for map selection upon those distributed in the TWM. For the server-side route recommendation mode, the agent should provide its fleet qualification in order to obtain the corresponding TWM for it.

B. MODEL FORMULATION

TWM can be expressed by a formulation including the multimap, routing and agent perspectives. Together with the formulation, we include as well the simulation model that is used in the experimental part of the paper. Table 1 summarizes basic TWM notation.

1) TWM MULTIMAPS

A TWM multimap function Π (1) takes as inputs a traffic network Θ , a set of traffic groups $[\Omega_k]$ (called *fleets*), a set of time constraints $\Gamma_{k,m}$ and a dynamic view Φ of the traffic usage of the network, in order to obtain a set of network maps $[\mu_{k,m}]$.

$$\Pi : \Theta, [\Omega_k], [\Gamma_{k,m}], \Phi \rightarrow [\mu_{k,m}] \quad (1)$$

In this paper we address static traffic routing with TWM, leaving the dynamic routing based on Φ using different routing algorithms (not only Dijkstra) for future works.

In general, each traffic group Ω_k has a set of map instances $[\mu_{k,m}]$ as a customized representation of the traffic network Θ , under certain time constraints $[\Gamma_{k,m}]$. There are two main types of time constraints $[\Gamma_{k,m}]$: those formed by periodic scheduled constraints (i.e. traffic restrictions over certain hours) and eventual time constraints (i.e. works, demonstrations, etc).

Urban areas Θ have a standard traffic network representation (2) formed by a directed graph of geographical nodes η_n connected by edges, being each edge $\epsilon_{i,j}$ a set of links (lanes) that connects nodes η_i and η_j with a weight $\beta_{i,j}^{k,m}$ as expressed by the tuple:

$$\Theta = \{[\eta_n], [\epsilon_{i,j}]\} \quad (2)$$

TABLE 1. Notation summary.

Θ : Urban network representation.
 Φ : Traffic density data of the urban network.
 Ω_k : Traffic vehicle grouping (fleet) for using TWM.
 Ω_0 : Generic vehicle group for TWM-unclassified vehicles.
 $[\mu_{k,m}]$: TWM multimap for urban network Θ .
 $\mu_{k,m}$: Single map instance (m) for vehicle group Ω_k . A group may use several maps.
 Π : multimap weight evaluation functions.
 Π_{std} : Standard map weight evaluation functions.
 Π_δ : Traffic weight evaluation function used for TWM creation (*).
 (*) δ indicates the weighting factor based on a distribution function, an optimization algorithm, or any other weighting criteria.)
 $\Gamma_{k,m}$: Time constraints for map $\mu_{k,m}$.
 η_n : Traffic network node for area inside traffic network Θ .
 $\epsilon_{i,j}$: Edge connecting nodes η_i and η_j .
 $\beta_{i,j}^{k,m}$: Traffic weight for edge $\epsilon_{i,j}$ for map $\mu_{k,m}$.
 $S_{i,j}$: max speed for edge $\epsilon_{i,j}$.
 $[v_a^k]$: Vehicle population.
 Δ_m : TAZ, traffic assignment zone.
 ψ_k : TWM adherence factor of fleet Ω_k .
 W_a^k : Individual trip of vehicle v_a^k from origin O_i to destination D_j .
 $[P_a^k]$: Sets of planned stops for the trip W_a^k .
 $R_a^{k,m}$: Route selected at vehicle v_a^k for its trip W_a^k using the map $\mu_{k,m}$.
 f : Routing algorithm: Dijkstra, A*, etc.
 RL_a^k : route length for vehicle v_a^k for its trip W_a^k .
 TT_a^k : travel-time for vehicle v_a^k for its trip W_a^k .
 STT_a^k : total congested time for vehicle v_a^k for its trip W_a^k .
 MTT_a^k : total non-congested time for vehicle v_a^k for its trip W_a^k .
 DTD : Ratio of completed traffic demand.
 NHD : Halted demand of vehicles.
 TTS : Total travel-time spent by the vehicles during the period.
 THS : Total halted travel-time spent by the vehicles during the period.
 VKT : Cumulative route lengths of trips.
 TTC : Individual travel-time improvement when using TWM.
 RLC : Individual trip-length improvement when using TWM.

$$\epsilon_{i,j} = (\eta_i, \eta_j, \beta_{i,j}^{k,m}) \quad (3)$$

Each TWM map $\mu_{k,m}$ is an instance of specific values for each weight $\beta_{i,j}^{k,m}$. As a proof of concept we propose a multi-map Π_{std} that just considers linear scaling α of link-speed $S_{i,j}$ for providing each edge weight $\beta_{i,j}^{k,m}$:

$$\Pi_{std} : [\epsilon_{i,j}], [\Omega_k], [\Gamma_{k,m}] \rightarrow [\mu_{k,m}] \mid \beta_{i,j}^{k,m} = \alpha * S_{i,j} \quad (4)$$

In our initial experiments, we have tried normal and uniform functions (5) to create weight distributions that allow

traffic dispersion in the network. These perspectives are created scaling weights by a factor δ determined by distribution functions $\delta_{normal} = normal(a, b)$ (a stands for the mean value and b stands for the statistical dispersion amplitude) and $\delta_{uniform} = uniform(a, b)$ (ranging from a to b):

$$\Pi_{\delta} : [\epsilon_{i,j}], [\Omega_k], [\Gamma_{k,m}] \rightarrow [\mu_{k,m}] | \beta_{i,j}^{k,m} = \alpha * S_{i,j} * (1 + \delta) \quad (5)$$

Design of optimal TWM weight distribution functions Π_x will be subject of future research, considering factors such as: network topology, vehicle fleets, historical traffic data, real-time traffic information and time constraints.

2) TRAFFIC DEMAND, ROUTING AND AGENTS

We assume a mobile population of $[v_a^k]$ vehicles grouped by $[\Omega_k]$ fleets. Those vehicles that do not belong explicitly to a fleet are assigned to the standard Ω_0 fleet. The percentage of vehicles that effectively use TWM at any time is called the adherence factor ψ :

$$\psi = \frac{\sum [v_a^k]_{TWM}}{\sum [v_a^k]} \quad (6)$$

Vehicles generate $[W_a^k]$ trips during observation epochs. Each trip, as described in (7) is composed by the vehicle identification, the starting timestamp, the starting point (origin node) O_a , the destination point (node) D_a and a tuple with possible intermediate stops $[P_a^k]$:

$$W_a^k = f(v_a^k, t_a^0, O_a, D_a, [P_a^k]) | \forall v_a^k \in \Omega_k \quad (7)$$

Traffic demand is grouped by geographical areas called TAZ (traffic assignment zones, Δ_m) that summarize trips as traffic flows, for all the trips starting in the same geo-fenced area.

For the map-distribution approach, depending on each concrete time epoch, each fleet may have a specific navigation map set $[\mu_{k,m}]$. In client-based routing, each map $\mu_{k,m}$ is distributed to its individuals (on-demand or by publication to subscriptions) and in server-based routing the map is used for individual route calculation. Vehicles not classified or in general belonging to standard Ω_0 fleet use the standard map.

The routing agent will calculate for each trip the best route $R_a^{k,m}$ or hyper-path using the corresponding map (standard or ad-hoc received multimap). This calculation uses some of the available routing algorithms \hat{f} (Dijkstra, A*, etc). Presented experiments use Dijkstra.

Non-TWM users will use the standard default road map Ω_0 for best-route calculation and the TWM users will use the corresponding map from the offered set according to the selected policy (per fleet for instance) as shown in:

$$R_a^{k,m} = \begin{cases} \hat{f}(O_i, D_a^k, [P_a], \mu_{k,m}) & v_a^k \in [v_a^k]_{TWM} \\ \hat{f}(O_i, D_a^k, [P_a], \mu_0) & v_a^k \notin [v_a^k]_{TWM} \end{cases} \quad (8)$$

Travel-time TT_a^k taken by each vehicle v_a^k is the sum of the partial travel times at each edge, and can also be expressed as

a composition of congested STT_a^k and non-congested times MTT_a^k . We will use these parameters for individual and global performance:

$$TT_a^k = STT_a^k + MTT_a^k \quad (9)$$

Distance RL_a^k run by each vehicle is expressed as:

$$RL_a^k = \sum length(\epsilon_{i,j}), \quad \epsilon_{i,j} \in R_a^{k,m} \quad (10)$$

For traffic routing performance analysis, we consider at every timestamp t those trips that have been already completed $[W_a^k]_{end}^t$, those that have been started $[W_a^k]_{run}^t$ and not completed $[W_a^k]_{pend}^t$, and those that haven't been started yet (11):

$$[W_a^k]_{total}^t = [W_a^k]_{end}^t \cup [W_a^k]_{run}^t \cup [W_a^k]_{pend}^t \quad (11)$$

3) OPTIMIZATION OBJECTIVES

There are two sets of optimization objectives: global objectives such as congestion or pollution, and individual objectives such as travel-time, trip cost or route length. Individual performance measurement is critical for TWM as it influences drivers' confidence: multiple positive individual adoptions would enable viral adoption of the multimap recommendations.

These variables can be measured and optimized globally for the whole network of by fleet. Some of the objectives can be expressed and measured at every single network edge and are marked with (*).

• Global network objectives:

- *Dispatched traffic demand: DTD^t* as the percentage of routed demand compared against the total traffic demand exposed to the network:

$$DTD^t = \frac{card([W_a^k]_{end}^t)}{card([W_a^k]_{total}^t)} \quad (12)$$

- *DTD_{TWM} as successfully TWM routed traffic*, as ratio of TWM routed traffic versus incoming traffic:

$$DTD_{TWM} = \frac{card([W_a^k]_{TWM})}{card([W_a^k]_{total})} \quad \begin{cases} | W_a^k \in [W_a^k]_{end} \\ | v_a^k \in [v_a^k]_{TWM} \end{cases} \quad (13)$$

- *TTS^t total time spent by the vehicles* in the traffic network:

$$TTS^t = \sum TT_a^k | W_a^k \in [W_a^k]_{end}^t \cup [W_a^k]_{run}^t \quad (14)$$

- *THS^t , Total Halting Time (Congestion Time, Waiting time) (*)*, as the total sum of halting times of the vehicles in the network:

$$THS^t = \sum STT_a^k | W_a^k \in [W_a^k]_{end}^t \cup [W_a^k]_{run}^t \quad (15)$$

- NHD^t , Number of halted demand (vehicles) (*):

$$NHD^t = \text{card}\left(\left[v_i^k\right]\right) \\ | W_a^k \in \left[W_a^k\right]_{end}^t \cup \left[W_a^k\right]_{run}^t \\ | \text{speed}(v_i^k) \leq 0.1 \quad (16)$$

- VKT total distance traveled by the vehicles that started their trips in the network:

$$VKT^t = \sum RL_a^k | W_a^k \in \left[W_a^k\right]_{end}^t \cup \left[W_a^k\right]_{run}^t \quad (17)$$

- *Edge traffic* (*): number of vehicles, mean speed, edge occupancy.
- *Gas Emissions* (*): CO, CO₂, HC, PM_x, NO_x of vehicles (as stated by HBEFA fleet assignments). SUMO simulator provides these edge measures.
- *Consumption* (*): fuel, electricity.
- *Noise emissions* (*). SUMO simulator provides this edge measure.
- *Individual objectives*, comparing how all the individuals¹ are being affected by TWM adoption versus the non-TWM standard situation (marked as experiments *no-TWM* and *TWM*). They are measured using paired statistics in simulations, comparing every individual trip between the standard routing scenario and the TWM routing scenario. Relative change is considered for improvement analysis, though in certain circumstances the absolute value analysis could be relevant from the user's subjective perspective.
 - TTC_{rel}^k *Individual relative travel time change* (as a percentage over original travel time), where $TT_a^{k|noTWM}$ and $TT_a^{k|TWM}$ denote travel-time of a single trip using TWM or not respectively:

$$TTC_{rel}^k = \frac{TT_a^{k|noTWM} - TT_a^{k|TWM}}{TT_a^{k|noTWM}} \quad (18)$$

- RLC_{rel}^k *Individual route length relative change* (as a percentage over original route length), where $RL_a^{k|noTWM}$ and $RL_a^{k|TWM}$ denote route-length of a single trip using TWM or not respectively:

$$RLC_{rel}^k = \frac{RL_a^{k|noTWM} - RL_a^{k|TWM}}{RL_a^{k|noTWM}} \quad (19)$$

- *Individual consumption*: fuel, electricity.

4) TWM SIMULATION MODEL

The simulation model explores some of the concepts used in the formulation. The following variables are considered for our traffic impact analysis with TWM.

- *Network variables*:

¹Whole vehicle population including TWM and non TWM users

- *Topology of urban network* ($\Theta_n = \{[\eta_k^n], [\epsilon_{i,j}]\}$). We consider in our experiments a real city network.

- *Traffic demand variables*:

- *Types of urban traffic* (Ω_k) where we distinguish typically fuel-cars, zero-emissions cars, taxis, commercial distribution, buses and motorcycles among others, or even emission models classification such as HBEFA or similar standards.
- *Traffic zones* (TAZ, Δ_m) to generate in/out and internal traffic inside the network.
- *Traffic demand density* ($[T_j^k]$), expressed by number of trips.
- *Traffic demand directionality*, where we have tested both crossing and internal traffic. Real scenarios combine both types of traffic.

- *Multi-map variables*:

- *TWM enabled/disabled*.
- *TWM cardinality*, or number of maps to distribute and apply, to check out which number of maps will be the best option for each situation. We use in our experiments 2^n maps $\{0, 1, 2, 4, 8, \dots\}$.
- *TWM, weight distribution functions* Π , using $\beta_{i,j}^{k,m}$ factor to increase current path weights, and thus impacting route calculus. Current functions implemented are the Π_{std} and Π_δ with normal and uniform distributions. Some weight factors are:
 - * No influence: $\beta_{i,j}^{k,m} = 1$.
 - * Random Low weight, using $\beta_{i,j}^{k,m} = \alpha * S_{i,j} * (1 + \text{normal}(0.5, 0.5))$.
 - * Random High impact, that will apply a normal distribution using $\beta_{i,j}^{k,m} = \alpha * S_{i,j} * (1 + \text{normal}(2, 0.5))$.
 - * Uniform Low and High impact, using the uniform functions instead of the normal ones.
- *TWM time triggering* ($[\Gamma_{k,m}]$): Time constraints for TWM $[\mu_{k,m}]$, reflecting the time instant where the multimaps are applied. This is used to check if maps are used to avoid congestion before it occurs, or used to help congestion clearance while it is occurring. We use:
 - * *Always on*.
 - * *When-congested*, where the vehicle uses multi-map when congestion is detected or forecasted.
 - * *On incident* occurrence or clearance.
 - * *On schedule* to set time and Geo constraints in the traffic network.

- *Routing algorithms*:

- *TWM route selection* algorithm \mathcal{F} . We support both Dijkstra and A* for the initial experiments ([23], [47], [49]).

Route selection, can be used at centralized route delivery where the agent requests the best route to follow, or decentralized where the agent calculates the best route by itself.

TABLE 2. Traffic fleet composition.

Fleet	%	Traffic mix	Use TWM
Car	44%	random + directional	Yes
Taxi	33%	random + directional	Yes
Bus	11%	random + directional	No
Motorcycle	11%	random + directional	Yes

TABLE 3. Driver adherences.

Adherence	Value
Early adopter	5%
Small confidence	10%
Mid confidence	20%
Big confidence	50%
full adoption	100%

- MTA Agent variables (individual / vehicle):
 - MTA multimap adherence ψ_n , or n -percentage of vehicles that use TWM in the traffic network. ψ_n is composed by the specific $\psi_{n,k}$ adherences at each fleet Ω_k . In this paper we use the aggregated value ψ_n .

III. APPLICATION OF TWM TO URBAN TRAFFIC

To demonstrate the feasibility of traffic weighted multi-maps, we created a simulation engine that is based on the microscopic simulator SUMO [9] and apply TWM to real urban networks under free-flow and congested conditions.

Considering the traffic demand as a main parameter, several profiles have been created to reproduce situations of low, normal and high levels of traffic congestion. Two types of traffic are used: internal traffic are those trips with random origins and destinations, while directional traffic is formed by trips that cross the whole network.

Several fleets are considered and shown in Table 2. Bus traffic won't use TWM as they follow prefixed routes.

To study TWM impact on traffic use several driver adherences ψ_n as percentage of vehicles effectively using the new routing recommendations. They are shown in Table 3.

For results analysis several diagrams are used:

- 1) Histograms to represent travel-time distributions, both global and individual. In these histograms we add both mean and median values to show how overall behavior has changed.
- 2) Evolution of traffic congestion in time, measuring the number of congested traffic nodes, mean network speeds and number of halted vehicles.
- 3) Histograms to represent individual improvement (positive or negative) of travel-time. It can be absolute or relative, and is zero-centered: positive values show how many vehicles have reduced their travel-time, and negative just those who have been impacted.

TABLE 4. Alcalá de Henares TAZ composition.

TAZ	NAME	DESCRIPTION	USAGE
90	Center	Downtown	Residential
91	Espartales	New neighborhoods	Residential
1	E-5	Highway	In+Out+Cross Traffic
2	E-5	Highway	In+Out+Cross Traffic
3	M-100	Road	In+Out+Cross Traffic
4	M-100	Road	In+Out+Cross Traffic
5	M-300	Road	In+Out+Cross Traffic
6	M-300	Road	In+Out+Cross Traffic
7	M-119	Road	In+Out+Cross Traffic
8	M-121	Road	In+Out+Cross Traffic
50	Cuadernillos	Molls & Supermarkets	Commercial
51	La Garena	Molls & Supermarkets	Commercial
60	Universidad	University & Hospital	Services
70	Industrial North	Industry	Industry
71	Industrial West	Industry	Industry

- 4) Cumulative probability of individual travel-time improvement to see the impact of TWM.

A. REAL CITY NETWORK EXPERIMENTS

We have used the traffic network from Alcalá de Henares to test the TWM framework. It is a mid-size city of 250K population, located at 30km north-east of Madrid, Spain.

1) URBAN NETWORK DESCRIPTION

This city is a good experimental scenario as it has a middle-age downtown with heavy traffic restrictions and pedestrian areas, tourism, administrative facilities and residential usages causing high density of internal traffic demand. The city has around the downtown extensive industrial, commercial and citizen service areas (hospitals, wide-area university campus and others). The city is crossed east-west by an intensive highway connecting Madrid and Barcelona. Due to the closeness to the airport and Madrid's business center, there is a heavy daily traffic in and out caused by people going to and from their workplaces. Also, the city has heavy traffic exchange with the surrounding villages.

We have identified the traffic flows in the city using Traffic Area Zones (TAZ) as shown in Figure 2 and in Table 4. We consider TWM adherences of $\psi_{0.1}$, $\psi_{0.2}$, $\psi_{0.5}$ and ψ_1 . Traffic types (fleets) distribution is shown in Table 2.

2) CONGESTED TRAFFIC NETWORK USING 16-TWM

Our simulation includes traffic flows between all the TAZ estimated using real data which correspond to heavy traffic hours. Several sources have used for data curation: public APIs, private crowd-sensing and city local traffic service web [3], [4]. Demands estimations are shown in Table 5. We select a 3 hours simulation.

To execute our TWM evaluation, we use a TWM with 16 maps that will be uniformly distributed and used by the fleets with the probability distribution shown in Table 6.

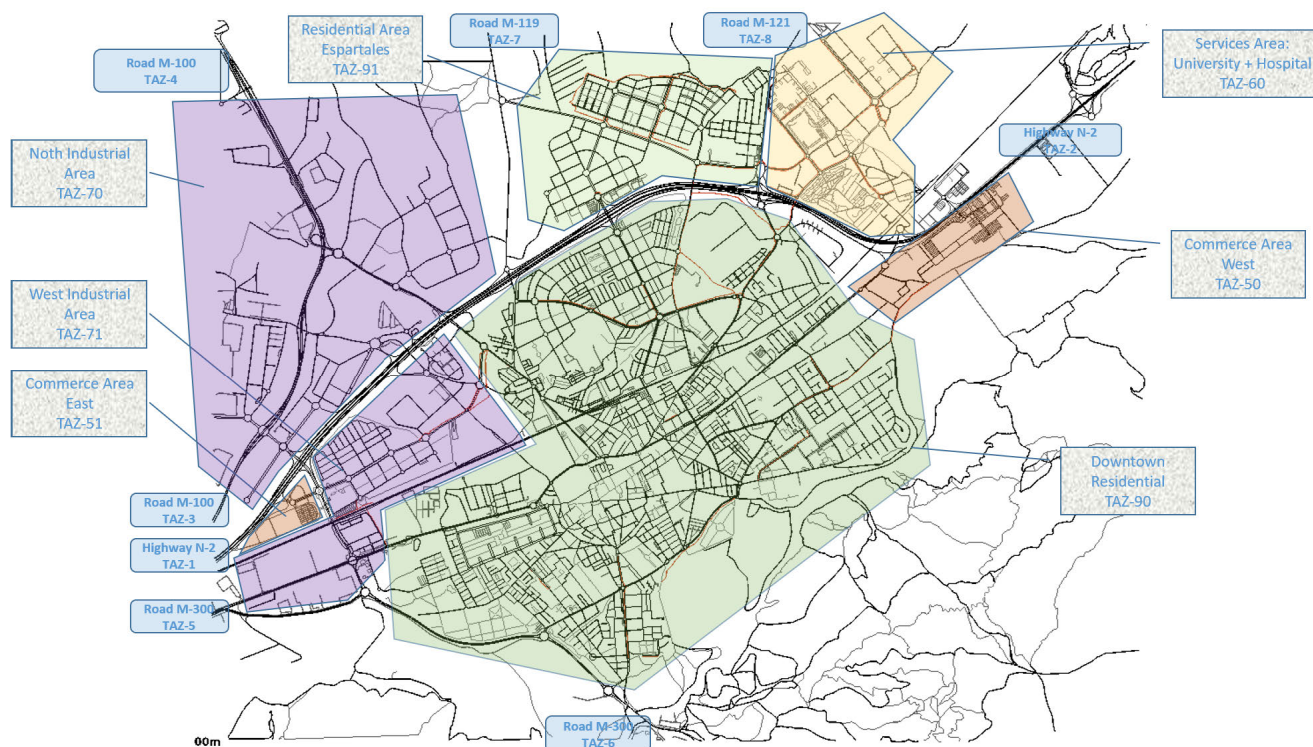


FIGURE 2. Alcalá de Henares traffic network and TAZ mapping.

TABLE 5. Alcalá de Henares traffic demands.

TRAFFIC ORIGIN	TRAFFIC DESTINATION															
	TAZ-90	TAZ-91	TAZ-1	TAZ-2	TAZ-3	TAZ-4	TAZ-5	TAZ-6	TAZ-7	TAZ-8	TAZ-50	TAZ-51	TAZ-60	TAZ-70	TAZ-71	
TAZ-90	8000	200	800	800	400	400	1000	400	400	400	200	200	200	100	100	
TAZ-91	200	100	300	300	150	150	100	100	100	100	100	100	100	50	50	
TAZ-1	800	500	2000								100	100	200	200	200	
TAZ-2	800	500	2000								100	100	200	200	200	
TAZ-3	400	100	400	400	1000						100	100	100	50	50	
TAZ-4	400	100	400	200	1000						100	100	100	50	50	
TAZ-5	800	100				400					100	100	100	50	50	
TAZ-6	800	100		400		1000					100	100	100	50	50	
TAZ-7	400	100	300	100							100	100	100	50	50	
TAZ-8	400	100	300	100							100	100	100	50	50	
TAZ-50	200	100	100	100	100	100	100	100	100	100				50		
TAZ-51	200	100	100	100	100	100	100	100	100	100				50		
TAZ-60	200	50	200	200	100	100	100	100	100	100				50	50	
TAZ-70	100	50	200	200	50	50	50	50	50	50				50		
TAZ-71	100	50	200	200	50	50	50	50	50	50				50		

TABLE 6. TWM usage distribution on traffic classes.

Fleet	μ_0	μ_1	μ_2	μ_3	...	μ_{16}
Bus	1.0	0	0	0	...	0
Car	0	0.063	0.063	0.063	...	0.063
Taxi	0	0.063	0.063	0.063	...	0.063
Motorcycle	0	0.063	0.063	0.063	...	0.063
Truck	0	0.063	0.063	0.063	...	0.063
Trailer	0	0.063	0.063	0.063	...	0.063

Bus use map μ_0 for their fixed routes. Routing uses Dijkstra algorithm.

TWM maps have been generated using the Uniform Random High Impact Π_δ . The configuration file is shown in Figure 3.

```
<?xml version="1.0" encoding="UTF-8"?>
<maps>
  <!-- car -->
  <map tag="car" prob="0.0625" file="map.alcalahenares.uni5.rand.1.xml" />
  [...]
  <map tag="car" prob="0.0625" file="map.alcalahenares.uni5.rand.16.xml" />
  <!-- taxi -->
  <map tag="taxi" prob="0.0625" file="map.alcalahenares.uni5.rand.1.xml" />
  [...]
  <map tag="taxi" prob="0.0625" file="map.alcalahenares.uni5.rand.16.xml" />
  <!-- motorcycle -->
  <map tag="motorcycle" prob="0.0625" file="map.alcalahenares.uni5.rand.1.xml" />
  [...]
  <map tag="motorcycle" prob="0.0625" file="map.alcalahenares.uni5.rand.16.xml" />
  <!-- bus -->
  <map tag="bus" prob="1" file="map.alcalahenares.reference.mapR.xml" />
  <!-- truck -->
  <map tag="truck" prob="0.0625" file="map.alcalahenares.uni5.rand.1.xml" />
  [...]
  <map tag="truck" prob="0.0625" file="map.alcalahenares.uni5.rand.16.xml" />
  <!-- trailer -->
  <map tag="trailer" prob="0.0625" file="map.alcalahenares.uni5.rand.1.xml" />
  [...]
  <map tag="trailer" prob="0.0625" file="map.alcalahenares.uni5.rand.16.xml" />
</maps>
```

FIGURE 3. 16-TWM composition.

3) GLOBAL TRAFFIC EVOLUTION USING 16-TWM RANDOM MAPS

We can see the impact of using TWM over travel-times in Figure 4 and Table 7, that compare traffic evolution of a congested scenario under two situations: no TWM usage and TWM usage with certain driver adherence. Travel-time is measured in the simulation for every single trip from departure to arrival. The histograms represent number of trips per travel-time duration. We have selected traffic histograms for the highest adherences as it easier to observe how




FIGURE 4. Alcalá de Henares simulation, TWM impact on TT with $\psi_{0.5}$ and ψ_1 adherences.

TABLE 7. Alcalá de Henares simulation, TWM impact with $\psi_{0.1}$, $\psi_{0.2}$, $\psi_{0.5}$ and ψ_1 adherences.

16 maps - uniform05		No TWM	10%	20%	50%	100%
Traffic	Demand	18694	18694	18694	18694	18694
	Using TWM	0	1846	3731	9385	18694
	Routed	17895	17667	18067	18042	18447
	% Routed, DTD	-	-1.27%	0.96%	0.9%	3.08%
Travel time TT	Mean		-3.41%	-4.75%	-9.17%	-19.60%
	Median		-2.93%	-7.25%	-21.28%	-34.70%
Route Length RL	Mean		1.10%	0.73%	1.59%	1.90%
	Median		0.00%	0.00%	2.27%	2.27%

TWM affects travel-time: the number of vehicles with shorter travel-times increases (peaks in the left side). The right side of each histogram shows local peaks where some vehicles are taking longer to complete their trips: TWM adoption moves this peak to the left shortening travel-times. We can also see how mean and median travel-times are reduced, flattening the curves and affecting all the trips in an homogeneous way. Travel-time gets improved when driver's adherence to TWM usage grows, ranging to 19,6% of improvement in the full-adherence scenario. The scenario considers the whole traffic network with many different fleets and types of roads: from small one-way edges to a big crossing high-way with 6 lanes in two senses. Traffic and congestion are strong heterogeneous in the scenario, and TWM provides routing alternatives for congested edges.

Not only travel-time (TT) is improved but also the routed traffic demand (for the time interval considered): the TWM scenario is routing 3,1% more vehicles. It is the *multimap route clearing effect*: TWM is reducing global congestion when drivers select the alternative best-cost routes.

The penalty of using TWM is reflected in route lengths, which grow slightly due to the fact of using alternative maps, but mean affection is just 1.9%. If we consider the 19.6% reduction in mean travel-time against 1.9% of mean route change we can consider that the balance of using TWM is worthy.

From the previous results we would expect that the global congestion measures get also positively affected in terms of:

- Reducing number of congested edges.

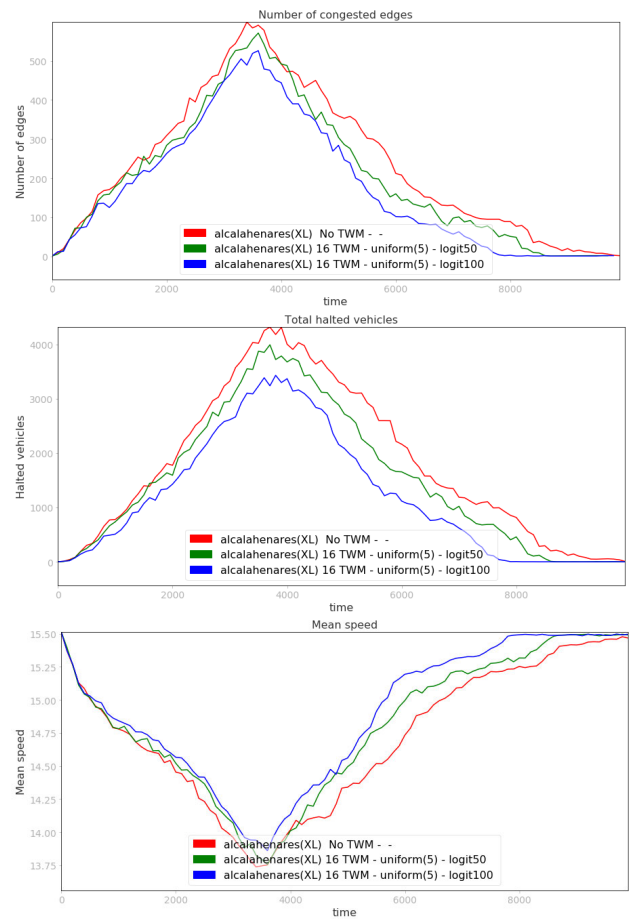


FIGURE 5. 16-TWM number of congested nodes, halted vehicles and mean speed.

- Reducing number of halted vehicles.
- Increasing mean speed in the network.

In Figure 5 we can observe how global network variables evolve in time for different vehicles adherences. The traffic network gets progressively congested while traffic demand is growing being able to route completely at the end of the simulation. The graphs confirm our hypothesis as the three mentioned indicators are significantly improved:




FIGURE 6. Alcala de Henares, TTC_{rel} travel-time relative individual experience with $\psi_{0.5}$.

- Congestion peaks (height of figure - number of congested edges and halted vehicles) are significantly lower using TWM.
- Congestion duration (width of figure - time with halted vehicles) is also significantly reduced using TWM.
- Mean network speed is also increased with TWM.

When we consider different TWM driver adherences, we notice that results get improved. Drivers will give positive feedback to the loop, and expectations are that adherence will grow. We can expect that the system will tend to increase adoption in time. This kind of system dynamics is left for future research.

B. INDIVIDUAL DRIVING EXPERIENCE USING 16-TWM

Global statistics hide the individual driver perception that is a key factor for adherence dynamics. To analyze driver's experience we use paired statistics, where we compare single o/d trip of the same vehicle under different scenarios and create travel-time histograms.

In Figure 6 we analyze individual travel time variation with adherence $\psi_{0.5}$ as percentage of affected vehicles over the whole vehicle population. Variations do not follow normal distributions, as confirmed from the results of standard paired tests (T-Test, Shapiro and others).

- 0-Value represents frequency of individuals that do not perceive any significant changes when using TWM.
- Negative values show the percentages of vehicles whose travel time has been penalized. When the TWM assigns a weighted map that differs from the original one, drivers are going to diverge in their decisions from the optimal ones considering just the free-flow empty network. Some of the individual travel-times TT_a^k are negatively affected mainly due to the increments in route lengths RL_a^k and lower speed. For the subjective experience we should also take into account the individual halted time STT_a^k that is reduced.
- Positive values from 0 show percentage of drivers whose travel time has been improved. The higher values, the bigger improvement, and also the main promoters for TWM adoption.

Relative impacts represent better the impact on driver's experience. The driver evaluates how much improved using TWM, when compared to the original non-TWM value.




FIGURE 7. Alcala de Henares, comparison of individual experiences for TWM/non TWM users (relative) with $\psi_{0.5}$.

Individual improvement is measured in travel-time, route-length, energy consumption and other parameters. We focus on travel-time which is the main indicator.

At the right side of Figure 6 we find that the subjective improvement is more relevant: a big number of drivers have significantly reduced their travel times respect to the original travel time expectations. They were the previously congested vehicles.

TWM benefits reach all the vehicles, not only for those that use TWM but also the other ones. This is the obvious consequence of routing some traffic out of the preferred paths: the whole network status gets highly improved.

Figure 6 also shows that some vehicles are suffering travel-time penalty as TWM weight adaptation forces evaluation of new optimal routes. Global TWM impact needs to consider the two factors shown in the graph: a) the relative impact for each driver and b) the number of drivers that are reducing travel-time.

1) TWM AND NON-TWM DRIVING EXPERIENCES

If we think in terms of awareness and reward (“What is my reward for using the multimap?”) we need to consider two different populations: those drivers that use TWM and non-using drivers.

Though TWM users achieve the expected benefits, non-TWM users benefit as well, and even more than the TWM users, generating a global improvement. Application of TWM on maps covering the original best-cost routes, derives a significant amount of the traffic out of them, thus triggering a congestion clearance on them: *the multimap route clearing effect*.

Figure 7 compares the variation/improvement for each population where we can see how both populations are being affected by TWM usage in a similar way.

2) MAXIMUM ADHERENCE SCENARIO

We have seen so far the $\psi_{0.5}$ scenario; we study now the scenario where all the vehicles are using TWM, ψ_1 . Figure 4 shows the global measures for different adherences, and Figure 8 shows the maximum relative improvements for the traffic network and the considered traffic demand. As expected, we find a right-side slope that reveals that most of the vehicles are having a better driver experience with a




FIGURE 8. Alcalá de Henares, TTC_{rel} at ψ_1 adherence.




FIGURE 9. Alcalá de Henares, cumulative probability distribution for $\psi_{0.1}$, $\psi_{0.2}$, $\psi_{0.5}$ and ψ_1 .

wide satisfactory perception. The ψ_1 histogram shows how real bottlenecks are eliminated, represented in the right peaks: previously halted vehicles are now routed.

3) CUMULATIVE PROBABILITY DISTRIBUTION OF DRIVING EXPERIENCE VARIATION

In the cumulative probability distribution for $\psi_{0.1}$, $\psi_{0.2}$, $\psi_{0.5}$ and ψ_1 (Figure 9) we observe how the improvement is achieved. We point out that:

- Starting with very low adherence such as $\psi_{0.1}$ (10%) the probability of being positively impacted is considerable. TWM generate benefits even with a small number of drivers.
- Probability of having improvements increases with the adherence almost linearly with it, and when we reach full adherence, the benefit is maximum.

IV. TWM APPLICATION ON URBAN ROAD INCIDENTS

TWM offers a wide number of use-cases for real application. One of them is to design ad-hoc traffic weighted multi-maps to minimize impacts of traffic incidents. These traffic incidents could be planned works (scheduled) or caused by a real-time event.

In case of incident to be managed by some TWM application, we will follow these steps:

- 1) Identify the physical coordinates of the incident.
- 2) Identify the edges and nodes affected by the incident, $[\epsilon_{i,j}]_x$
- 3) Create an ad-hoc multi-map $[\mu_{k,m}]_x$ (20) around the affected edges, within a distance radius of R_x . The multi-map will be valid for a certain time lapse that will

typically cover from the incident detection to some time after incident clearance.

$$\Pi_x : [\epsilon_{i,j}]_x, [\Omega_k], [\Gamma_{k,m}], R_x \rightarrow [\mu_{k,m}]_x \quad (20)$$

- 1) Distribute the TWM $[\mu_{k,m}]_x$ to the adequate fleets. Some fleets may not use it for some possible reasons, for instance, in case of using fixed routes (like buses).
- 2) In case of supervised routing, where we don't know in advance the time duration of the incident:
 - a) Monitoring traffic conditions during the traffic incident.
 - b) Restoration of original TWM conditions.

Generated $[\mu_{k,m}]_x$ maps for incidents are the result of merging edge weights of current $[\mu_{k,m}]$ that could be currently in use, or the standard map μ_0 if there is no previous TWM usage.

In the creation step of the new $[\mu_{k,m}]_x$ for the incident, TWM generator allows us to apply several routing policies with different functions Π_δ as we mentioned in the formulation chapter:

- Apply a *fixed weight penalty of value K* to all the edges surrounding the affected edge with N edges of distance.
- Apply a *random weight penalty amplified by value K* to all the edges surrounding the affected edge with N edges of distance. Random distributions allow that different paths will be selected by the vehicles.

Radius R_x is a distance metric that expresses the maximum number of edges belonging to the possible traffic paths that converge into the affected edge $[\epsilon_{i,j}]_x$. It is not measured in meters nor miles, but in number of edges. This distance calculus is more convenient in urban areas as once the vehicles have entered the edge they should complete the whole edge distance.

A. INCIDENT EXPERIMENT DESIGN

To analyze a realistic scenario, we use the Alcalá de Henares traffic network, with ad-hoc traffic demands. Impact of TWM usage in case of traffic incidents has a very different impact depending on the congestion stage of the whole network: highly congested traffic networks are not going to receive the same improvement as other non-congested scenarios.

Our traffic scenario consists on a heavy directional traffic flow that crosses the city (traffic area zones taz5 and taz50). The flow consists on around 2000 vehicles/hour distributed in the first hour. This flow generates some congestion points in the most used edges.

The traffic incident location is shown in Figures (10 and 11). It occurs in an edge belonging to the most selected routes, though it is not at the top congested edges to avoid forcing experimental results. The incident lasts from timestamps 2000 (incident) to 4800 (restore).

Figures 12 and 13 compare both global scenarios of free-flow with or without the incident, showing the evolution of total number of halted vehicles in the network and travel-times of the vehicles using it. The incident creates a

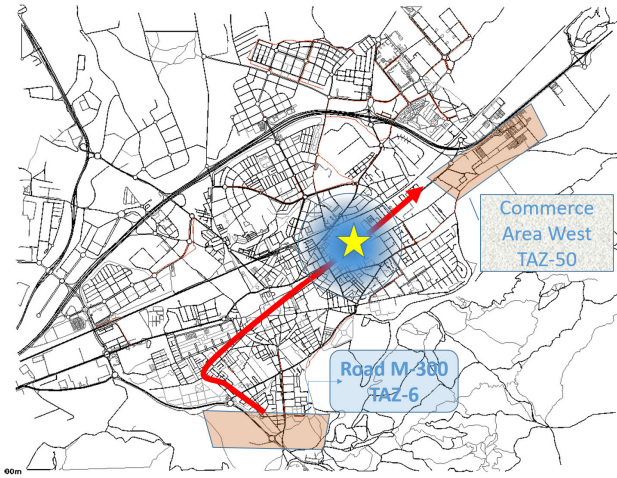


FIGURE 10. Alcalá with directional traffic and incident in the main path.

```
<?xml version="1.0" encoding="UTF-8"?>
<commands>
<!-- INCIDENTS SECTION -->
<!-- Incidents placed in the most occupied edges -->
<!-- Incident 1-->
<!-- Avenida Lope de Figueroa -->
<command time="2000" name="Incident" param="151292453#1" />
<command time="4800" name="Restore" param="151292453#1" />
<!-- COMMAND TO CLEAR CONGESTION IN THE INCIDENTS AREAS -->
<command time="2000" name="Maps" param="alcalahenares_TWM_timeALL_taz5-taz50X8_incident3x1-join_01.maps.xml" />
</commands>
```

FIGURE 11. TWM routing command for incident management.




FIGURE 12. Effect of incident on travel-times.




FIGURE 13. Impact of road incident on halted vehicles.

congestion situation as can be seen in the red right side of the histogram where many vehicles are increasing their travel-times. Also it can be observed that total number of halted vehicles raises until incident clearance.

```
<?xml version="1.0" encoding="UTF-8"?>
<maps>
<map tag="car" prob="1" file="alcalahenares.taz5-taz508.incident3x1.join_map_1.xml" />
<map tag="taxi" prob="1" file="alcalahenares.taz5-taz508.incident3x1.join_map_1.xml" />
<map tag="motorcycle" prob="1" file="alcalahenares.taz5-taz508.incident3x1.join_map_1.xml" />
<map tag="bus" prob="1" file="alcalahenares.reference.mapR.xml" />
</maps>
```

FIGURE 14. $\Pi_x : [\mu_{k,m}]_x$ multi-maps for incident management.

```
<?xml version="1.0" encoding="UTF-8"?>
<config>
<gmb>
<mode value="penalty"/>
<net_file value="xml_maps/alcalahenares.net.xml"/>
<output_prefix value="map.alcalahenares.taz5-taz508.incident3x1"/>
<output_dir value="alcalahenares.maps"/>
<!-- <weight_factor value="abs(1+numpy.random.uniform(0,5))"/> -->
<weight_factor value="5"/>
<weight_add value="20"/>
<num_maps value="1"/>
<begin value="0"/>
<end value="10000"/>
<join_map value="alcalahenares.maps/map.alcalahenares.reference.mapR.xml"/>
<join_option value="max"/>
<!-- Set incident point in the highest occupancy edges -->
<pen_edges value="151292453#1" />
<pen_edges_steps value="5"/>
</gmb>
</config>
```

FIGURE 15. Configuration file for the TWM map generator.

B. TWM DESIGN FOR THE INCIDENT

In the experiments, the framework distributes the corresponding multi-map $[\mu_{k,m}]_x$ with the assumption that the incident is detected in the same time instant that it has been produced, and that the TWM generation and distribution is immediate. This assumption is used for simplicity, as the results will be similar using different times.

The linear multi-map $[\mu_{k,m}]_x$ used in the experiment is a simple one, that will be used by three of the four fleets; the fourth fleet, buses, is going to use its regular fixed paths.

The linear function Π_{lin} described in (21) is used to create the new weights based on the standard ones based on max speed constraints, setting the new edge weight has a combination of a fixed penalty (parameter a) and a variable scaling factor (parameter b). Our objective is to amplify the edge weights around the incident so that they won't be selected for the new best-route calculation, thus discouraging drivers from using them.

$$\Pi_{lin} : [\epsilon_{i,j}]_x, [\Omega_k], [\Gamma_{k,m}], R_x \rightarrow [\mu_{k,m}]_x$$

$$\left| \beta_{i,j}^{k,m} = a + b * S_{i,j} \right. \begin{cases} a = 20 \\ b = 5 \end{cases}$$

$$\left| R_x = 5 \right.$$

$$\left| \Gamma_{k,m} \in [2000, 4800] \right.$$

Figure 15 shows TWM map generator configuration, where the parameter $pen_edges_steps=5$ indicates that we are using a distance radius of $R_x = 5$ as explained before. Traffic is dispersed around the incident avoiding edges with distance 5 to the incident and re-calculating the best-path to their destination.

The experiments that have been executed, consider different driver's adherences of $\psi_{0.1}$, $\psi_{0.2}$, $\psi_{0.5}$ and ψ_1 for the multi-map adoption.

```
<?xml version="1.0" encoding="UTF-8"?>
<meandata>
  <interval begin="0" end="10000" id="whatever">
    <edge id="-378122091" traveltime="74.70482361411086"/>
    <edge id="151292453#0" traveltime="32.478401727861765"/>
    <edge id="151292453#1" traveltime="23.41432685385169"/>
    <edge id="378122091" traveltime="74.76601871850251"/>
    <edge id="23907635#3" traveltime="20.050395968322533"/>
    <edge id="23907635#4" traveltime="21.198704103671705"/>
    <edge id="151292453#2" traveltime="22.14542836573074"/>
    <edge id="-28355546#0" traveltime="22.42260619150468"/>
    <edge id="23907635#2" traveltime="30.00179985601152"/>
    <edge id="28355546#0" traveltime="22.42260619150468"/>
    <edge id="23907635#0" traveltime="26.89704823614111"/>
    <edge id="408924700#4" traveltime="40.72714182865371"/>
    ...
  </interval>
</meandata>
```

FIGURE 16. New $[\mu_{k,m}]_x$ weights.




FIGURE 17. Travel-time variation with ad-hoc TWM on incident for $\psi_{0,5}$ and ψ_1 .

TABLE 8. Travel-time variation with ad-hoc TWM on incident for $\psi_{0,5}$ and ψ_1 .

Incident + 1 TWM, linear a=20, b=5		No TWM	50%	100%
Traffic	Demand	500	500	500
	Using TWM	0	241	500
	Routed	500	500	500
Travel time	Mean		-32,67%	-52,36%
	Median		-64,00%	-79,09%
Route Length	Mean		-0,10%	-1,04%
	Median		0%	0%

Both the linear function used and the selected parameter values are part of basic experiments, and no optimization algorithms have been applied. They will be subject of future research in order to obtain optimal results: optimization function, linear factors, distance radius, number of maps to be used and other parameters that offer a wide range of possibilities.

C. TWM APPLICATION RESULTS

As we can observe at histograms in Figure 17 and Table 8 for $\psi_{0,5}$ and ψ_1 adherences, the initial congestion is cleared




FIGURE 18. Global evolution of incident managed by TWM: Halted vehicles.




FIGURE 19. Global evolution of incident managed by TWM: Congested edges.

by the TWM, rerouting traffic out of the boundaries of the incident edge. Travel-time variation perceived by the drivers in this case raises up to 79% for a full ψ_1 adherence, but it is clear that this value depends on the incident instant and duration and the route lengths of all the vehicles. Right side of the histograms (green side) show the incident situation where vehicles are blocked by the incident; red left side shows how the vehicles using TWM find alternative paths and get rerouted, thus reducing their travel-times.

Figures 18, 19 and 20 show how global congestion due to the incident is impacted by TWM usage depending on the adherence to the system by drivers:

- Halted vehicles initially collapse the network for the selected paths when the incident appears (red line). Usage of TWM with maximum adherence is able to flatten the curve, reducing to a minimum the impact of the incident (black line). The big gap occurs while jumping from 50% to 100% adherence where the maximum efficiency is achieved.
- Number of edges congested also gets flattened with application of TWM, reducing the congestion peak.
- Mean speed in the network is raised globally while applying TWM.

Subjective individual variation is shown in Figure 21 for ψ_1 adherence where it is clear that vehicles that were initially




FIGURE 20. Global evolution of incident managed by TWM: Mean speed.




FIGURE 21. Individual travel-time relative variation.

blocked by the incident (right-side) have obtained a great reward for using TWM in terms of travel-time. Very few vehicles have been negatively impacted.

V. CONCLUSION AND FUTURE WORKS

Traffic weighted multimaps (TWM) is offering a new approach for both static and dynamic traffic management, as it considers enhancing both global network and individual traffic objectives. It considers the fact that traffic network usually provides multiple paths for the same O/D pair, but traffic agents recommendations usually propose the same routes as they use network and traffic load data, not taking into account the different traffic groups objectives and capabilities.

We have shown with our experiments in a real city traffic network under real traffic conditions, how TWM application can lead to improvements of global travel time indicators between 20% and 30%, depending on scenario conditions, enhancing greatly congestion situations. The penalty paid is using slightly bigger routes. TWM behaves correctly in low and high traffic density scenarios:

- In low-density traffic scenarios, individual improvement has no valuable impact as agents are close to their ideal performance (travel time), but group and global Smart-City indicators are greatly improved.
- In high-density traffic scenarios (close to congested networks), multimap algorithms offer their best performance, as they are able to enhance individual objectives improving also group and global indicators.

- Real-Time response to changes in network such as incidents, is fast and effective, by means of releasing new multimaps sets with link costs adapted to the new situation.

The benefits of TWM include the following:

- The possibility of automating early and real-time decision making for drivers and authorities.
- Generation of an integral policy for the application of management and control policies.
- It can be offered as a service (SaaS model), as it uses a non intrusive architecture.
- It is conceived as a evolutionary planning model, based in on traffic feed back and learning cycles.
- Compatible with existing traffic management frameworks and traffic agents.
- Drivers' agents autonomy is preserved as the multimap model takes into account individual freedom of route choice.
- It allows for the articulation of contingency plans and the integration of traffic prognosis models.

TWM stands out from an innovative perspective in the following:

- Offers an integrated planning and re-planning model, extensible and open.
- Enables traffic categorization for application to very different groups and situations: electric vehicle, pay-to-drive and car-sharing fleets, commercial distribution, disabled people, pollutants, dangerous transport, routing due to weather, timetables, etc.
- It is replenished and self-learning.
- Route calculation can use standard optimization algorithms and techniques.
- Uses existing data (Smart-Cities, OpenData) and adds value.
- TWM can be implemented easily in current traffic control systems, creating a new routing module that uses differentiated maps as defined by TWM. It does not require the installation of additional infrastructure.
- TWM does not require V2V communications nor deployment of sensors, panels or communication infrastructures.
- From the user perspective, it is compatible with existing traffic agents, as we will replace the maps they use.
- TWM usage does not require all vehicles to adopt it. May be used in a biased manner (only for certain categories or policies).

There are many open future research works that mainly deal with dynamic traffic assignment with TWM, creating evolutionary algorithms and optimization functions for finding local area minimum for routing maps that can cover eventual time-dependent situations, and also releasing new reference networks, such as radial topologies, roundabouts, etc.

Also modeling user-perspective for influencing the adherence factor that is shown as a key condition for TWM impact is a topic of future research. Generation of hyperpaths based

on TWM is a promising research direction, and adding new simulation engines such as mesoscopic ones.

REFERENCES

- [1] *Google Route Planner*. Accessed: Jun. 2019. [Online]. Available: <https://www.drivingdirectionsandmaps.com/route-planner/>
- [2] *Mapbox Navigation*. [Online]. Available: <https://www.mapbox.com/navigation/>
- [3] *Movilidad y Tráfico—Movilidad y Tráfico—Ayto. de Alcalá de Henares*. [Online]. Available: <http://www.traficoalcala.es/>
- [4] (Nov. 2016). *TomTom Routing API*. [Online]. Available: <https://developer.tomtom.com/routing-api>
- [5] (Nov. 2018). *TomTom Inicio*. [Online]. Available: <https://www.tomtom.com/>
- [6] (2019). *Routing Server—Wazeopedia*. [Online]. Available: https://wazeopedia.waze.com/wiki/Global/Routing_server
- [7] A. L. C. Bazzan and F. Klügl, "A review on agent-based technology for traffic and transportation," *Knowl. Eng. Rev.*, vol. 29, no. 3, pp. 375–403, 2013.
- [8] A. L. C. Bazzan and F. Klügl, "Introduction to intelligent systems in traffic and transportation," in *Introduction to Intelligent Systems in Traffic and Transportation: Synthesis Lectures on Artificial Intelligence and Machine Learning*, vol. 7, no. 3. Williston, ND, USA: Morgan & Claypool, Dec. 2013, pp. 1–137.
- [9] M. Behrisch, L. Bieker, J. Erdmann, and D. Krajzewicz, "SUMO—Simulation of Urban MObility: An overview," in *Proc. 3rd Int. Conf. Adv. Syst. Simulation (SIMUL)*, A. Omerovic, D. A. Simoni, and G. Bobashev, Eds. Barcelona, Spain: ThinkMind, Oct. 2011, pp. 63–68.
- [10] R. A. C. Bianchi and A. L. C. Bazzan, "Combining independent and joint learning: A negotiation based approach," in *Proc. Int. Conf. Auto. Agents Multiagent Syst. (AAMAS)*, Valencia, Spain, Jun. 2012, pp. 1395–1396.
- [11] Y. Chen, M. G. H. Bell, and K. Bogenberger, "Reliable pretrip multipath planning and dynamic adaptation for a centralized road navigation system," *IEEE Trans. Intell. Transp. Syst.*, vol. 8, no. 1, pp. 14–20, Mar. 2007.
- [12] R. Claes and T. Holvoet, "Traffic coordination using aggregation-based traffic predictions," *IEEE Intell. Syst.*, vol. 29, no. 4, pp. 96–100, Jul./Aug. 2014.
- [13] R. Claes, T. Holvoet, and D. Weyns, "A decentralized approach for anticipatory vehicle routing using delegate multiagent systems," *IEEE Trans. Intell. Transp. Syst.*, vol. 12, no. 2, pp. 364–373, Feb. 2011.
- [14] L. Cruz-Piris, I. Marsa-Maestre, and M. A. Lopez-Carmona, "A variable-length chromosome genetic algorithm to solve a road traffic coordination multipath problem," *IEEE Access*, vol. 7, pp. 111968–111981, 2019.
- [15] L. Cruz-Piris, M. A. Lopez-Carmona, and I. Marsa-Maestre, "Automated optimization of intersections using a genetic algorithm," *IEEE Access*, vol. 7, pp. 15452–15468, 2019.
- [16] E. de la Hoz, I. Marsa-Maestre, and M. A. Lopez-Carmona, "Simulation of coordinated anticipatory vehicle routing strategies on MATSim," in *Proc. 14th Int. Conf. Agent Based Simulation Sustain. Soc. Multi-Agent Smart Comput. (PRIMA)*. Berlin, Germany: Springer-Verlag, 2012, pp. 90–108.
- [17] Y. Djenouri and A. Zimek, "Outlier detection in urban traffic data," in *Proc. 8th Int. Conf. Web Intell., Mining Semantics*, 2018, pp. 1–12.
- [18] B. Fortz, J. Rexford, and M. Thorup, "Traffic engineering with traditional IP routing protocols," *IEEE Commun. Mag.*, vol. 40, no. 10, pp. 118–124, Oct. 2002.
- [19] *The Multi-Agent Transport Simulation MATSim*. London, U.K.: Ubiquity Press Limited.
- [20] A. Gkoulalas-Divanis and C. Bettini, *Handbook of Mobile Data Privacy*. New York, NY, USA: Springer, 2018.
- [21] M. Gohar, S. H. Ahmed, M. Khan, N. Guizani, A. Ahmad, and A. U. Rahman, "A big data analytics architecture for the Internet of small things," *IEEE Commun. Mag.*, vol. 56, no. 2, pp. 128–133, Feb. 2018.
- [22] A. Guleria, M. R. Abbasi, and M. S. Devi, "Traffic engineering in software defined networks: A survey," *J. Telecommun. Inf. Technol.*, vol. 4, pp. 3–14, Dec. 2016.
- [23] M. G. H. Bell, "Hyperstar: A multi-path Astar algorithm for risk averse vehicle navigation," *Transp. Res. B, Methodol.*, vol. 43, no. 1, pp. 97–107, Jan. 2009.
- [24] Z. Hong and D. Fukuda, "Effects of traffic sensor location on traffic state estimation," *Procedia—Social Behav. Sci.*, vol. 54, pp. 1186–1196, Oct. 2012.
- [25] W. Hu and P. J. Jin, "Dynamic origin-destination estimation based on time delay correlation analysis on location-based social network (LBSN) data," in *Proc. Annu. Meetings Transp. Res. Board*, National Academies, Washington, DC, USA, 2018.
- [26] W. Hu, Z. Yao, S. Yang, S. Chen, and P. J. Jin, "Discovering urban travel demands through dynamic zone correlation in location-based social networks," in *Proc. Joint Eur. Conf. Mach. Learn. Knowl. Discovery Databases*, 2018, pp. 88–104.
- [27] H. Ibrahim and B. H. Far, "Data-oriented intelligent transportation systems," in *Proc. IEEE 15th Int. Conf. Inf. Reuse Integr. (IEEE IRI)*, Aug. 2014, pp. 322–329.
- [28] J. F. Kurose and K. W. Ross, *Computer Networking: A Top-Down Approach*, 6th ed. London, U.K.: Pearson, 2012.
- [29] L. B. Reinhardt and D. Pisinger, "Multi-objective and multi-constrained non-additive shortest path problems," *Comput. Oper. Res.*, vol. 38, no. 3, p. 605, 2011.
- [30] Z. Liang and Y. Wakahara, "A route guidance system with personalized rerouting for reducing traveling time of vehicles in urban areas," in *Proc. 17th Int. IEEE Conf. Intell. Transp. Syst. (ITSC)*, Oct. 2014, pp. 1541–1548.
- [31] S. Lin, B. D. Schutter, Z. Zhou, and Y. Xi, "Multi-agent model-based predictive control for large-scale urban traffic networks using a serial scheme," *IET Control Theory Appl.*, vol. 9, no. 3, pp. 475–484, Feb. 2015.
- [32] R. Luo, R. Bourdais, T. J. J. van den Boom, and B. De Schutter, "Multi-agent model predictive control based on resource allocation coordination for a class of hybrid systems with limited information sharing," *Eng. Appl. Artif. Intell.*, vol. 58, pp. 123–133, Feb. 2017.
- [33] J. Ma and D. Fukuda, "A hyperpath-based network generalized extreme-value model for route choice under uncertainties," *Transp. Res. C, Emerg. Technol.*, vol. 59, pp. 19–31, Apr. 2017.
- [34] J. Ma, D. Fukuda, and J.-D. Schmöcker, "Faster hyperpath generating algorithms for vehicle navigation," *Transportmetrica*, vol. 9, no. 13, pp. 925–948, 2012.
- [35] M.-R. N. Rad, L. Padgham, P. Perez, K. Nagel, and A. Bazzan, Eds., *Agent Based Modelling of Urban Systems—First International Workshop, ABMUS 2016, Held in Conjunction With AAMAS, Singapore, Singapore, May 10, 2016, Revised, Selected, and Invited Papers* (Lecture Notes in Computer Science), vol. 10051. New York, NY, USA: Springer, 2017.
- [36] J. d. D. Ortúzar and L. G. Willumsen, *Modelling Transport*, 3rd ed. Hoboken, NJ, USA: Wiley, 2001.
- [37] J. Pan, I. S. Popa, K. Zeitouni, and C. Borcea, "Proactive vehicular traffic rerouting for lower travel time," *IEEE Trans. Veh. Technol.*, vol. 62, no. 8, pp. 3551–3568, Oct. 2013.
- [38] A. P. Garcia and M. A. Lopez-Carmona, "Multimap routing for road traffic management," in *Advances in Practical Applications of Survivable Agents and Multi-Agent Systems: The PAAMS Collection* (Lecture Notes in Computer Science), 17th ed. Ávila, Spain: Springer, Jun. 2019.
- [39] J. Pei, P. Hong, K. Xue, and D. Li, "Resource aware routing for service function chains in SDN and NFV-enabled network," *IEEE Trans. Services Comput.*, to be published.
- [40] E. Pérez-Wohlfeil, F. Chicano, and E. Alba, "An intelligent data analysis of the structure of np problems for efficient solution: The vehicle routing case," in *Proc. 4th Euro-China Conf. Intell. Data Anal. Appl.*, 2018, pp. 368–378.
- [41] L. R. Nielsen, K. A. Andersen, and D. Pretolani, "Finding the K shortest hyperpaths," *Comput. Oper. Res.*, vol. 32, no. 6, pp. 1477–1497, 2005.
- [42] M. Rezaei, H. Noori, D. Rahbari, and M. Nickray, "ReFOCUS: A hybrid fog-cloud based intelligent traffic re-routing system," in *Proc. IEEE 4th Int. Conf. Knowl.-Based Eng. Innov. (KBEI)*, Dec. 2017, pp. 992–998.
- [43] H. Sagara and J. Tanimoto, "A study on social diffusive impacts of a novel car-navigation-system sharing individual information in Urban traffic systems," in *Proc. IEEE Congr. Evol. Comput.*, Sep. 2007, pp. 836–842.
- [44] A. Sarker, H. Shen, and J. A. Stankovic, "MORP: Data-driven multi-objective route planning and optimization for electric vehicles," *Proc. ACM Interact., Mobile, Wearable Ubiquitous Technol.*, vol. 1, no. 4, pp. 1–35, 2018.
- [45] E. Thonhofer, T. Palau, A. Kuhn, S. Jakubek, and M. Kozek, "Macroscopic traffic model for large scale urban traffic network design," *Simul. Model. Pract. Theory*, vol. 80, pp. 32–49, Jan. 2018.
- [46] L. Z. Varga, "On intention-propagation-based prediction in autonomously self-adapting navigation," in *Proc. IEEE 8th Int. Conf. Self-Adapt. Self-Organizing Syst. Workshops (SASOW)*, vol. 16, Sep. 2015, pp. 38–43.
- [47] D. Wagner and T. Willhalm, "Speed-up techniques for shortest-path computations," in *Proc. Annu. Symp. Theor. Aspects Comput. Sci.*, 2007, pp. 23–36.

- [48] M. M. de Weerd, S. Stein, E. Gerding, V. Robu, and N. R. Jennings, "Intention-aware routing of electric vehicles," *IEEE Trans. Intell. Transp. Syst.*, vol. 17, no. 5, pp. 1472–1482, May 2016.
- [49] N. Nie and X. Wu, "Shortest path problem considering on-time arrival probability," *Transp. Res. B, Methodol.*, vol. 43, no. 6, pp. 597–613, 2009.
- [50] Z. Cong, B. De Schutter, M. Burger, and R. Babuška, "Monitoring of traffic networks using mobile sensors," in *Proc. 17th Int. IEEE Conf. Intell. Transp. Syst. (ITSC)*, Qingdao, China, Oct. 2014, pp. 792–797.
- [51] Y. Zheng, L. Capra, O. Wolfson, and H. Yang, "Urban computing," *ACM Trans. Intell. Syst. Technol.*, vol. 5, no. 3, 2014, Art. no. 38.



ALVARO PARICIO received the double M.S. degree in computer science and communications from the Universidad Politécnica de Madrid, Madrid, Spain, in 1992. He is currently pursuing the Ph.D. degree in information and communications technologies with the Universidad de Alcalá (UAH), Madrid. He is also an Assistant Professor of Computer Science with UAH and Digital Transformation with Escuela de Organización Industrial, depending of the Spanish Ministry

of Industry. His main research interests include optimization algorithms, traffic routing optimization, the IoT architectures, and massive data analytics. He has developed a wide professional career in private held companies. He joined Telefonica Research and Development, in 1994, as an AI Expert. In 1999, he Co-founded the company IAPsolutions (Spain and USA), as the CTO, a technology startup for AI agents, the IoT, and edge-computing. In 2014, he joined SecuritasDirect, a global leader for home-security, as the Development Director for the EMEA and LATAM. Since 2017, he leads Digital Transformation Offices in Telecom Group MasMovil (the fastest growing telecom operator in Europe, since 2017).



MIGUEL A. LOPEZ-CARMONA received the B.S. degree in electronics engineering from the University of Alcalá, in 1994, the M.S. degree in telecommunication engineering from the Polytechnic University of Madrid, in 1999, and the Ph.D. degree in telecommunication engineering from the University of Alcala, in 2006. From 1995 to 2000, he held positions in Logytel and Alcatel, as a Project Manager and a Research Scientist, in the areas of railways and defense.

From 2010 to 2017, he was the Vice-Dean of the Polytechnic School, University of Alcalá, where he has been an Associate Professor with the Department of Computer Engineering, since 2000. He has also been a Visiting Researcher at the Center for Collective Intelligence, Massachusetts Institute of Technology (MIT), where he did research in complex automated negotiations and optimization of complex networks. His research interests include intelligent transport systems, automated negotiation, multiagent systems, and optimization of complex networks.

...

4

Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment

En este capítulo se muestra el artículo publicado “Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment”. Tras una breve resumen de este, se muestran los datos sobre la publicación y su relevancia. Por último, se ha incluido una copia de la versión publicada del artículo.

4.1. Introducción

Tradicionalmente se han usado los mecanismos de asignación estática de tráfico para la planificación, dimensionado y control de las redes urbanas de tráfico. El problema principal de la asignación de tráfico (TAP, *traffic assignment problem*) consiste en la generación y distribución de las rutas de menor coste a los vehículos en función no sólo de las características de la propia red sino del estado del tráfico en cada momento [100]. Cada decisión tomada por un vehículo, altera las condiciones de ocupación de la red, y por tanto el equilibrio óptimo.

La resolución del TAP es un problema no lineal complejo, no diferenciable y convexo [113]. La asignación de tráfico estática se fundamenta en los dos principios básicos de Wardrop [132]: a) el equilibrio de los usuarios (UE), por el que los usuarios hacen su selección de ruta basándose en la obtención de rutas de mínimo coste, básicamente un criterio microscópico; y b) el sistema óptimo (SO), según el cual, bajo condiciones de equilibrio social, el tráfico

se organiza de tal forma que el tiempo medio de viaje queda minimizado, un criterio macroscópico. Existen diversos criterios adicionales a estos dos, orientados a la asignación dinámica de tráfico, a la asignación estocástica, etc.

La complejidad del cálculo del TAP hace que se empleen mecanismos alternativos basados en heurísticos que aporten aproximaciones a su resolución. Y en este sentido, vista la viabilidad de TWM para generar distribuciones alternativas de tráfico, el artículo aborda la problemática de cómo encontrar las distribuciones de mapas y sus pesos de manera que lleven a una asignación estática del tráfico muy próxima al óptimo del sistema.

En ese sentido, el artículo aborda las diferentes perspectivas de la asignación estática, seleccionando varios métodos de cálculo aproximado con los que comparar posteriormente los resultados que nos suministren los mapas TWM óptimos [94]: el método Todo-O-Nada (AON, *All-Or-Nothing*), el método de medias sucesivas (MSA, *Successive Averages Method*), el método acumulativo (CAM, *Cummulative Assignment Method*), y el método de aproximación por programación lineal definido por Wei et al. [133] (LP, *Linear Programming Method*) fruto de la recomendación dada por los revisores.

El artículo analiza diversas estrategias de cálculo de mapas de pesos TWM que ofrezcan una asignación óptima de rutas a los conductores de una red de tráfico, conocidos la propia red y la demanda prevista de tráfico (flujos históricos). El criterio fundamental de optimización en este caso es la minimización del tiempo total de viaje de los vehículos (SO). La optimización se realiza mediante algoritmos genéticos, inicialmente considerando la red completa y posteriormente aplicando restricciones sobre la misma en base a las k -rutas de coste mínimo (KSP, *k-shortest paths*), y sus áreas circundantes.

Los experimentos de simulación se realizan sobre una red sintética tipo GRID y sobre una red urbana real (Madrid-Retiro) (ver apéndice), para diferentes niveles de adherencia de los conductores a TWM y para diferentes parametrizaciones de KSP y áreas de influencia.

Los resultados obtenidos muestran que los mapas TWM óptimos generan soluciones muy próximas a las soluciones de SO propuestas por los algoritmos aproximados. La gran aportación en este caso, es que TWM ofrece una solución viable a implementable en los sistema de enrutamiento actuales, con un coste

computacional razonable, y sin necesidad de tener una evaluación continua del estado de la red.

4.2. Relevancia de la publicación

Título	Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment		
Autores	Paricio, A. y Lopez-Carmona M.A.		
Estado	Publicado	Fecha	10/feb/2021
		publicación:	
DOI	https://doi.org/10.1109/ACCESS.2021.3058508		
	Nombre	IEEE Access	
Revista	Editorial	IEEE - Institute of Electrical Electronics Engineers Inc.	
	País	EE.UU.	
Relevancia	Revista (*)	Índice de Impacto:	3,367 (2020) : 4,076 (5 años)
		JCR (2020):	Q2 (94/273)
	Artículo	Lecturas:	92
		Citas:	0

(*)IEEE Access tiene un factor de impacto de 3,367 en 2020 y de 4.076 a 5 años, un Eigenfactor de 0.15396, y una puntuación de influencia de artículos de 0.592 (Índice JCR-2020). Fuente:

IEEE Access <https://ieeaccess.ieee.org/about-ieee-access/frequently-asked-questions/>.

Calificación FECYT para IEEE Access disponible en <https://apps.webofknowledge.com/>.

4.3. Artículo

Received January 6, 2021, accepted February 1, 2021, date of publication February 10, 2021, date of current version February 24, 2021.

Digital Object Identifier 10.1109/ACCESS.2021.3058508

Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment

ALVARO PARICIO^{ID} AND MIGUEL A. LOPEZ-CARMONA^{ID}

Departamento de Automática, Escuela Politécnica Superior, Universidad de Alcalá. Campus Universitario, 28807 Alcalá de Henares, Spain

Corresponding author: Alvaro Paricio (alvaro.paricio@uah.es)

ABSTRACT Traffic Assignment Problem (TAP) is a critical issue for transportation and mobility models that deals mainly with the calculus and delivery of best-cost routes for the trips in a traffic network. It is a computationally complex problem focused on finding user equilibrium (UE) and system optimum (SO). The Traffic Weighted Multi-Maps (TWM) technique offers a new perspective for TAP calculus, based on routing decisions using different traffic network views. These TWM are complementary cost maps that combine physical traffic networks, traffic occupation data, and routing policies. This paper shows how evolutionary algorithms can find optimal cost maps that solve TAP from the SO perspective, minimizing total travel time and providing the best-cost routes to vehicles. Several strategies are compared: a baseline algorithm that optimizes the whole network and two algorithms based on extended k-shortest path mappings. Algorithms are analyzed following a simulation-optimization methodology over synthetic and real traffic networks. Obtained results show that TWM algorithms generate solutions close to the static UE traffic assignment methods at a reasonable computational cost. A crucial aspect of TWM is its good performance in terms of optimal routing at the system level, avoiding the need for continuous route calculus based on traffic status data streaming.

INDEX TERMS Traffic assignment, traffic control, traffic simulation, vehicle routing, multi-map routing, traffic weighted multi-maps.

I. INTRODUCTION

Traffic Assignment is a key concern of urban mobility systems, where transportation demand formed by origin/destination vehicle trips, needs to be allocated to the traffic network. Assignment follows some principles related to the observed behavior of the driver, in the so-called the Traffic Assignment Problem (TAP) [39] that is a complex non-linear, non-differentiable and convex problem [33]. Even small traffic networks and reduced demands lead to a very high number of route alternatives and link occupation scenarios. Individual routing decisions also modify traffic conditions in the links and their cost, affecting the rest of the vehicles' routing decisions.

TAP has been addressed by many approaches and models [14], [33], [44]. All of them rely mainly on the static traffic assignment models (TA) based on the Wardrop's principles [48]. They state that individuals usually select their trip route in terms of best-cost criteria, and do adaptive choices depending on network status and occupation, until equilibrium con-

ditions are met. Basic principles are user equilibrium (UE) (users make route choices leading to their individual minimum cost) and system optimum (SO) (under social equilibrium, traffic conditions should arrange in congested networks in such a way that the average travel time is minimized). Other principles and models are proposed over UE and SO such as stochastic traffic assignment (STA) [39] adding traveler's perception of travel time cost and uncertainty of travel times. Dynamic traffic assignment approaches (DTA) [12], [44] focus on departure times to complement with new principles such as dynamic user equilibrium (DUE) [20], stochastic DUE (SDUE) [41], dynamic system optimum (DSO) [27] and also the addition of the bounded-rational user equilibrium principle (BRUE) [25]. More recently, other approaches have been proposed, such as prospect-based traffic assignment that considers user's perceived utility criteria [21], [50], and also traffic assignment based on risk-averse driver behaviors modeled by fuzzy rules [28].

All these principles lead to models with diverse complexity that provide theoretical and simulation-based results, but they present important issues for being applied to real deployable solutions for TAP: a) they require very high

The associate editor coordinating the review of this manuscript and approving it for publication was Nabil Benamar^{ID}.




FIGURE 1. TWM creation and distribution.

computing resources [23]; b) scaling and tractability depend on the network size and traffic volume [33]; c) efficient management of congestion situations; d) reaction to road incidents; and e) management of routing adherence when either some drivers are not part of the system or they don't follow routing recommendations [30]. Meta-heuristic approaches for TAP provide approximate problem solutions at reasonable computing costs in contrast to the analytical ones, mainly considering TAP as a multi-objective optimization problem [8], [10], [26], [34].

Traffic Weighted Multi-Maps (TWM) is a routing technique that may be used as a meta-heuristic approach for TAP considering the system optimum. It was introduced in [31], [32] demonstrating how the usage and distribution of complementary views (maps) of the traffic network can reduce global travel times, individual mean travel time and congestion. TWM is based on the fact that traffic network maps are composed of a physical topology representation and a layer of logical rules (policies and constraints) that describe how to use the network. TWM maps deliver differentiated network views to the vehicles, altering the logical perspective by providing new link weight sets. They are distributed to the traffic groups to create scattered vehicle routing that is one of the key points for congestion mitigation. TWM offers a strategic and tactical perspective on the individual routing of each vehicle, as opposed to the signaling-based solutions more oriented to the operation of the network itself. TWM is a feasible approach for both existing centralized and distributed routing approaches because map usage is a core requirement.

Previous works have focused on the TWM practical usage, showing promising results under microscopic simulation environments (SUMO [7]). Considered scenarios were: congestion mitigation, per fleet differential routing, and real-time incident management. However, a question that still remains unsolved is how to find the best traffic weighted multi-maps configuration for a given traffic demand. This paper focuses on using TWM as a meta-heuristic approach for TAP solution, finding the best-cost TWM configuration. It describes and compares strategies and algorithms using demand's total travel-time as the optimization goal for System Optimum achievement.

Figure 1 describes how the optimized TWM maps are used. Considering a predefined demand for a given traffic scenario in a traffic network, the TWM optimization engine generates a map distribution that heuristically solves the TAP. Generated maps are then suitable to be distributed as network views for existing routing tools, traffic management centers

and map distribution services. TWM direct download from the vehicles is also feasible. As well, generated TWM can be directly imported in simulation tools, such as SUMO by means of ad-hoc plugins.

The TWM optimization engine creates optimal link-weight sets to build the TWM maps using evolutionary algorithms (GA), applying the concept of flow-paths (FP) for demand routing. FP are calculated as the set of k-shortest paths (KSP) that would be used by the demand under the "all-or-nothing" routing algorithm (AON) [29].

The following strategies are analyzed:

a) Basic TWM optimization (B-TWM), a reference configuration that optimizes the weights of the entire network to individual trips.

b) Flow-Paths TWM optimization (FP-TWM), considering link weights optimization of just the routing paths that are part of the FP.

c) Extended Flow-Paths TWM optimization (EFP-TWM), considering that flow-paths may be used to define traffic routing areas rather than linear paths.

Using the TWM mechanism, drivers take their routing decisions based on biased network views (TWM), so from the user-optimum perspective, a driver using a different map may obtain a better route. This would be the case when the driver ignores TWM and uses the original physical network map (TWM adherence < 100%). We must notice that system-optimum TAP strategies often cause route unfairness to some drivers on behalf of the global objective [4], [35], [37].

In order to see how far are the static SO-based TWM results from the theoretical UE, they are compared to basic static traffic assignment strategies such as the cumulative traffic assignment method (CAM), the successive averages method (MSA), and the more recent SOCP/LP methods referred by Wei [14], [29], [49] which also cover Frank-Wolfe algorithm [19].

TWM results are also compared to the simple random TWM maps strategy (R-TWM), in which random weights are used to create entropy for routing diversity.

Simulation experiments are conducted in a grid 8×8 reference traffic network (GRID64) and a real traffic scenario in an urban network heavily congested. The synthetic network enables a clear analysis of algorithm results, whilst the urban network experiments provide empirical results validation. Experiments show how traffic assignment is achieved, revealing the optimal route distribution selected by the vehicles. Total travel time, mean travel time, and algorithm performance are then analyzed.

The main contributions of this paper include:

- 1) A formulation model for TWM optimization oriented to TAP solving. TWM can be seen as a function that provides ad-hoc network cost maps adapted to the status, demand structure and routing policies. Generated traffic weighted multi-maps may be used by any kind of routing agents in any other routing systems.
- 2) A set of evolutionary optimization algorithms for TWM which can produce map distributions at low

computing cost. Traffic assignment metrics provided by these TWM maps are very close to those calculated by UE theoretical estimators. The concept of extended k-short-path using flow-path is introduced, as a way to define routing areas.

- 3) Simulation studies on both synthetic and real urban traffic network with traffic demands where the algorithms are applied, depicting how TWM optimization can be used for congestion mitigation.

The paper is organized as follows: II contains a review of state-of-art and related works. III describes the TWM and flow-path model, and the optimization strategies are discussed in IV. V describes the experimental use cases and results, and finally, VI points out conclusions and future research lines.

II. PREVIOUS WORKS

Meta-heuristic approaches have been used to obtain approximate solutions for TAP, as an alternative to the complex analytical approaches and the uncertainty inherent to traffic dynamics. Some of these approaches try to find optimal routing distributions using evolutionary algorithms (GA) and are applied to static route planning and dynamic traffic routing. Optimal calculation usually requires heavy iterative routing calculation that depends on the network size and complexity and trip demands. Network total travel-time and individual's mean travel-time are the optimization problem goals.

Evolutionary algorithms have already been used in [5] focusing on how to create optimal route distributions based on traffic flows. Routes based on the free-flow k-shortest paths (KSP) are calculated, and an evolutionary algorithm is used to find the optimal route assignment to the vehicles. However, complexity of the proposed GA depends on the number of vehicles (demand) and assumes that vehicles are always going to follow the KSP delivered by the algorithm. This approach can be hardly scaled for increasing demands, requires a central routing service for traffic assignment, and also assumes that all the vehicles are required to use the assigned routes.

“All-or-nothing” (AON) routing strategy is considered a basic reference to compare with user-equilibrium scenarios [14], [29], [33]. It assumes that all the vehicles select their best-cost route considering only the network and not the occupation, density or traffic status, thus leading to congestion. The use of k-shortest paths under AON assumption is not enough for vehicles or flow routing as there is usually a high correlation between the different path alternatives which only differ in few links. This fact leads to the concept of disjoint k-shortest paths [17], [40] which recently has been extended to the concept of k-shortest paths with limited overlap (k-SPwLO) [13]. This concept is more suitable for static flow route planning with complementary traffic network maps as TWM. The proposed algorithm OnePass evolves the well-known Yen's algorithm for KSP [51].

Evolutionary algorithms have been also applied to dynamic traffic routing by [43], generating dynamic controls for signaling systems and traffic panels. This solution is intended for urban environments using a vehicle-to-infrastructure (V2I) protocol and a central management station. It requires a massive deployment of hot-spot devices and also full connectivity of the vehicles. Communications effort is very high and also computing resources. GA is designed in a per-vehicle basis so complexity is linear with the demand payload.

Other traffic signaling optimization systems based on evolutionary algorithms have also been described by [38], [47]. Bi-level optimization criteria are introduced for TAP solving: first minimizing average travel-time and then finding network equilibrium. They require a central management station with high computing capabilities, where scalability is a main concern for real deployments.

Besides intelligent signaling systems, TAP optimization has also been addressed through induction of incentives and penalties to the drivers using tolls. [42] focuses in the toll-booth problem: creating an optimal toll distribution for TAP. Evolutionary algorithms are also used to find heuristic solutions, but practical deployment is a big concern, requiring complete adoption by the vehicles.

Recently, Ant-Colony Optimization algorithms (ACO) have been used for distributed dynamic traffic optimization as in [10], [11]. These approaches rely on the hypothesis of fully connected vehicles that interact continuously between them or with their environment. Essentially, each vehicle leaves time-dependent pheromones related to the links it traverses: pheromone accumulation gives a measure of link usage. These pheromones are read by other vehicles to take their routing decisions when they reach the affected links, recalculating their routes, avoiding highly used paths and dispersing traffic. Distributed capabilities to store pheromones need to be complemented with a centralized station that manages traffic. This is a distributed heuristic approach where optimality is not fully addressed.

Fuzzy logic approaches are also used for optimal route choice as described in [8], [26], [45] where link costs are biased by the inherent traffic imprecision and user preference functions. Bias is implemented by fuzzy numbers usage. TAP relies on the design of route assignment rules based on the approximate travel-time of every driver and the ranked set of route fitness. This approach requires that drivers have (fuzzy) knowledge of the status of the network to make their decisions and thus define their approximate preferences. UE is achieved by means of fuzzy decisions and optimality is not achieved.

Pan *et al.* [30] propose a method to provide proactive dynamic traffic routing based on traffic density measures and predicted congestion. The study relies on the existence of a central routing service that receives all the collected traffic status data from the network. It proposes multiple shortest paths strategies where paths are ranked, assuming certain entropy level as path popularity. This approach relies on the ability of the drivers to receive and react to new routing

plans. Link occupation is measured using explicit metrics considering vehicles sizes and traffic spacing [30]

Algorithm results are usually compared to the theoretical TAP estimation methods focused on UE, mainly the cumulative traffic assignment method (CAM) and the successive averages method (MSA) [14], [29]. Recently, Wei *et al.* [49] have proposed alternative ways to efficiently compute total travel time applying second-order cone and linear programming techniques to solve the UE convex optimization problem described by Beckmann *et al.* [6].

Our work relates to these previous studies in the flow-oriented and GA approaches used to solve the optimization process for SO, though it presents important differences: a) it decouples optimal map generation and distribution from the route calculation problem, enabling feasible implementations over existing systems and methods; b) flow-paths are defined as an abstraction of the KSP based routing enabling optimization strategies; c) there is not a central routing-server assumption that computes and distributes routes: they can be managed in a centralized or distributed way; d) proposed GA algorithms are simpler as they do not use a per-vehicle optimization but a per flow-path basis: only traffic demand matrices are required instead of knowing individual trips in advance.

III. TRAFFIC WEIGHTED MAPS AND FLOW-PATH MODEL

There are many factors to consider when computing the best route in a loaded traffic network, where drivers choose their routes attending to objective and subjective factors which can be modeled as a route cost factor. The k -shortest paths of an O/D pair is formed by the set of its k minimum cost routes [18], where the cost function generally depend on: a) network topology; b) traffic policies (for instance, speed limits); c) network usage and status (congestion, density, blocking); d) the multi-objectives considered; and e) driver's subjective perception.

A. TRAFFIC ASSIGNMENT

The urban traffic network Θ can be described as a graph of nodes η_m connected by edges, each one formed by the links $\epsilon_{i,j}$ (each with one or more lanes) that connect nodes η_i and η_j with a weight $\beta_{i,j}$.

$$\Theta = \{\eta_m, [\epsilon_{i,j}]\}, \epsilon_{i,j} = (\eta_i, \eta_j, \beta_{i,j}) \quad (1)$$

Traffic demand is composed by the set of trips $[W_a^G]$ generated by a vehicle population $[\Omega_G]$ belonging to G differentiated groups. Traffic groups are called fleets and have distinguished properties in terms of routing needs and capabilities. Each vehicle belonging to group G is represented by its routing agent v_a^G (v_a in general).

Each trip $W_a(v_a, t_a^0, O_a, D_a)$ is defined by its routing agent v_a , the starting timestamp t_a^0 , the starting node O_a and the destination node D_a .

Traffic flows $\mathbb{T} = [f_1, f_2 \dots f_F]$ are described by the trips that have the same origin and destination (O_i, D_i), where F represents the number of distinct O/D pairs. Origins and

destinations can be physical network nodes, traffic area zones (TAZ) or traffic centroids.

Every routing agent v_a belonging to the flow f_i , chooses a route r_a which is formed by the ordered sequence of nodes and links $\epsilon_{i,j}$ that connects trip origin and destination (O_i, D_i). The cost $\Psi(\Theta, r_a)$ of the route r_a evaluated in the network Θ is the sum of the costs of the traversed links [12]:

$$\Psi(\Theta, r_a) = \sum \Psi(\Theta, \epsilon_{i,j}), \forall \epsilon_{i,j} \in r_a \quad (2)$$

Under free-flow traffic conditions [29], link costs are evaluated as $\beta_{i,j}^*$ (3) which is the minimum travel-time for the link (link distance $d_{i,j}$ at maximum link speed $s_{i,j}$):

$$\Psi_{FF}(\Theta, \epsilon_{i,j}) = \beta_{i,j}^* = \frac{d_{i,j}}{s_{i,j}} \quad (3)$$

Static traffic assignment mechanisms consider this free-flow travel-time $\Psi_{FF} : \Theta \rightarrow \beta_{i,j}^*$ as the basis for "all-or-nothing" traffic assignment [29]. It is used when no traffic status information is available for the routing agents.

When the traffic network load is considered to evaluate route costs, then Wardrop's equilibrium criteria need to be applied, and volume-delay functions (VDF) are used to re-evaluate link costs [36]. TWM can be used with any VDF function where the most commonly used is (4) defined by the Bureau of Public Roads (BPR) [16], [29]. It estimates the link cost (travel-time β_{ij}) as a function of the free-flow cost travel time β_{ij}^* augmented by a factor that depends on the current traffic w_{ij} served by the link and its effective link capacity C_{ij} . Two correcting factors k_1 and k_2 are used with typical values of $k_1 = 0.15$ and $k_2 = 4.0$.

$$\beta_{ij} = \beta_{ij}^* * (1 + k_1 * (\frac{w_{ij}}{C_{ij}})^{k_2}) \quad (4)$$

The effective link capacity C_{ij} can be obtained from the traffic fundamental diagrams and tables. A complete discussion can be found at [9].

B. TRAFFIC WEIGHTED MULTI-MAPS (TWM)

Part of the TWM formulation was first introduced in [31] and is partially reproduced for readability and extended for the optimal TWM calculus. A multi-map TWM $[\mu_i]$ is a set of M views (maps) of the traffic network Θ , which is assigned and distributed to the routing agents $[v_a]$ of a traffic network. Each routing agent uses the cost function Ψ over the received network view μ_i to calculate route costs. TWM composition is described in terms of three main factors: 1) weight assignment policies, b) number of available maps, and c) vehicle assignment policies. View μ_0 reflects the default physical view of the network Θ .

If we consider per-category assignment where every traffic category G uses M specific maps, the TWM will be formed by $G \times M$ maps. Alternatively if we consider per-traffic flow assignment, the TWM will be formed by $F \times M$ maps. F is the number of O/D tuples (flows).

Each map μ_m (5) is the m -representation of the traffic network Θ , formed by a set of weights $[\beta_{i,j}^m]$ representing

the directed traversing cost of each available link. They are obtained applying a cost evaluation function Π over a) the network topology Θ ; b) the traffic groups $[\Omega_G]$; c) certain time-constraints $[\Gamma_m]$ for map usage; and d) network traffic status data Φ . Time constraints $[\Gamma_m]$ and traffic status data Φ are used in dynamic traffic assignment scenarios.

$$\Pi : \Theta, [\Omega_G], [\Gamma_m], \Phi \rightarrow [\mu_m] \quad (5)$$

$$\mu_m = \left\{ [\epsilon_{i,j}], [\beta_{i,j}^m], \Gamma_m \right\} \quad (6)$$

We define the TWM adherence factor ψ (7) as the percentage of agents $[v_a]_{TWM}$ that are using TWM, as there could be a partial adoption of the routing mechanism. ψ is used to compare different TWM adoption scenarios.

$$\psi = \frac{\sum [v_a]_{TWM}}{\sum [v_a]} \quad (7)$$

Previous work [31] analyzed the impact of TWM under different adherence scenarios using non-optimal functions Π that provide the $[\beta_{i,j}^m]$ weight maps. Approaches used so far were: a) linear scaling of current weights, b) adding certain randomness in the original maps so that new alternative routes are selected, or c) creating maps to solve incidents in the network. In this work we use optimization functions to calculate weight maps.

C. FLOW-PATHS

Routing agents v_a may be located either in the vehicle or in a remote back-end that provides route-as-a-service capabilities. Every v_a calculates the best route r_a in terms of minimal route cost. Minimum route cost calculation is made for every trip using a routing algorithm R_a that depends on: a) the origin and destination points (O_a, D_a); b) the network map selected μ_m ; and c) the current traffic status described by link occupation $[w_{i,j}]$ [30].

Given a traffic demand described as the set of flows $\mathbb{T} = [f_1, f_2 \dots f_F]$, a function Υ (8) is defined to obtain the k-shortest paths (routes) for the flows $R_m^{F,k} = [(r_1^1, \dots, r_k^1), \dots, (r_1^F, \dots, r_k^F)]$ when the network view μ_m is used. It receives as inputs: 1) the traffic demand \mathbb{T} as O/D pairs; 2) a network map μ_m , 3) the (minimum cost) routing algorithm R_a , and 4) the number of k-shortest paths.

$$\Upsilon : \mu_m, \mathbb{T}, R_a, k \rightarrow R_m^{F,k} = \left[(r_1^1, \dots, r_k^1), \dots, (r_1^F, \dots, r_k^F) \right] \quad (8)$$

We denote the flow-path R^k of the traffic demand \mathbb{T} , as the route set obtained from Υ using the physical traffic network μ_0 under the ‘‘all-or-nothing’’ conditions [29].

In this work we use the Dijkstra routing algorithm [15], though other strategies may be used for the flow-path calculus such as A*, hyperpaths or disjoint-paths [22], [24], [30], [52].

IV. TRAFFIC ASSIGNMENT USING TWM OPTIMIZATION STRATEGIES

The optimization problem consists on finding the weights for a TWM map set that minimize our target objectives while

considering a cost function Ψ . Our work considers total travel-time as the target objective.

This section provides some optimization strategies based on the creation of optimal network map weights. They are compared to standard TAP algorithms for UE/SO, and also with random-weights assignment strategy. Total travel time is computed as the sum of every trip travel time, considering the assigned routes and the network load reflected by the link weights.

A. REFERENCE STRATEGIES

TAP static methods provide an excellent theoretical framework to estimate the UE situation despite their limitations [44], while SO is usually estimated using dynamic assignment.

Optimal TWM strategies focus on SO using static maps, so they are compared with other static methods mainly used for UE: 1) cumulative traffic assignment method (CAM); 2) the successive averages method (MSA), and 3) linear programming optimization method (WEI-LP) [14], [29], [49]. Wei’s approach considers statically both UE and SO.

1) CUMULATIVE ALGORITHM (CAM)

It splits the traffic demand into traffic subsets (buckets) that are loaded to the network by incremental steps. The first traffic trips subset is loaded into the network, finding an ideal empty traffic network (the all-or-nothing approach). Selected routes will use maximum capacity of the links. When the next traffic subset is loaded, the link weights for route calculation are modified usually applying the VDF function. All the trips subsets are gradually loaded by this method to the traffic network. Precision of the algorithm depends on the number and size of the traffic buckets, and results may vary depending on the trips load order and the directionality of the traffic.

2) SUCCESSIVE AVERAGES ALGORITHM (MSA)

It uses an iterative procedure considering the entire demand in every step. In step 0, demand is routed in an all-or-nothing approach producing a loaded network (link occupation). Step 1 balances the traffic demand between the previous network and the loaded network assigning a fraction φ of the demand to the new view. Every step repeats the previous process until the global network load has not changed or the maximum number of iterations has been reached. To improve the convergence of the algorithm, it is convenient to reduce in every step the fraction φ of the demand. Usually a $\varphi = \frac{1}{i}$ is used for the i^{th} iteration.

3) LINEAR PROGRAMMING APPROXIMATION FOR TAP SOLVING (WEI-LP)

Wei *et al.* [49] have shown that the UE optimality condition pointed by Beckmann *et al.* [6] can be efficiently computed by means of second-order cone functions and linear-programming approaches.




FIGURE 2. Non-uniform partition of link ϵ_{ij} occupation for Wei's LP algorithm.

Considering the LP approach (WEI-LP), the convex VDF function (4) that describes link performance, can be approximated with a bounded error, by means of a piece-wise linear function f_{ij} . In order to reduce the number of slices, a non-uniform partition for each link is created with an adaptive function, as shown in Figure 2. The partition is upper-bounded by a X_{ij} value which depends on the maximum link capacity C_{ij} .

For a given traffic demand, the SO is defined by the trip distribution that leads to the minimum sum of link travel times, so TAP is reduced to obtain the link traffic occupation set $[w_{ij}]$ restricted to the $[f_{ij}]$ functions.

WEI-LP algorithm solves iteratively the TAP problem considering progressive traffic routing distributions. It starts assigning an AON routing strategy to the vehicles based on k-shortest paths, and solving the TAP with $[f_{ij}]$. It produces new link weights based on the VDF function, showing that some vehicles may have obtained better min-cost routes considering these weights. These new min-cost routes are then calculated by means of a Mixed-Integer Linear Programming function (MILP) and added to the routing strategy. Again, a new TAP evaluation is needed to obtain the traffic distribution for this new routing scenario. This situation loops until no more min-cost routes can be added.

This algorithm provides an interesting static TAP solution that considers both UE and SO, though it requires $[f_{ij}]$ calibration considering the maximum link occupation.

4) RANDOM TWM ALGORITHM (R-TWM)

The most simple TWM algorithm consists on just creating m weight maps $[\beta_{i,j}^m]$ that include random variations in the link weights from the original map. The aim of R-TWM is to stochastically distribute trip routes flows through specific network links in a one-shot fashion by generating maps with different link weights. We use the Π_δ random function that uses a random factor δ and a constant scaling factor k_1 :

$$\Pi_\delta : [\epsilon_{i,j}], [\Omega_k], [\Gamma_m] \rightarrow [\mu_m] \mid \beta_{i,j} = k_1 * \beta_{i,j}^* * (1 + \delta) \tag{9}$$

We use Π_δ random in our experiments with normal and uniform distributions using δ as $\delta_{normal} = normal(a, b)$ (a stands for the mean value and b stands for the statistical

dispersion amplitude) and $\delta_{uniform} = uniform(a, b)$ (ranging from a to b).

B. OPTIMAL LINK WEIGHT EVOLUTIONARY STRATEGIES

The most direct approach for traffic optimization using TWM is to obtain the optimal link-weight $[\beta_{i,j}^m]$ sets for a collection of M maps, considering a certain traffic demand \mathbb{T} that is known, estimated or predicted in advance. Optimal criteria take into account the network load status at every moment.

The global process consists on these steps: 1) optimal TWM evaluation calculus for the traffic demand, 2) TWM assignment and distribution to the vehicles; 3) traffic assignment considering the TWM maps; and 4) assignment evaluation.

We consider a common link-weight optimization algorithmic core with several study cases: a) B-TWM, the basic approach that considers optimization over the whole network; b) FP-TWM that considers weight optimization of the flow-paths; and c) EFP-TWM that considers flow-path extension to their surrounding links, transforming them into routing areas.

1) TWM LINK-WEIGHT OPTIMIZATION CORE

Our TWM optimization problem focuses on minimizing Total Travel-Time (TTS) in the traffic network (10). The optimization algorithm \mathcal{F} takes as inputs the network Θ , the traffic demand (flows) \mathbb{T} , the depth M of the TWM, and a TWM-to-vehicle assignment function f^A . It produces a $[\mu_m]$ configuration that minimizes our fitness function TTS.

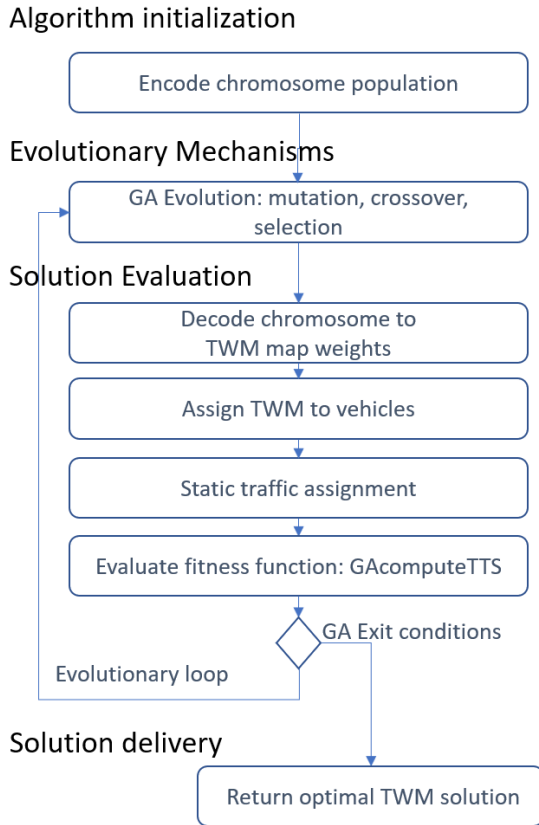
$$\mathcal{F} : \Theta, \mathbb{T}, M, f^A \rightarrow [\mu_m] \mid min(TTS) \tag{10}$$

Due to the nonlinear properties and the real-world size of the TAP problem, evolutionary algorithms (GA) provide a way to find problem solutions through generating and evaluating multiple population candidates that evolve. They use several mechanisms such as: selection, mutation and crossover. Effectiveness and wellness of found solutions are evaluated by comparison to the reference strategies.

Chromosome \aleph encodes the link weights in the network, and individuals represent different network link weights configurations.

The whole process of the evolutionary algorithm is depicted in Figure (3):

- 1) There is an initial chromosome encoded using algorithm parameters: network topology, number of TWM maps, and other parameters.
- 2) Every population iteration generates a \aleph chromosome whose genes represent TWM weights. The chromosome is created using evolutionary methods that include: selection to retain the genes (weight distributions) which provide lower TTS; mutation to modify link-weighting policies, thus causing new paths to be explored; and crossover to exchange weight criteria between links, exploring bonus and penalties in their usage.


FIGURE 3. Genetic algorithm for B-TWM, FP-TWM and EFP-TWM.

- 3) They are decoded to the M TWM maps as illustrated by Figure (4).
- 4) These maps are assigned to the vehicle population, using an assignment function f^A . It provides map-selection criteria for every vehicle from the TWM $[\mu_m]$. Several strategies may be used: a) random assignment; b) based on traffic flows; c) based on vehicle fleet grouping; d) sequential, or any other. For the map weights optimization problem, we use random assignment as it enables independent routing decisions not biased by other factors. It is shown in Figure (4), where any vehicle receives a $[1 \dots M]$ map index referencing to the corresponding map of the TWM.
- 5) Every vehicle uses this TWM map to select the best-cost route r_a using its routing algorithm ($R_{Dijkstra}$) and “all-or-nothing” assumption.
- 6) When all the static traffic assignment is done, the objective TTS is evaluated.
- 7) The genetic algorithm iterates over the target population, ending by any of these conditions: 1) when the algorithm reaches a minimum fitness for the tolerance allowed, 2) when the maximum number of iterations has been reached, or 3) when maximum processing time has been wasted. When some of the exit conditions are met, the chromosome is decoded to the optimal TWM solution.

The GA returns the best fitting chromosome with the link-weights to be used in the TWM maps $[\mu_m]$, which are distributed to the vehicles for the traffic assignment stage and final TTS performance evaluation. The assignment function f^A is used to distribute the TWP maps $[\mu_m]$ to the vehicles. Then, every vehicle uses the assigned TWM map to select the best-cost route choice.

We use the fitness function $computeTTS_{static}$ (11) that receives the loaded network Θ_L , the routes assigned to the vehicle trips, and a reference to the volume-delay function Ψ_{VDF} , returning total travel time evaluation:

$$computeTTS_{static} : \mu_0, \Theta_L, \Psi_{VDF} \rightarrow TTS \quad (11)$$

Individual route selection r_a is made considering the assigned μ_a logical map from the TWM, though global TTS evaluation is measured with the real physical view μ_0 of the network. After that, TTS is evaluated with the all-or-nothing (AON) criteria, as the sum of the individual route r_a cost evaluations:

$$TTS = \sum_a \Psi(\mu_0, r_a) = \sum_a \sum_i \Psi_{VDF}(\mu_0, \epsilon_{i,j}^a) \quad (12)$$

$$\forall \epsilon_{i,j}^a \in r_a \quad (13)$$

2) BASIC TWM OPTIMIZATION ALGORITHM (B-TWM)

The *Basic TWM Optimization algorithm (B-TWM)* provides the most straightforward approach to find an optimal TWM solution for the TAP problem. B-TWM uses a genetic algorithm (GA) where the chromosome \mathfrak{N}_B is composed of $E \times M$ genes, representing the set of variables to be optimized:

- $E = size([\epsilon_{i,j}])$ is the number of links of the traffic network (considering road directions as separate links).
- $M = size([\mu_m])$ is the number of maps that define the TWM.

Figure (4) shows how the chromosome \mathfrak{N}_B is configured: for every map μ_m in the TWM, and for every link in the map, there is one gene representing the link weight. The genes are linearly concatenated as shown in (14):

$$\mathfrak{N}_B = [(\beta_{11} \dots \beta_{1E}), (\beta_{21} \dots \beta_{2E}) \dots (\beta_{M1} \dots \beta_{ME})] \quad (14)$$

Algorithm 1 details the GA evaluation procedure for B-TWM, while Algorithm 2 shows how the chromosome \mathfrak{N}_B is encoded and decoded.

3) FLOW-PATH TWM OPTIMIZATION ALGORITHM (FP-TWM)

Basic TWM Optimization algorithm (B-TWM) complexity may be high due to the size of chromosome \mathfrak{N}_B , $size(\mathfrak{N}_B) \mathcal{D} E * M$ which depends directly on the number of links and TWM cardinality. The number of variables could be very high depending on the topology of the network. Besides, not all the links are electable for traffic demand purposes as vehicles may never use them. They may provide null or small benefit for routing purposes though they increase computing complexity. We need a strategy that focuses on the most valuable links from the routing perspective.

This routing perspective can be achieved by means of the flow-paths R^k in the network. FP-TWM algorithm considers

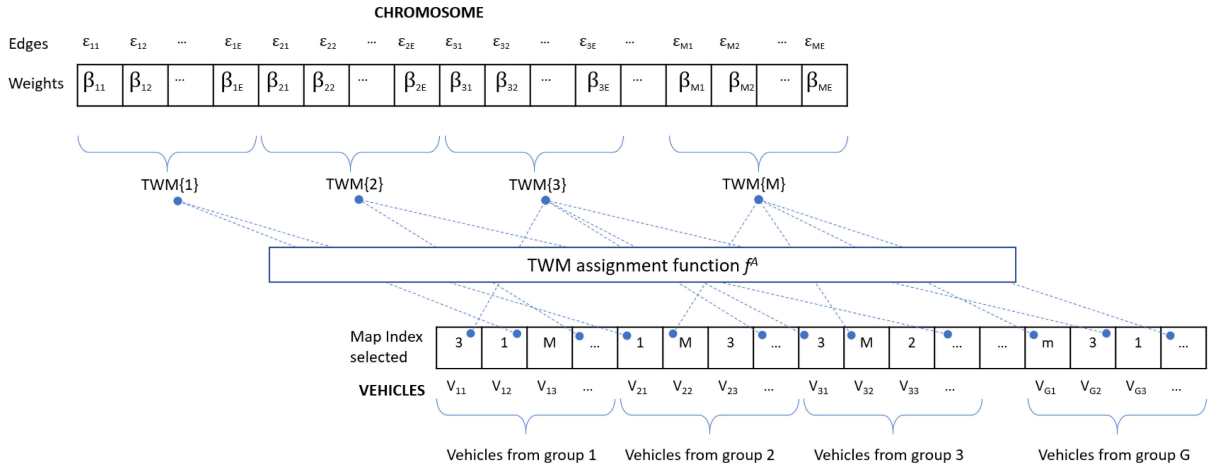


FIGURE 4. B-TWM chromosome composition \mathfrak{S}_B .

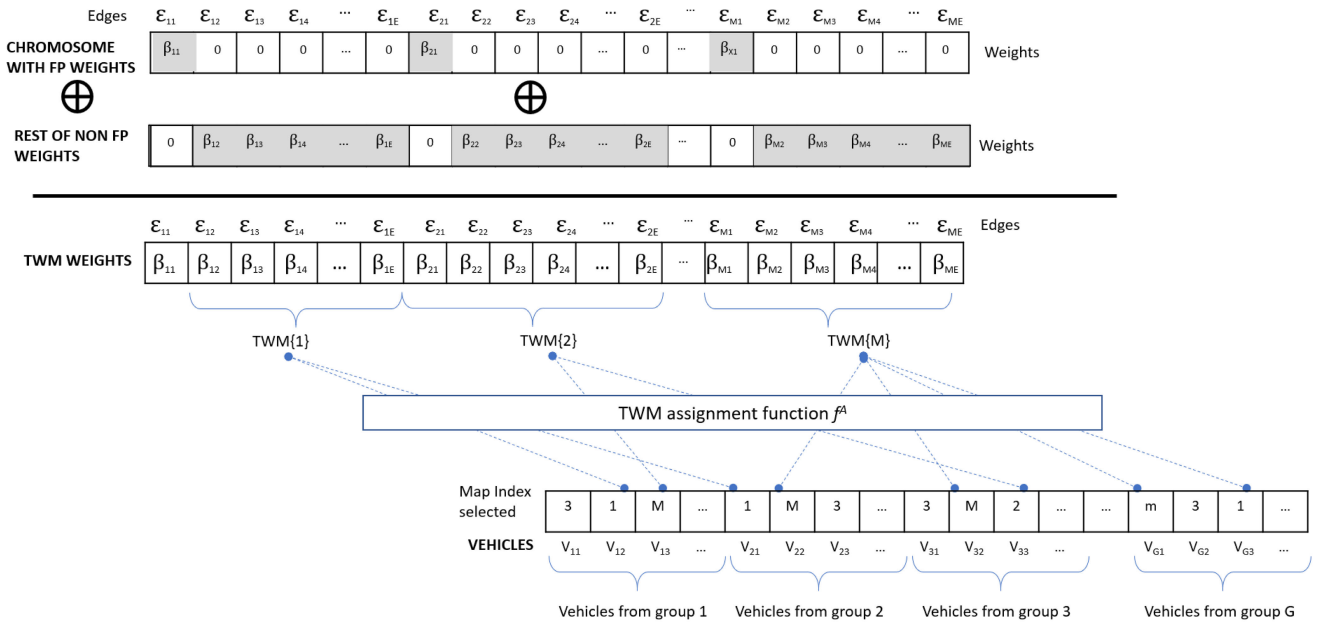


FIGURE 5. FP-TWM chromosome composition \mathfrak{S}_{KSP} .

optimization on the weights which exclusively belong to the flow-paths. The flow-path is formed by a route set $[r_1^f, \dots, r_k^f]$ that also conforms a connected sub-graph Θ_f^{KSP} of the network Θ :

$$\Theta^{F,k} = \{[\eta_m], [\epsilon_{i,j}]\}, \epsilon_{i,j} \in [r_1^f, \dots, r_k^f] \quad (15)$$

The optimization problem now adds both the number of k-shortest paths to consider, and the routing algorithm R_a to use ($R_{Dijkstra}$ in our study). It is expressed by (16):

$$\mathcal{F} : \Theta^{F,k}, \mathbb{T}, M, f^A, k, R_a \rightarrow [\beta_{i,j}^m], [\mu_m] \mid \min(TTS) \quad (16)$$

We design the \mathfrak{S}_{KSP} chromosome for the FP-TWM algorithm with those genes corresponding to links that are part of any flow-path. If the original traffic network has E links

and the flow-path contains E^{FP} unique links, then FP-TWM algorithm reduces complexity to $\frac{E^{FP}}{E}$.

Figure (5) shows how the chromosome \mathfrak{S}_{KSP} is configured. For every map μ_m in the TWM, and for every unique link in the map that is included in the flow-path, one gene is added to represent the link weight. \mathfrak{S}_{KSP} is formed now by $E^{FP} \times M$ genes.

The genes are coded as a linear array as shown in (17):

$$\mathfrak{S}_{KSP} = [(\beta_{11} \dots \beta_{1E}), (\beta_{21} \dots \beta_{2E}) \dots (\beta_{M1} \dots \beta_{ME})] \quad (17)$$

The evaluation function is shown in Figure 3: it receives the \mathfrak{S}_{KSP} chromosome and splits it into M -blocks corresponding to the M maps of the TWM. The link weights of each map μ_m of the TWM are combined with the weights received from

Algorithm 1 B-TWM GA Evaluation Procedure

```

1: function B_TWM_algorithm( $\mu_0, M, \Psi_{VDF}, [W_a^G], [v_a^G]$ )
2:   maxIterations = someValue
3:   maxTime = someValue
4:   minTTSDelta = someValue
5:    $\aleph_B = B\_encodeChromosome(\mu_0, M)$ 
6:   TTS = 0
7:   TTSprev = 0
8:   iter = 0
9:   repeat
10:    TTSprev = TTS
    ▷ Evolve the chromosome
11:     $\aleph_B = GA\_evolve(\aleph_B, \dots)$ 
12:    twm = B_decodeChromosome( $\aleph_B, M$ )
    ▷ Assign TWM maps to the vehicles,  $f^A$ 
13:     $[v_a^G].map = assignTWM([v_a^G], twm)$ 
    ▷ Static traffic assignment
14:     $\Theta_L = staticAssignment_{AON}(\mu_0, [v_a^G], twm, [W_a^G])$ 
    ▷ Compute total TTS
15:    TTS = computeTTSstatic( $\Psi_{VDF}, \Theta_L$ )
16:    TTSdelta = TTSprev - TTS
17:    iter ++
    ▷ exit condition 1: iter >= maxIterations
    ▷ exit condition 2: executionTime >= maxTime
    ▷ exit condition 3: TTSdelta >= minTTSDelta
18:  until exitCondition
19:  twmopt = B_decodeChromosome( $\aleph_B, M$ )
    ▷ Assign optimal TWM maps,  $f^A$ 
20:   $[v_a^G].map = assignTWM([v_a^G], twm_{opt})$ 
    ▷ Static traffic assignment
21:   $\Theta_L = staticAssignment_{AON}(\mu_0, [v_a^G], twm_{opt}, [W_a^G])$ 
    ▷ Compute total TTS
22:  TTS = computeTTSstatic( $\Psi_{VDF}, \Theta_L$ )
23:  return TTS
24: end function

```

the \aleph_{KSP} chromosome block. The combination is made by direct replacement of the corresponding weight. The resulting TWM $[\mu_m]$ is then assigned to the vehicles using the f^A distribution function, and finally, the static traffic assignment is calculated.

FP-TWM algorithm evaluation considers the generated TWM maps $[\mu_m]$ to calculate the static traffic assignment.

4) EXTENDED FLOW-PATH TWM OPTIMIZATION ALGORITHM (EFP-TWM)

Usage of free-flow k-shortest path as optimization criteria reduces considerably the amount of link weights to be calculated. But it also restricts the GA search space assuming certain routing constraints: a) it only considers direct linear routes included in the flow-path, ignoring other feasible route variations; b) flow-paths are estimated under ideal “all-or-nothing” conditions which discard traffic network status; and c) it doesn’t take into account that TWM are maps and they

Algorithm 2 B-TWM Chromosome Encode and Decode Functions

```

1: function B_encodeChromosome( $\mu_0, numMaps$ )
    ▷ Create chromosome from the network map
2:   numLinks = getNumLinks( $\mu_0$ )
3:    $\aleph_B = zeros(numMaps * numLinks)$ 
4:   for m = 0; m < numMaps; m++ do
5:     for w = 0; w < numLinks; w++ do
        ▷ Assign each gene the corresponding link weight
6:       genei = m * numLinks + w
7:        $\aleph_B[genei] = getLinkWeight(\mu_0, w)$ 
8:     end for
9:   end for
10:  return  $\aleph_B$ 
11: end function
12: function B_decodeChromosome( $\aleph_B, numMaps$ )
    ▷ Create a TWM from the B-TWM chromosome
13:  twm = newTWM[numMaps]
    ▷ Initialize every TWM map with the network map
14:  twm[m] =  $\mu_0$ 
15:   $[weights] = split(\aleph_B, numMaps)$ 
16:  for m = 0; m < numMaps; m++ do
        ▷ Assign the gene to the TWM link
17:    twm[m].weights = weights[m]
18:  end for
19:  return twm
20: end function

```

Algorithm 3 FP-TWM Chromosome Decoding

```

1: function FP_decodeChromosome( $\aleph_{FP}, M, \mu_0$ ,)
    ▷ Create TWM from a FP-TWM chromosome
2:  twm = newTWM[M]
    ▷ Initialize every TWM map with the network
3:  twm[m] =  $\mu_0$ 
    ▷ link ids from FlowPaths to index weights
4:  linkIndexes = getLinkIndexes( $\mu_0$ ,)
    ▷ Split the chromosome in M map array chunks
5:   $[weights] = split(\aleph_{FP}, M)$ 
6:  for m = 0; m < M; m++ do
        ▷ Assign the gene to the TWM link
7:    twm[m].weights = weights[m]
8:    i = 0
        ▷ Assign  $i^{th}$  value to  $\mu_m[j]$  link weight
9:    for all j ∈ linkIndexes do
10:      twm[m].weights[j] = weights[m][i]
11:      i += 1
12:    end for
13:  end for
14:  return twm
15: end function

```

represent networks (areas). FP-TWM search spaces provide very constrained solutions.

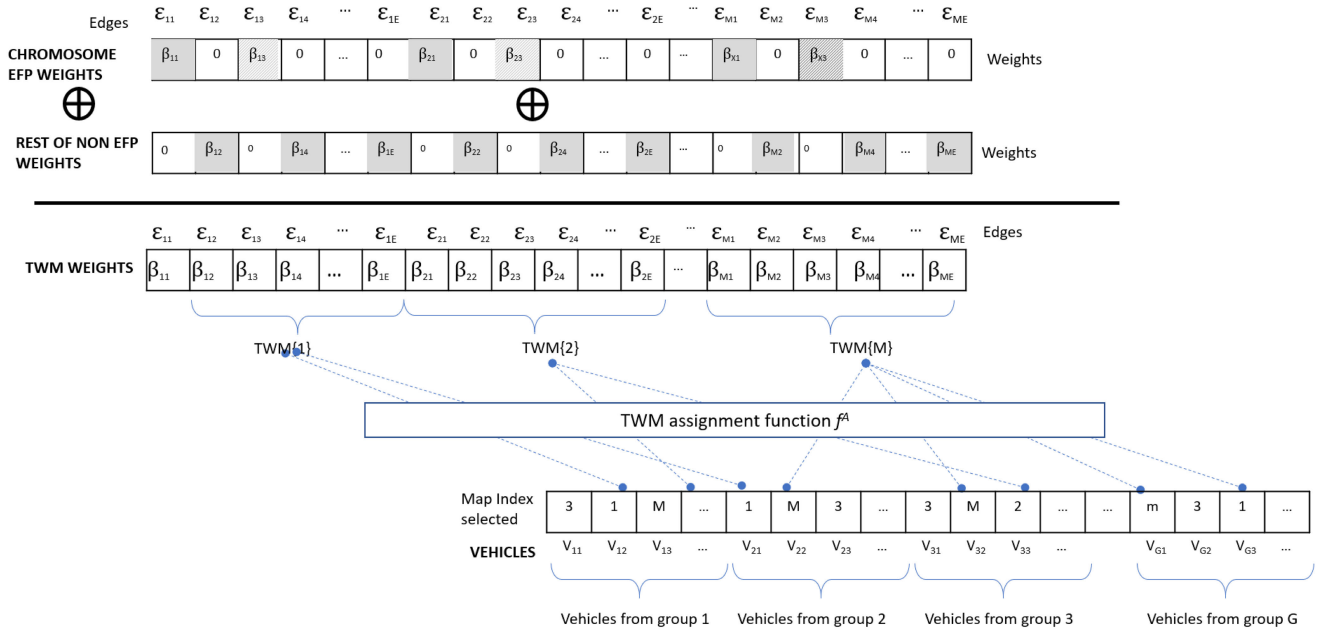


FIGURE 6. EFP-TWM chromosome composition \aleph_{EKP} .

Extended-FP algorithm (EFP-TWM) considers that a route in the flow-path may provide a linear best-route and a routing influence area around it. Congestion in urban networks is spread as waves around the congested links, but also in a complementary way, urban networks usually provide short alternative paths starting from the nodes in the route, which allow slight deviations from the predefined route.

We define the extended k-shortest path of distance d ($EKSP_d$) between origin A and destination B, as the ordered sequence of links that form a KSP together with all the routing influence areas Θ_{η_i} of every node η_i in the KSP. Θ_{η_i} is formed by the reachable connected nodes and links at a distance d from the node η_i (18):

$$\Theta_{\eta_i} = ([\eta_j], [\epsilon_x]) \mid \begin{cases} \eta_j & \text{distance}(\eta_i, \eta_j) \leq d \\ r_{ij} & = (\epsilon_{ia}, \epsilon_{ab} \dots, \epsilon_{yz}, \epsilon_{zj}) \mid \text{len}(r_{ij}) \leq d \\ \epsilon_x & \epsilon_x \in r_{ij} \end{cases} \quad (18)$$

The Extended Flow-Path (EFP) with distance d (EFP_d) for a traffic network Θ considering a traffic demand \mathbb{T} , is formed by the network graph Θ^{EFP} defined by the flow-path R^k and its corresponding extended k-shortest paths $EKSP_d$.

Distance may be calculated as: a) the geographical distance between node A and node B; b) the sum of the route cost between A and B; c) the number of connecting links between A and B; any other criteria which may include node ranking, preferences, or other parameters. In our work for urban scenarios we use option c) to fulfill the traffic conservation equation.

The optimization problem formulation now adds the EFP_d graph Θ^{EFP} and the routing algorithm R_a to use. It is

expressed by (19):

$$\mathcal{F} : \Theta^{EFP}, \mathbb{T}, M, f^A, k, R_a \rightarrow [\beta_{i,j}^m], [\mu_m] \mid \min(TTS) \quad (19)$$

In the EFP-TWM algorithm the \aleph_{EFP} chromosome is formed by those genes corresponding to links that are part of the routing influence areas $[\Theta_{\eta_i}]$. Figure (6) shows how the chromosome \aleph_{EKP} is configured: for every map μ_m in the TWM, and for all the links contained in the routing influence areas $[\Theta_{\eta_i}]$, there is one gene representing the link weight. The genes are linearly concatenated as shown in (20):

$$\aleph_{EFP} = [(\beta_{11} \dots \beta_{1E}), (\beta_{21} \dots \beta_{2E}) \dots (\beta_{M1} \dots \beta_{ME})] \quad (20)$$

\aleph_{EFP} is formed now by $E^{EFP} \times M$ genes, where $E^{EFP} = \text{size}([\epsilon_{i,j}]^{EFP}) \forall \epsilon_{i,j} \in [\Theta_{\eta_i}]$ is the number of links contained in the routing influence areas $[\Theta_{\eta_i}]$.

EFP-TWM optimization uses the GA chromosome \aleph_{EFP} that includes the EFP links for all the traffic flows of the network. The GA evaluation function is the same as FP-TWM described in Figure 3, where a new chromosome decoding function $EFP_decodeChromosome(\aleph_{EFP}, [\mu_m], \mu_0, \Theta^{EFP})$ is used (procedure 4).

The EFP-TWM algorithm's complexity is higher than FP-TWM but lower than B-TWM depending on the selected node distance: $0 \leq \frac{E^{FP}}{E} \leq \frac{E^{EFP}}{E} \leq 1$.

5) GA FEATURING AND PERFORMANCE FOR OPTIMAL LINK-WEIGHT ALGORITHMS


All the optimal link-weight strategies (B-TWM, FP-TWM, EFP-TWM) use unconstrained GA feature sets for selection, mutation, and crossover, provided that the link-weights

Algorithm 4 FP-TWM Chromosome Decoding

```

1: function EFP_decodeChromosome( $\mathfrak{N}_B, M, \mu_0, \Theta^{EFP}$ )
    ▷ Create a TWM from the EFP chromosome
2:   twm = newTWM[M]
    ▷ Initialize every TWM map with the network map
3:   twm[m] =  $\mu_0$ 
    ▷ link indexes are used to map weights
4:   linkIndexes = getLinkIndexes( $\mu_0, \Theta^{EFP}$ )
    ▷ Split the chromosome in numMaps array chunks
5:   [weights] = split( $\mathfrak{N}_B, M$ )
6:   for m = 0; m < M; m++ do
7:     i = 0
        ▷ Assign the ith value to the  $\mu_m$  link weight
8:     for all j ∈ linkIndexes do
9:       twm[m].weights[j] = weights[m][i]
10:      i += 1
11:     end for
12:   end for
13:   return twm
14: end function

```


FIGURE 7. Grid64 synthetic scenario.

(costs) in a map depend on the link length, which is fixed, max speed, and link status. The algorithm population is formed by the TWM maps over the network, and the chromosome is formed by the link-weights in the map. Stochastic uniform selection strategy is used for weight selection in every evolution stage. It chooses random individuals from uniformly distributed population buckets arranged linearly. In the same way, we consider an elite count for immutable individuals set to 5% of total number of maps.

Mutation is achieved by means of a Gaussian operator that modifies link weights in the maps by adding a random number with mean 0 to the chromosome values. Each generation of the algorithm reduces the impact of the mutation in the evolutive algorithm by shrinking the Gaussian standard

deviation by a factor of $\frac{g}{G_{max}}$ where g is the current generation of the algorithm and G_{max} is the total number of generations.

In the same way, crossover is achieved by random scattered function for the chromosome. It extracts ordered genes (link-weights) at random from two parent individuals (maps), and combines them to generate a new map. It is shown in (21). Crossover is limited to 0.8 fraction.

$$\Phi_{Cross}^{uc} : \mathfrak{N}^A, \mathfrak{N}^B \rightarrow \mathfrak{N}^C \mid \beta_{ij}^C = \beta_{ij}^A \oplus_{uc} \beta_{ij}^B, \quad (21)$$

$$\beta_{ij}^A \oplus_{uc} \beta_{ij}^B = \beta_{ij}^A * r_{01} + \beta_{ij}^B * (1 - r_{01}) \quad (22)$$

$$r_{01} = \text{integer_rand}(0|1) \quad (23)$$

Complexity of GA for optimal-TWM calculus depends mainly on:

- Size of the traffic network, as chromosome size depends on the number of selected links by KSP and distance d .
- Population size and number of generations, which are values that depend mainly on the chromosome size.
- Number of times that minimum cost algorithm needs to be evaluated (Dijkstra). This parameter depends on the number of GA generations, and the traffic demand as number of traffic demand flows (OD pairs). They require path re-evaluation at each generation.

When increasing traffic demand by a D factor, GA algorithm will evaluate the minimum cost routing by $D * g$ (g is the number of GA generations to be evaluated), and thus computing performance will be affected by $D * g * t_R$, where t_R is the computing time of the minimum cost routing function (Dijkstra in our case).

Unlike other SO TAP solutions using microscopic approaches, TWM complexity does not depend on the number of routed vehicles, being enough to know the OD pairs to provide a feasible SO solution.

V. EVALUATION

The main objective of our simulation-based evaluation is to compare the performance of the different optimization strategies for TAP related to other classical (CAM, MSA, WEI-LP and random):

- Which strategy leads to better traffic performance in terms of global travel time TTS?
- How affect the different configuration variables in the optimization process, such as the number of TWM maps and the number of KSP used?
- How do individuals perceive the changes in their routing experience?
- What is the trade-off between algorithm complexity, computation cost, and strategy effectiveness?
- How scales the algorithm for vast areas and high traffic volumes?

For the experimental process over a given urban traffic network, traffic demands are loaded to the TWM generation software that produces several TWM optimized configurations. They are used for individuals routing, obtaining a loaded net-

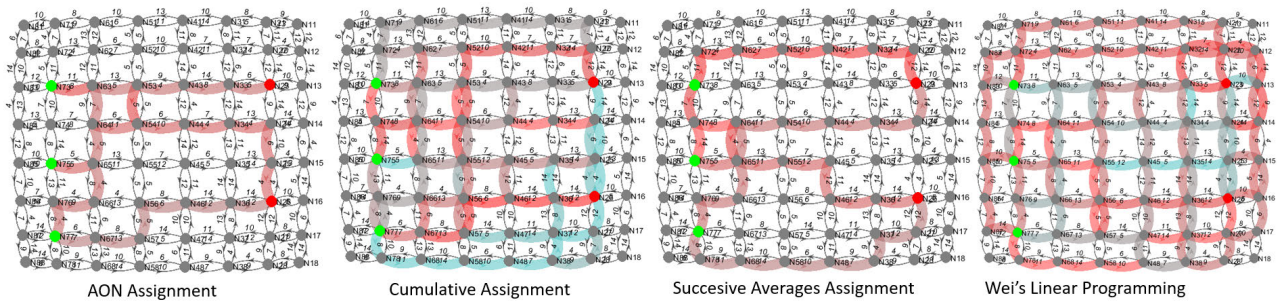


FIGURE 8. Comparison of static traffic assignment with AON, CAM, MSA and WEI-LP on Grid64.

TABLE 1. O/D Matrix.

Source/Destination	N_{73}	N_{75}	N_{77}
N_{23}	1000	500	1000
N_{26}	500	1000	500

work that is used to evaluate global TTS. TAP solutions based on the different TWM configurations are then compared to the mentioned static solutions.

A. SIMULATION ENVIRONMENT SETUP

The GA algorithm design and evaluation framework selected for TWM optimization is a Matlab R2019b environment with the Simulink package and the GA package for Genetic Algorithm processing [1], [2]. It runs in an Intel iCore5 dual-core architecture with 16Gb RAM. Dijkstra k-shortest path implementation follows the algorithm proposed by Yen [51].

Several different scenarios have been considered for the TWM optimal algorithms evaluation: a lab grid scenario with synthetic traffic flows that enables a precise algorithm analysis and an urban scenario corresponding to a real network under congestion that shows the real application of the optimized TWM. All the experiments use heavily loaded scenarios where the TAP is of application.

B. SYNTHETIC SCENARIOS EXPERIMENTS AND RESULTS

Figure 7 shows the Grid64 network formed by an 8 × 8 nodes cross-connected grid formed by bi-directional edges, making a total amount of 64 nodes and 224 links. Links have uniformly randomly distributed weights in the [4, 12] range. Nodes are named as N_{xy} from their coordinates. The network contains three traffic sources (N_{73}, N_{75}, N_{77}) marked in green in the figure) that generate traffic to the sinks (N_{23}, N_{26} , shown in red in the figure) with a distribution of 6 traffic flows. The payloads are shown in Table 1, with 4,500 vehicles to be routed in the time frame considered.

According to the BPR’s VDF function (4) the following values are widely used $k_1 = 0.15, k_2 = 4$. Link capacities are adapted from [9], [46].

Wei’s LP algorithm uses the following parameters: a maximum absolute error for data partitioning considered is 5%,

TABLE 2. Performance of non TWM traffic assignment methods on Grid64.

Method	Routes	Total travel time	Mean Travel Time	Execution Time
AON	6	74,713,058	16,603	0.09s
CAM	61	499,218	111	5.22s
MSA	6	459,154	102	4.28s
WEI-LP	35	536,890	69	37.75s




FIGURE 9. GA chromosome size depending on TWM, KSP and node distances.

a non-uniform value aggregation factor of 0.9, and $X_{ij} = C_{ij} * 2$.

Traffic assignment experiments are exposed in Table 2, describing the leading objective indicator (total travel time), another secondary indicator (mean travel time), the number of alternative routes, and the traffic assignment execution time.

Total travel time and mean travel time obtained with the AON traffic assignment clearly show that the standard routing based on the network topology exclusively (no taking into account traffic status and link occupation) leads to high traffic congestion. UE estimators (CAM, MSA, WEI-LP) provide consistent results framing the theoretical optimal value range, where WEI-LP offers the broadest range of alternative routes, thus reflecting the best results.

Non-TWM reference traffic assignment scenarios are illustrated in Figure 8. AON basic assignment provides just the six routes planned, where no alternative routes selection is made. Cumulative assignment (CAM) generates a total of 61 routes




FIGURE 10. GRID64 Routing sub-graphs for several KSP and node distances.

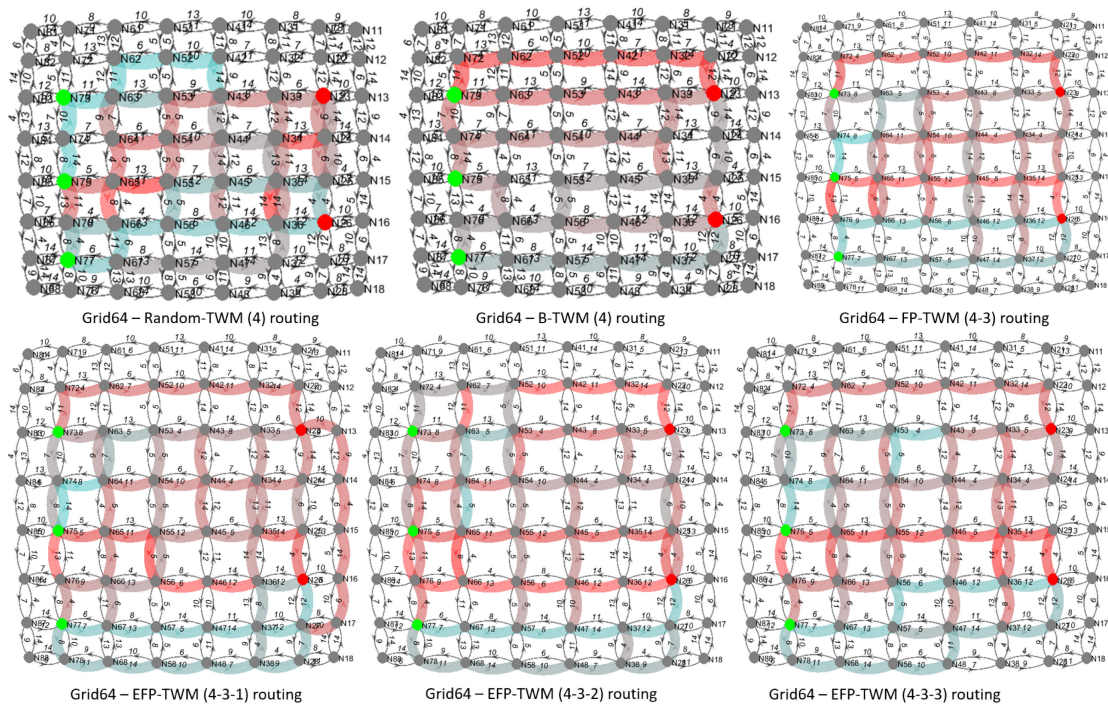


FIGURE 11. Comparison of TWM-based traffic assignment with TWM (4-3-x) on Grid64 network.

using 20 steps for traffic assignment. Successive averages model (MSA) delivers 6 routes considering a convergence limit of 0.001 and using 27 iterations for it, and Wei-LP delivers 35 routes in 7 iterations.

FP-TWM and EFP-TWM algorithms select a set of connected nodes and links which define a sub-graph of the traffic network. TWM weights are optimized for the links contained in the sub-graphs. These sub-graphs are shown in Figure 10 for the 4-layer TWM set with several k-shortest paths [1..3] and node distances [0..3]. The bigger TWM size, number of KSP and d , the wider sub-graph coverage over the whole traffic network, ranging to a full coverage as maximum. Full coverage corresponds to the B-TWM option. Numerical notation (x-y-z) refers to the number of TWM maps, k-shortest paths, and node distances d .

Table 3 zooms several scenarios showing the number of selected nodes and links that are part of the sub-graphs, the size of the GA chromosome (number of genes), and the sub-graph coverage ratio of the whole network. Coverage factors

depend on the network's topology and the origin-destination tuples of the traffic flow for the KSP.

Figure 9 shows the GA chromosome sizes (number of genes) generated from different combinations of TWM sizes, number of k-shortest paths, and distances. Chromosome size affects the GA algorithm performance as the number of variables to be optimized increases, and more population and iterations are required to converge.

Attending to the size and structure of the traffic network, a configuration of 4-layer TWM with 3 k-shortest paths and [0..3] distance is selected for the synthetic experiments. It provides enough path variability to assure the right traffic dispersion to compare the algorithms. TWM algorithm executions use the 6 flows traffic demand defined where each vehicle will be randomly assigned one of the 4 maps coming from the TWM. Once the optimal TWM are created and randomly assigned to the vehicles, they select their minimum cost routes using the TWM map received. This mechanism generates 24 possible routes.

TABLE 3. Nodes and links selection, chromosome sizes and network sub-graph coverage, from several TWM-KSP-node_distance configurations (3-2-3, 4-3-3).

Method	TWM	Nodes	Links	Genes	Coverage
Random	4	64	224	-	-
B-TWM	4	64	224	896	100%

Method	TWM	KSP	d	Nodes	Links	Genes	Coverage
FP-TWM	3	2	0	27	76	304	34%
EFP-TWM	3	2	1	51	170	700	78%
EFP-TWM	3	2	2	62	216	864	96%
EFP-TWM	3	2	3	64	224	896	100%

Method	TWM	KSP	d	Nodes	Links	Genes	Coverage
FP-TWM	4	3	0	28	82	328	37%
EFP-TWM	4	3	1	52	176	704	79%
EFP-TWM	4	3	2	62	216	864	96%
EFP-TWM	4	3	3	64	224	896	100%




FIGURE 12. GA convergence at Grid64 with 50 individuals and 200 generations for the FP and EFP algorithms.

For the EFP-TWM algorithm, several d node distances are considered, ranging from 1 to 3. The sub-graphs that take part in the optimization algorithm are depicted in Figure 10 where FP corresponds to EFP with $d = 0$. They show how the routing sub-graph extends when the EFP distance increases, covering more traffic network areas, selecting more links, and generating more routing alternatives.

Several experiments are then executed for all the described methods: random weights assignment, B-TWM full network optimization, FP-TWM optimization based on the k -shortest paths, and EFP-TWM with several d . Figure 11 shows the routes obtained for every scenario which should be compared to the routes obtained with the static methods (Figure 8). Routing with optimized TWM generates more routing alternatives. Maps are randomly assigned to the vehicles in every optimization loop, clearing the deterministic effects of having a fixed list of vehicles to be routed.

In the random TWM experiment, map weights are uniformly distributed in the range $[\beta_{min}, \beta_M]$ where β_M is a




FIGURE 13. Grid64 total travel time comparison for (4-3-3).

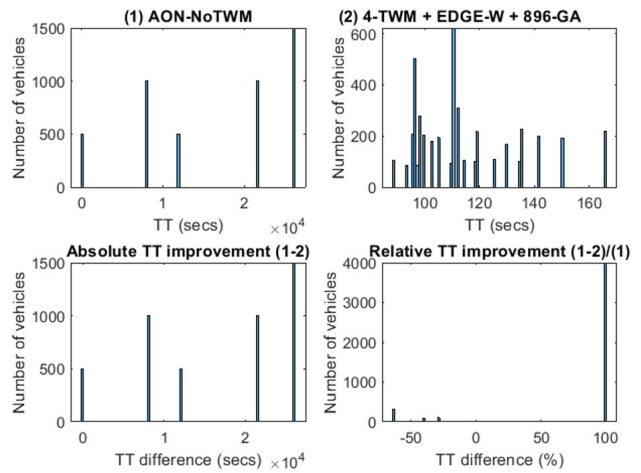


FIGURE 14. Individual travel time comparison between AON and EFP-TWM (4-3-3).

random value over the min and max original network weights β_{min} and β_{max} . It is scaled according to the internal size of the network (number of links, E), which enables enough entropy for map diversity:

$$\beta_M = (\beta_{max} - \beta_{min}) * rand(E) \mid E = count(\beta_{ij}) \quad (24)$$

The GA functions use a population of 200 individuals and 250 generations where the initial population size is 50. These values are selected after several experiments searching GA convergence (see Figure 12) for the 4-TWM, 3-KSP, and $d = [0, 1, 2, 3]$. Algorithm convergence is achieved quickly for the mean value after 50 generations in all the scenarios. GA generations and initial population size depend on the traffic network size (number of links). Gene values in the chromosome are normalized in the $[1,2]$ range to avoid zero-weight links that would create routing conflicts. Selection uses an elite count of 5% of immutable individuals and a stochastic uniform strategy in every evolutionary step. Crossover is limited to a 0.8 fraction of the genes, applying a r_{01} random scattered function as described in (21). Mutation uses an additive 0-mean Gaussian operator to the genes that reduces its impact inversely to the generation iterations.




FIGURE 15. TWM optimal weights distribution, maps 1 to 4, on Grid64 for B-TWM.




FIGURE 16. Grid64 total travel time comparison for TWM(4-3-x) and 10% incremental adherence.

TABLE 4. TWM algorithms performance on Grid64 with TWM(4-3-x).

Method	d	Routes	Total TT (s)	Mean TT. (s)	Execution (s)
Random		24	9,181,913	2040	0.17
B-TWM		24	523,876	116	503.97
FP-TWM	0	24	611,805	136	149.17
EFP-TWM	1	24	543,542	121	316.63
EFP-TWM	2	24	573,904	128	696.90
EFP-TWM	3	24	627,819	140	492.52

Total travel time values are presented in Figure 13 and Table 4 for the 4-TWM and 3-KSP experiments, together with mean travel times and algorithm execution times.

TWM usage enables alternative routing paths, improving congestion (TTS) noticeably compared to the AON scenario. The use of random maps provides traffic improvements, but it is far from being an optimal routing solution: entropy

and route selection improve the congestion scenario but do not lead to the best configurations. Optimized TWM (FP, EFP) generates much better solutions close to the system optimal. Moreover, it is unnecessary to optimize the whole network, but just those links related to the k-shortest paths. Providing TWM sets that affect close adjacency links to the KSP provides better solutions even with small node distances. Even with just a $d = 1$ distance, results are significant.

On the other hand, TAP solutions obtained with optimized TWM are far from the UE obtained by the static methods described, as they encourage traffic distributions close to the SO.

Considering driver’s perspective of individual travel time, it is possible to compare individual travel time obtained in the AON traffic assignment with the TWM-based routing as shown in Figure 14. First two histograms show individual travel times based on AON and EFP-TWM (4-3-3) assignment, where travel time for every selected route can be observed. The histograms in the second-row show the




FIGURE 17. Grid64 total travel time comparison for TWM(4-3-x) for different chromosome sizes and adherences.

improvement of the absolute and relative travel times of the individuals. The relative diagram shows that most vehicles greatly improved while using optimized TWM routing.

Nevertheless, the left side of the relative TT improvement shows that a small fraction of individuals suffers the route unfairness effect described by [4], [35], [37] as inherent to the SO approaches.

Figure 15 illustrates the TWM weight distribution for B-TWM, where a full optimization is made. Link thickness and color densities show the relative link weights. Each map in the TWM has its network view specialization selecting differentiated areas identified by the evolutionary algorithm. These weighted areas thus condition traffic routing.

We may consider that only a part of the vehicles use the TWM routing strategy. The TWM genetic algorithms receive in the optimization function the TWM adherence parameter ψ . Optimization takes into account that only a certain percentage of users use maps coming from TWM, and the rest use the standard original traffic network map. The FP and EFP algorithms take this into account in the map assignment phase while keeping the chromosome distribution immutable. Vehicles now consider $M+1$ maps where the additional map is the original μ_0 .

Figure 16 shows several total travel time measures for different adherence scenarios from 10% to 100% with the algorithm configurations seen so far. As expected, low TWM adherences affect travel times, though total travel time drops when the adherence factor increases. When a considerable amount of vehicles uses TWM, the whole traffic network is improved.

Besides, Figure 17 illustrates how total travel time varies for different adherences and TWM configurations represented by chromosome sizes. TWM optimization for low adoption scenarios ($\psi = 10\%, 20\%$) provides small improvement and increasing TWM optimization complexity is not adding extra benefit. On the other hand, high benefits

TABLE 5. Madrid-Retro Quarter O/D Matrix.

From Node	To Node	Vehicles
1760085654	3964030753	1000
2005647264	1505184332	1000
2005647264	3964030753	1000
25901898	1505184332	1000
25901940	3964030753	1000
25903291	3964030753	1000
3587032531	1505184332	1000
4456617457	3964030753	1000

are easily achieved when adoption rises to $\psi = 40\%$ reaching almost optimal behavior with low algorithm complexity. Higher complexities and bigger adherences scarcely improve results.

Travel time per chromosome length ratio at a TWM adherence shows an interesting empirical result. The creation of optimized TWM based on known estimated initial traffic demands and considering partial adherences provides traffic assignment results very close to the theoretical UE calculus.

C. REAL URBAN TRAFFIC NETWORK EXPERIMENTS

The scenario selected to evaluate the different algorithms is a real urban traffic environment: the central Retro neighborhood in Madrid Spain, extending from GPS coordinates (40.4255, -3.692) to (40.4205, -3.680). It is an urban area with a grid shape formed by 191 nodes and 259 links that enables finding alternative routes for the traffic flows. Figure 18 shows the network detail both in google-maps physical image and the wired traffic network. Traffic origin nodes are marked in green and destinations in red. The traffic network has been obtained from the OpenStreetMaps project [3].

Experiments are based on synthetic traffic demands formed by 8 traffic flows of 1000 vehicles entering from 2 main routing areas with 4 and 3 incoming nodes respectively, with vehicles directing to 2 areas with one main node each. Traffic demand is detailed in Table 5 and illustrated in Figure 18. This experiment uses the same configuration and options in the evolutionary algorithm solver that has been considered in the synthetic experiments.

Figure 19 shows routing dispersion under the different traffic assignment modes: AON shows the basic traffic routes when no UE/SO are considered, leading to traffic congestion. UE estimators (CAM, MSA, WEI-LP) provide a theoretical evaluation framework for UE-TAP, while adding new additional routes attending to the traffic load in the links. TWM traffic routing also provides alternative routes based on SO criterion. In fact, due to the high dispersion and geographical impact of the considered traffic flows, the different TWM algorithms propose similar solutions, at a very different computing cost.

The selected TWM size (4), number of KSP (3), and distances d , determine the network sub-graph that is




FIGURE 18. Madrid - Retiro traffic network showing traffic sources, destinations and demand flows.

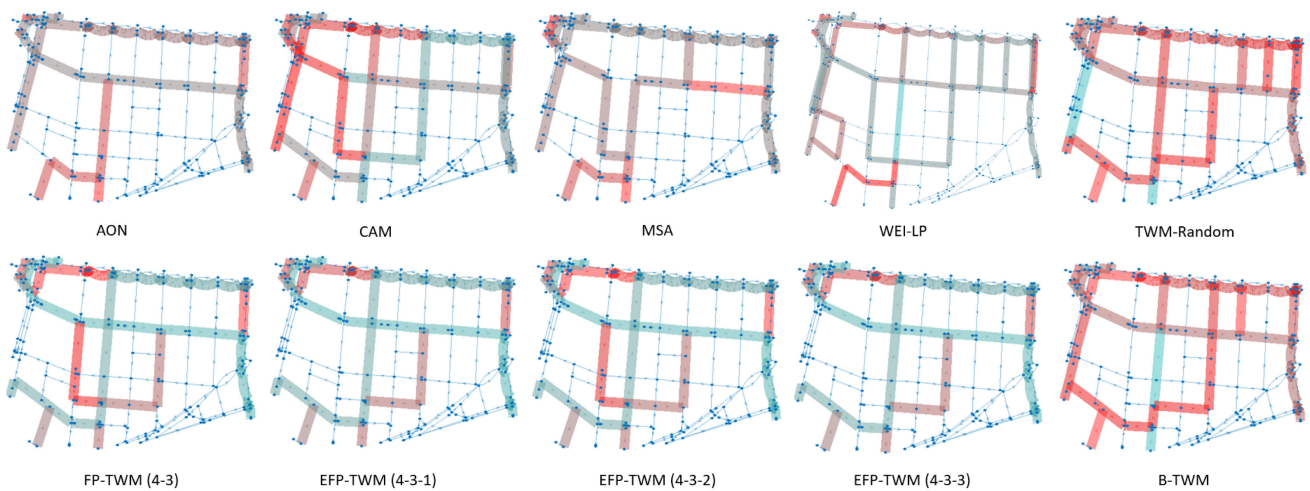


FIGURE 19. Madrid - Retiro routing for UE estimators and TWM configurations B, FP and EFP with (4-3-x).

chosen for weight optimization (number of nodes and number of links), which also will condition the chromosome sizes for the GA execution. They are shown in Table 6.

Total travel time measures, mean travel times and algorithm execution times are detailed in Table 7. TTS are compared in Figure 21 where absolute values are included for the algorithms considered (static UE estimators and the

TWM ones). Taking as a reference the AON TTS, randomly weighted TWM offers a 35% best value but it is far from the theoretical UE-TTS. Random TWM provides enough entropy to improve by itself traffic assignment although it is not an optimal distribution. Instead, optimized TWM maps offer TTS values (~ 58,5%) very close to the UE ones (~ 60%). When we consider TWM optimization, traffic assignment gets very close to its optimal value just using small values,

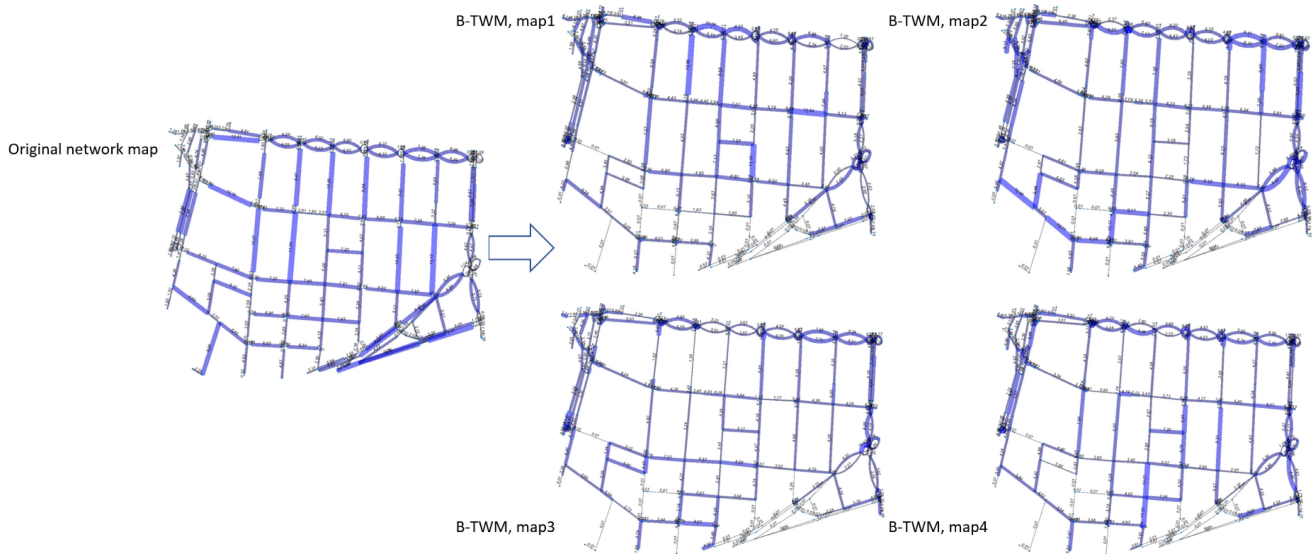


FIGURE 20. B-TWM optimal weight maps 1 to 4, on Madrid-Retiro compared to original network weights.

TABLE 6. Nodes and links selection, chromosome sizes and sub-graph coverage over total network.

Method	TWM	KSP	d	Nodes	Links	Genes	Coverage
Random	4	0		191	259		
B-TWM	4	0		191	259	1036	100%
FP-TWM	4	3	0	107	134	536	52%
EFP-TWM	4	3	1	131	172	688	66%
EFP-TWM	4	3	2	145	192	768	74%
EFP-TWM	4	3	3	154	208	832	80%

TABLE 7. TWM algorithms performance on Madrid-Retiro with TWM(4) and KSP(3).

Method	d	Routes	Total TT.	%AON	Mean TT.	Execution
AON		8	19,382,773		2,423	0.12
CAM		55	7,801,697	59.75%	975	7.51
MSA		8	7,743,361	60.05%	968	6.75
WEI-LP		22	7,365,860	62.00%	847	41.05
Random		32	12,593,118	35.03%	1,574	0.25
B-TWM		32	8,099,209	58.21%	1,010	631.00
FP-TWM	0	32	7,967,106	58.90%	996	685.48
EFP-TWM	1	32	8,045,973	58.49%	1,006	586.33
EFP-TWM	2	32	8,028,827	58.58%	1,004	722.89
EFP-TWM	3	32	8,051,164	58.46%	1,006	1,112.75

as the choice of 4-TWM and 3-KSP adds enough route variety to the route selection.

The difference between the synthetic network results and the real networks mainly consists of the topology because real urban network maps are modeled by many nodes and links representing small network chunks. Calculation of k-shortest paths in these networks provide very similar alternative paths which differ in small amounts of links, where disjoint-paths approaches may be used as discussed by [17].

Figure 20 compares the TWM maps 1 to 4 optimized for B-TWM to the original network weights, where it can




FIGURE 21. Madrid-Retiro total travel time comparison for UE static and SO TWM algorithms.




FIGURE 22. Individual travel time differences between AON and EFP-TWM (4-3-3).

be clearly seen how some routing areas have bonus/malus strategies, which are computed to provide minimum total travel time in the network. The maps also show how differentiated routing will be selected by the vehicles to use different network views. Map assignment is also achieved by random distribution to the vehicles, so each map will contain vehicles belonging to the different flows that use the traffic network.




FIGURE 23. GA performance for Madrid-Retiro experiments.

If we consider how TWM routing impacts driver's perception, most vehicles have improved their travel time by around 30–50, as shown in Figure 22. Few of them suffered a penalty in their routing as they were induced to take bad routes. TWM is a heuristic model that focuses mainly on group behaviors.

Figure 23 shows the GA performance for the considered experiments. Performance mainly relies on how many times traffic assignment needs to be evaluated and the traffic network's physical conditions: network size and topology for k-shortest paths calculus. The number of traffic assignment operations to be executed also depends on the demand (total number of vehicles to be considered) and the GA's termination conditions, as it iterates over the evolutive traffic assignment scenarios until a solution is found.

VI. CONCLUSION AND FUTURE WORKS

This paper has addressed how to approach the Traffic Assignment Problem (TAP) with the System Optimum criterion (SO) using Traffic Weighted Multi-Maps (TWM). They decouple the traffic network from the usage view, distributing different traffic network views to the drivers. TWM resembles the road signaling mechanisms that adapt road usage to certain conditions. However, TWM does not affect the signaling system but the views of the network presented to drivers.

The fundamental question about TWM regarding traffic assignment is how to create optimal network views to minimize total travel time in the network. We have proposed the usage of evolutionary algorithms to find optimal TWM configurations that solve the TAP, minimizing the network's total travel time.

Experiment results obtained under different simulation scenarios based on synthetic networks and real urban scenarios, confirmed that generation of optimized TWM for traffic routing is a feasible task when the traffic demands are known for a given network.

They have also shown that traffic assignment based on TWM allows providing effective routing recommendations to drivers with a performance very close to the theoretical static TAP approaches like cumulative or successive averages traffic assignment.

Evolutionary algorithms have been proved as feasible solvers for the TWM optimization problem. We found that the computational load may be reduced using traffic network sub-graphs based on the traffic demand's k-shortest paths (KSP). These sub-graphs based on KSP and their close surrounding

areas, provide a consistent mechanism to generate routing alternatives based on link weights optimization and differentiated map distribution.

The complexity of optimal TWM distributions depends on several influencing factors. Some of them are intrinsic to the network, like the number of links, road topology and nodes connectivity, and others depend on the traffic demand as the O/D directionality, traffic flow volumes and TWM adherence.

The complexity of the evolutionary algorithms presented for TWM optimization, depends on the chromosome size that mainly depends on the routing demand flows (origin/destinations pairs) and the number of KSP. Several approaches have been tested to reduce the complexity of the process and obtain optimal TWM distributions, reducing computational time and maintaining the solution's accuracy.

It is important to observe that optimal TWM calculus does not depend on the number of vehicles, as other SO approaches do, mainly based on microscopic analysis.

Assuming that not all the network nodes/links are useful for the considered demand, KSP provides a good route selection approach. Moreover, considering that TWM relates to traffic areas and not only to linear routes, we considered surrounding influence areas around the KSP (node distance in the KSP). Total travel time is then evaluated using a static traffic assignment based on TWM.

Interestingly, while static UE approaches provide an estimation algorithm for TAP based on traffic status, optimal TWM provides a practical routing mechanism that delivers traffic assignment results very close to them. These TWM maps are generated using the physical network data and the expected/measured traffic demands.

One of the great advantages of TWM is its simplicity of implementation, as the optimized TWM maps are calculated by a traffic back-end and delivered to the vehicles. TWM maps may be offered as a web-service (map-server or similar). Each vehicle uses the received map to select its best-cost routes with AON policy regardless of the traffic conditions. As an alternative, TWM can be used in web-based routing-service offering optimized routes.

Optimal TWM usage is useful in flow-oriented traffic distributions and can coexist with other background traffic profiles. We have shown how KSP for traffic flows determine smaller routing sub-networks that can be easily optimized with TWM.

Several extensions are being considered for this research, mainly focused on extending the TWM weights optimization to how the maps are assigned and distributed, thus creating optimal map distributions. This approach would lead to a double-step algorithm where: 1) optimal TWM is created considering whole traffic demand, and 2) optimal TWM distribution is done. Finally, proposed optimization algorithms are fast and flexible, and so, it is expected that dynamic traffic assignment (DTA) may be easily implemented with the TWM and flow-path approach.

REFERENCES

- [1] *MatLab—Genetic Algorithm Options-MATLAB & Simulink-MathWorks España*. Accessed: Sep. 2020. [Online]. Available: <https://es.mathworks.com/help/gads/genetic-algorithm-options.html#f6633>
- [2] (Sep. 2020). *MatLab (R2019b)—MATLAB and Simulink Product Families Update*. [Online]. Available: https://mathworks.com/products/new_products/release2019b.html
- [3] *OpenStreetMa*. Accessed: Sep. 2020. [Online]. Available: <https://www.openstreetmap.org>
- [4] E. Angelelli, V. Morandi, and M. G. Speranza, “Minimizing the total travel time with limited unfairness in traffic networks,” *Comput. Oper. Res.*, vol. 123, Nov. 2020, Art. no. 105016.
- [5] A. L. C. Bazzan, D. Cagara, and B. Scheuermann, “An evolutionary approach to traffic assignment,” in *Proc. IEEE Symp. Comput. Intell. Vehicles Transp. Syst. (CIVTS)*, Orlando, FL, USA, Dec. 2014, pp. 43–50.
- [6] M. Beckmann, C. McGuire, and C. Winston, *Studies in Economics of Transportation*, vol. 26. London, U.K.: Yale Univ. Press, 1956.
- [7] M. Behrisch, L. Bieker, J. Erdmann, and D. Krajzewicz, “SUMO—Simulation of urban MOBility: An overview,” in *Proc. Int. Conf. Adv. Syst. Simulation*, Barcelona, Spain, Oct. 2011, pp. 63–68.
- [8] M. Binetti, M. Mitri, and M. Ottomanelli, “Analysis of imprecise perception in route choice considering fuzzy costs,” in *Proc. Adv. Intell. Syst. Comput.* Springer, Jul. 2018, pp. 452–467.
- [9] T. R. Board, “Highway capacity manual, 6th edition: A guide for multimodal mobility analysis,” in *Proc. Nat. Acad. Sci., Eng., Med.*, Washington, DC, USA, 2016, pp. 1–9.
- [10] K.-H.-N. Bui and J. J. Jung, “ACO-based dynamic decision making for connected vehicles in IoT system,” *IEEE Trans. Ind. Informat.*, vol. 15, no. 10, pp. 5648–5655, Oct. 2019.
- [11] J. C. Dias, P. Machado, D. C. Silva, and P. H. Abreu, “An inverted ant colony optimization approach to traffic,” *Eng. Appl. Artif. Intell.*, vol. 36, pp. 122–133, Nov. 2014.
- [12] Y.-C. Chiu, J. Bottom, M. Mahut, A. Paz, R. Balakrishna, T. Waller, and J. Hicks, “Dynamic traffic assignment: A primer,” *Transp. Res. E-Circular, Transp. Res. Board*, Jun. 2011.
- [13] T. Chondrogiannis, P. Bouros, J. Gamper, and U. Leser, “Alternative routing: K-shortest paths with limited overlap,” in *Proc. 23rd SIGSPATIAL Int. Conf. Adv. Geographic Inf. Syst.*, Nov. 2015, pp. 1–4.
- [14] J. Chow and W. Recker, *Informed Urban Transport Systems: Classic and Emerging Mobility Methods toward Smart Cities*. Amsterdam, The Netherlands: Elsevier, 2018.
- [15] E. W. Dijkstra, “A note on two problems in connexion with graphs,” *Numerische Math.*, vol. 1, no. 1, pp. 269–271, Dec. 1959.
- [16] *Traffic Assignment Manual* Bureau of Public Roads., U.S. Department of Commerce, Washington, DC, USA, 1964.
- [17] T. Eilam-Tzoref, “The disjoint shortest paths problem,” *Discrete Appl. Math.*, vol. 85, no. 2, pp. 113–138, Jun. 1998.
- [18] D. Eppstein, “Finding the K-shortest paths,” *SIAM J. Comput., ACM*, vol. 28, pp. 652–673, Feb. 1970.
- [19] M. Frank and P. Wolfe, “An algorithm for quadratic programming,” *Naval Res. Logistics Quart.*, vol. 3, nos. 1–2, pp. 95–110, 1956.
- [20] T. L. Friesz, J. Luque, R. L. Tobin, and B.-W. Wie, “Dynamic network traffic assignment considered as a continuous time optimal control problem,” *Oper. Res.*, vol. 37, no. 6, pp. 893–901, Dec. 1989.
- [21] S. Gao, E. Frejinger, and M. Ben-Akiva, “Adaptive route choices in risky traffic networks: A prospect theory approach,” *Transp. Res. C, Emerg. Technol.*, vol. 18, no. 5, pp. 727–740, Oct. 2010.
- [22] M. G. H. Bell, “Hyperstar: A multi-path astar algorithm for risk averse vehicle navigation,” *Transp. Res. B, Methodol.*, vol. 43, p. 97, Dec. 2009.
- [23] N. Hoang, “The dynamic traffic assignment models with real-time information,” Ph.D. dissertation, Swinburne Univ. Technol., Melbourne, VIC, Australia, Feb. 2018.
- [24] L. B. Reinhardt and D. Pisinger, “Multicriteria and multi-constrained non-additive shortest path problems,” *Comput. Oper. Res.*, vol. 38, p. 605, Dec. 2011.
- [25] H. S. Mahmassani and G.-L. Chang, “On boundedly rational user equilibrium in transportation systems,” *Transp. Sci.*, vol. 21, no. 2, pp. 89–99, May 1987.
- [26] M. Luisa De Maio and A. Vitetta, “Route choice on road transport system: A fuzzy approach,” *J. Intell. Fuzzy Syst.*, vol. 28, no. 5, pp. 2015–2027, Jun. 2015.
- [27] D. Merchant and G. Nemhauser, “A model and an algorithm for the dynamic traffic assignment problem,” *Transp. Sci.*, vol. 12, pp. 183–199, Aug. 1978.
- [28] M. Miralinaghi, Y. Lou, Y.-T. Hsu, R. Shabanpour, and Y. Shafahi, “Multiclass fuzzy user equilibrium with endogenous membership functions and risk-taking behaviors,” *J. Adv. Transp.*, vol. 50, no. 8, pp. 1716–1734, Oct. 2016.
- [29] J. D. D. Ortúzar and G. Luis Willumsen, *Modeling Transport*. Hoboken, NJ, USA: Wiley, 2001.
- [30] J. Pan, I. S. Popa, K. Zeitouni, and C. Borcea, “Proactive vehicular traffic rerouting for lower travel time,” *IEEE Trans. Veh. Technol.*, vol. 62, no. 8, pp. 3551–3568, Oct. 2013.
- [31] A. Paricio and M. A. Lopez-Carmona, “Urban traffic routing using weighted multi-map strategies,” *IEEE Access*, vol. 7, pp. 153086–153101, 2019.
- [32] A. Paricio and A. M. Lopez-Carmona, “Multimap routing for road traffic management,” in *Proc. Int. Conf. Practical Appl. Agents Multi-Agent Syst.*, June 2019, pp. 188–199.
- [33] M. Patriksson, *The Traffic Assignment Problem: Models and Methods*. New York, NY, USA: Dover, 2015.
- [34] G. D. O. Ramos and A. L. C. Bazzan, “Efficient local search in traffic assignment,” in *Proc. IEEE Congr. Evol. Comput. (CEC)*, Vancouver, BC, Canada, Jul. 2016, pp. 1493–1500.
- [35] T. Roughgarden, “How unfair is optimal routing?” in *Proc. 13th Annu. ACM-SIAM Symp. Discrete Algorithms (SODA)*, Nov. 2001, pp. 203–204.
- [36] A. Saric, S. Albinovic, S. Dzebo, and M. Pozder, “Volume-delay functions: A review,” in *Proc. Int. Symp. Innov. Interdiscipl. Appl. Adv. Technol.*, Jan. 2019, pp. 3–12.
- [37] A. S. Schulz and N. E. Stier-Moses, “Efficiency and fairness of system-optimal routing with user constraints,” *Networks*, vol. 48, no. 4, pp. 223–234, Dec. 2006.
- [38] Z. Li, M. Shahidehpour, S. Bahramirad, and A. Khodaei, “Optimizing traffic signal settings in smart cities,” *IEEE Trans. Smart Grid*, vol. 8, no. 5, pp. 2382–2393, Sep. 2017.
- [39] Y. Sheffi, *Urban Transportation Networks: Equilibrium Analysis with Mathematical Programming Methods*. Upper Saddle River, NJ, USA: Prentice-Hall, 1984.
- [40] D. Sidhu, R. Nair, and S. Abdallah, “Finding disjoint paths in networks,” in *Proc. Conf. Commun. Archit. Protocols*, 1991, pp. 43–51.
- [41] K. Small, “The scheduling of consumer activities: Work trips,” *Amer. Econ. Rev.*, vol. 72, pp. 467–479, Feb. 1982.
- [42] F. Stefanello, L. Buriol, M. Hirsch, P. Pardalos, T. Querido, M. Resende, and M. Ritt, “On the minimization of traffic congestion in road networks with tolls,” *Ann. Oper. Res.*, vol. 7, pp. 1–21, Feb. 2017.
- [43] D. H. Stolfi and E. Alba, “Red swarm: Reducing travel times in smart cities by using bio-inspired algorithms,” *Appl. Soft Comput.*, vol. 24, pp. 181–195, Nov. 2014.
- [44] W. Szeto and S. Wong, “Dynamic traffic assignment: Model classifications and recent advances in travel choice principles,” *Open Eng.*, vol. 2, no. 1, pp. 1–18, Jan. 2012.
- [45] D. Teodorovic and S. Kikuchi, “Transportation route choice model using fuzzy inference technique,” in *Proc. 1st Int. Symp. Uncertainty Modeling Anal.*, 1991, pp. 140–145.
- [46] *Technical Note 10—What is the Capacity of the Road Network for Private Motorised Traffic and How Has This Changed Over Time*, Transport for London, London, U.K., 2015.
- [47] H. R. Varia, P. J. Gundaliya, and S. L. Dhingra, “Application of genetic algorithms for joint optimization of signal setting parameters and dynamic traffic assignment for the real network data,” *Res. Transp. Econ.*, vol. 38, no. 1, pp. 35–44, Feb. 2013.
- [48] J. G. Wardrop and J. I. Whitehead, “Correspondence some theoretical aspects of road traffic research,” *Proc. Inst. Civil Engineers*, vol. 1, no. 5, pp. 767–768, Oct. 1952.
- [49] W. Wei, L. Hu, Q. Wu, and T. Ding, “Efficient computation of user optimal traffic assignment via second-order cone and linear programming techniques,” *IEEE Access*, vol. 7, pp. 137010–137019, 2019.
- [50] H. Xu, Y. Lou, Y. Yin, and J. Zhou, “A prospect-based user equilibrium model with endogenous reference points and its application in congestion pricing,” *Transp. Res. B, Methodol.*, vol. 45, no. 2, pp. 311–328, Feb. 2011.
- [51] J. Yen, “Finding the k shortest loopless paths in a network,” *Manage. Sci., JSTOR*, vol. 17, pp. 712–716, Jan. 1970.
- [52] Z. W. Ji, Y. S. Kim, and A. Chen, “Multi-objective alpha-reliable path finding in stochastic networks with correlated link costs: A simulation-based multi-objective genetic algorithm approach (SMOGA),” *Expert Syst. Appl., Elsevier*, vol. 38, p. 1515, Dec. 2011.



ALVARO PARICIO received the double M.S. degree in computer science and communications from the Universidad Politecnica de Madrid, Madrid, Spain, in 1992. He is currently pursuing the Ph.D. degree in information and communications technologies with the Universidad de Alcalá (UAH), Madrid. He is also a Lecturer of computer science with UAH and digital transformation with the Escuela de Organización Industrial, depending of the Spanish Ministry of Industry. His main

research interests include optimization algorithms, traffic routing optimization, safety and evacuation strategies, the IoT architectures, and massive data analytics. He has developed a wide professional career in private held companies. He joined Telefonica Research and Development, as an AI expert in 1994. He co-founded the company IAPsolutions, Spain, USA, a technology startup for AI agents, IoT and Edge-Computing leading the company, as a CTO in 1999. He joined SecuritasDirect, a global leader for home-security, as a Development Director for EMEA and LATAM in 2014. Since 2017, he has been leading Digital Transformation Offices with the telecom Group MasMovil (the fastest growing telecom operator in Europe).



MIGUEL A. LOPEZ-CARMONA received the B.S. degree in electronics engineering from the University of Alcalá, in 1994, the M.S. degree in telecommunication engineering from the Polytechnic University of Madrid, in 1999, and the Ph.D. degree in telecommunication engineering from the University of Alcalá, in 2006. From 1995 to 2000, he held positions in Logytel and Alcatel as a Project Manager and a Research Scientist in the areas of railways and defense. Since

2000, he has been an Associate Professor with the Department of Computer Engineering, University of Alcalá. From 2010 to 2017, he was the Vice-Dean of the Polytechnic School, University of Alcalá. He has been a Visiting Researcher with the Center for Collective Intelligence, Massachusetts Institute of Technology (MIT), where he did research in complex automated negotiations and optimization of complex networks. His research interests include intelligent transport systems, safety and evacuation strategies, automated negotiation, multi-agent systems, and optimization of complex networks.

...

5

Modeling Driving Experience with Smart Traffic Routing Strategies: Application to Traffic Multi-Map Routing

En este capítulo se muestra el artículo publicado “Modeling Driving Experience with Smart Traffic Routing Strategies: Application to Traffic Multi-Map Routing”. Tras una breve resumen de este, se muestran los datos sobre la publicación y su relevancia. Por último, se ha incluido una copia de la versión publicada del artículo.

5.1. Introducción

A la hora de abordar la efectividad de la implantación de nuevos sistemas inteligentes de enrutamiento y recomendación de rutas (ITS, *Intelligent Transportation Systems*), nos encontramos con diversas problemáticas que deben abordarse teniendo en cuenta el comportamiento de los usuarios: la primera, los usuarios se enfrentan a múltiples sistemas y aplicaciones ITS sobre las que pueden escoger sus mejores rutas, sin embargo esto provoca que los modelos sobre los que los ITS hacen sus previsiones no son autocontenidos sino que dependen del nivel de adopción en cada uno. El estado global del tráfico viene determinado por las recomendaciones que entregan los diferentes ITS.

La segunda problemática es la subjetividad en la toma de decisión por parte de los conductores que toman diferentes criterios en función de los datos de estado disponibles, sus experiencias previas, el grado de penetración de las herramientas ITS, la influencia de las redes sociales, y otros factores. En

definitiva, un modelo complejo y subjetivo, que además va cambiando en el tiempo.

Una tercera problemática viene dada por la resistencia al cambio de los conductores, donde a pesar de las recomendaciones entregadas por el ITS seleccionado, los conductores ignoran sus recomendaciones en base a criterios subjetivos.

Por último, ya se detectó en los estudios previos de la tesis, el hecho de que algunos conductores se ven penalizados por el hecho de buscar un óptimo del sistema, lo que se ha dado en llamar el efecto de enrutamiento injusto (RU, *Route Unfairness*). [11, 108]. Si un conductor detecta que se ve penalizado por el hecho de usar un ITS, obviamente su tendencia será la de cambiar su elección.

El artículo propone un modelo de evaluación del comportamiento de los conductores frente a la decisión del enrutamiento de sus trayectos, basado en sus creencias, obligaciones, intenciones, deseos e influencia social (BOID+S, *Beliefs, Obligations, Intentions, Desires and Social Influence*) así como en la incertidumbre de los mismos y su resistencia al cambio.

Este modelo ha sido desarrollado al considerar cómo de receptivos sería las conductores a la introducción de un ITS basado en TWM, cómo evolucionaría dicho modelo en términos de adherencia al mismo por parte de los conductores, y qué resultados de mejora global e individual son esperables.

El modelo propuesto emplea tres niveles de abstracción para la toma subjetiva de las decisiones del conductor. En primer lugar, el comportamiento del usuario es evaluado mediante un modelo de utilidad implementado con un conjunto de variables y reglas borrosas (incertidumbre) [104, 43, 103]. Este primer nivel nos entrega las utilidades de usar cada uno de los ITS disponibles, incluyendo el no-ITS como una opción más.

Esta utilidades son posteriormente empleadas en un modelo de elección discreta mediante logit multinomial para obtener la probabilidad de uso de cada uno de los ITS [18, 8]. Con esta función de probabilidad, finalmente se realizará un experimento estocástico con el que se seleccionará el ITS tentativo a usar.

El último de los niveles modela la resistencia al cambio de los conductores, de manera que, en caso de haber decidido el conductor un cambio de ITS, se evaluará su resistencia al cambio mediante una función de probabilidad [126, 7].

Los resultados experimentales del modelo son aplicados tanto en redes sintéticas a fin de evaluar los mecanismos básicos, y posteriormente en una red de tráfico urbano real, concretamente en el distrito de Madrid-Las Tablas.

Los experimentos muestran cómo es la convergencia en función de los diferentes niveles de confianza y resistencia al cambio llevando al sistema de forma inequívoca hacia su óptimo.

El interés del modelo radica en su generalidad ya que es sumamente práctico y declarativo, y su capacidad de aplicación a entornos de muy distinta complejidad, dando pie a numerosas aplicaciones futuras.

5.2. Relevancia de la publicación

Título	Modeling Driving Experience with Smart Traffic Routing Strategies: Application to Traffic Multi-Map Routing		
Autores	Paricio, A. y Lopez-Carmona M.A.		
Estado	Publicado	Fecha	JUnio/2021
DOI	publicación: https://doi.org/10.1109/ACCESS.2021.3091322		
Revista	Nombre	IEEE Access	
	Editorial	IEEE - Institute of Electrical Electronics Engineers Inc.	
	País	EE.UU.	
Relevancia	Revista (*)	Índice de Impacto:	3,367 (2020) : 4,076 (5 años)
		JCR (2020):	Q2 (94/273)
	Artículo	Lecturas:	56
		Citas:	0

(*)IEEE Access tiene un factor de impacto de 3,367 en 2020 y de 4.076 a 5 años, un Eigenfactor de 0.15396, y una puntuación de influencia de artículos de 0.592 (Índice JCR-2020). Fuente: IEEE Access <https://ieeaccess.ieee.org/about-ieee-access/frequently-asked-questions/>. Calificación FECYT para IEEE Access disponible en <https://apps.webofknowledge.com/>.

5.3. Artículo

Received May 13, 2021, accepted June 17, 2021, date of publication June 21, 2021, date of current version June 30, 2021.

Digital Object Identifier 10.1109/ACCESS.2021.3091322

Modeling Driving Experience in Smart Traffic Routing Scenarios: Application to Traffic Multi-Map Routing

ALVARO PARICIO^{ID} AND MIGUEL A. LOPEZ-CARMONA^{ID}

Departamento de Automatica, Universidad de Alcala, Escuela Politecnica Superior, Campus Externo de la UAH, 28807 Alcala de Henares, Spain

Corresponding author: Alvaro Paricio (alvaro.paricio@uah.es)

ABSTRACT The effectiveness of user-oriented traffic routing applications to mitigate traffic congestion in Intelligent Transportation Systems depends on their degree of adoption, which usually evolves depending on subjective and exogenous factors. This paper proposes a user experience and social dynamics model to analyze and evaluate traffic routing methods, based on fuzzy rules and discrete choice theory. The model has been applied to the optimal Traffic-Weighted Multi-Maps (TWM) routing method to evaluate the adoption dynamics and analyze convergence towards the system optimum. Route unfairness and resistance to change are also considered in the model. Experimental results are obtained simulating the evolution of the drivers' population behavior. Simulation is carried over synthetic and real networks, using optimized TWM maps. The experimental results show how the TWM system evolves to a stationary System Optimum, improving overall traffic congestion and showing how User Equilibrium variability is bounded as it depends on user routing choices influenced by behavioral patterns.

INDEX TERMS Dynamic traffic assignment, multi-map routing, fuzzy logic, evolutionary algorithms, discrete choice modeling, traffic simulation, vehicle routing, traffic weighted multi-maps.

I. INTRODUCTION

The efficiency and impact of routing software applications (routing apps) in Intelligent Transportation Systems (ITS) to mitigate traffic congestion depend not only on the quality of the routing solutions proposed to the drivers but also on their adoption rate [1]–[3]. This adoption rate depends on individual factors, public policies and regulation, and social influence [4], [5].

There is a considerable amount of route choice, and traffic information management proposals focused on congestion mitigation and travel-time improvement using static or dynamic methods [6]. From a macroscopic perspective, they try to reach the right balance on Wardrop's principles of User Equilibrium (UE) and System Optimal (SO) [7], [8]. These proposals consider that most users are free to decide the route they would take for their trips, using a subjective evaluation of objective data and status information such as travel time forecast, network traffic status, previous routing choices, social information, and other individual parameters. Multi-criteria

and imprecise traveler behavior is usually approached with Utility theory (UT), Prospect Theory (PT), and Regret Theory (RT), together with Discrete Choice Methods (DCM) and Fuzzy Methods (FM) [9], [10].

In an environment with multiple routing apps available which are not usually interoperable and interfere between them [11], [12], drivers first need to decide which app to use [13]. User experience, perception and trust, and social influence are key concerns [14], [15].

Discrete choice methods with multinomial logit models (MLM) have been widely applied to route choice problems [1], [16] as they consider mutually exclusive alternatives. Individual trip routing decisions are taken after considering and comparing the utilities of every routing strategy. The utility evaluation is a subjective process that considers the available (fuzzy) knowledge of the considered parameters. It can be processed and weighted employing fuzzy (behavioral) rules.

The effectiveness of traffic routing applications depends on their user adoption rate (adherence). This ITS adherence must be considered as a time-dependent process [12], [17]. Successive trip planning iterations have different ITS

The associate editor coordinating the review of this manuscript and approving it for publication was Shaohua Wan.

adherences as user experiences evolve. ITS adherence has a double impact on total travel time (TTS) and congestion: even with low adoption levels, the whole network gets improved as the most used routes receive less traffic assignment, and thus non-adopters are also positively impacted. Nevertheless, SO-oriented ITS have a well-known issue that needs to be addressed: a fraction of the drivers may be penalized on behalf of the majority improvement. This effect is called route unfairness (RU), which has been studied by [18]–[20].

Fuzzy modeling of the route choice problem has been described in [21] and [22], and later works have developed and enriched this approach as in [23] that proposed a multi-criteria framework for route generation, evaluation, and selection. These models propose calibrated fuzzy sets for traffic variables and fuzzy rules to make routing decisions. They require that the drivers have imprecise knowledge of the status of the network to make their decisions, and from a global perspective, UE and SO cannot be guaranteed.

User utility functions defined as fuzzy methods have been used to model decision-making processes as shown in [24] and [25]. These approaches have also been applied to the transportation problem in [26] where a multi-criteria route choice model for driver utility is proposed. Risk-averse decisions are also taken into account in the route choice fuzzy models as described in [27]–[29]. Risk-aversion and user's perceived utility are in the basis of Prospect Theory which has also been applied to route choice under uncertain information [30], [31].

Other fuzzy-based proposals have also been applied as a heuristic approach to the Traffic Assignment Problem (TAP) [32], proving a macroscopic routing perspective. This fuzzy macroscopic approach has been exposed by [33] considering fuzzy costs for the traffic network links and applying the model to the TAP. Fuzzy cost sets can be biased to avoid the Independence from Irrelevant Alternatives (IIA) from the Logit based models. In the same way, user inertia in decision making is a well-known effect that needs to be considered as resistance to change [34]. Hassan *et al.* [35] have recently proposed a two-level approach for modeling transit-path travel strategies and route choice in transit paths, where fuzzy sets are used to calibrate a discrete choice model.

Our work proposes a method to estimate and simulate ITS adoption by modeling driver's behavior under multi-criteria and uncertainty. It is used to study how SO-oriented ITS approaches behave over time in terms of global adoption considering individual fuzzy decision criteria. Will the drivers use the system considering their fuzzy utility criteria? Will the ITS adherence converge to stable values that fulfill the global SO objectives? It uses a two-level approach similar to [35] that combines fuzzy rules and discrete choice methods to model ITS adoption dynamics considering their utilities. Multiple concurrent ITS usage may converge to a system optimum, evolving towards a stationary global adoption status.

The main contributions of this paper include:

- 1) A driver experience evaluation model that describes the utility of using different routing strategies, based

on a fuzzy parameter model and rule-set behavior evaluation.

- 2) An individual trip routing decision model based on the subjective utility set using a multinomial logit model and considering the inherent resistance to change.
- 3) A study of the traffic system evolution in time, considering the adherence to a concrete smart routing application (Traffic Multi-Map Routing, TWM), and the convergence and stability of the system optimum for global travel time.
- 4) Simulation study on temporal system dynamics, validating how SO-oriented principles can be evaluated in ITS and smart apps for congestion mitigation.

The routing strategy developed with the Traffic Weighted Multi-Maps (TWM) routing system has been previously introduced in [36] and [37], and it essentially relies on the design, distribution, and adoption of complementary network views that decouple the physical road network layout from the logical perspective of the network usage. These views are created by applying different weights to the links between connected roads or street junctions. It induces the routing applications to select different minimum-cost routes depending on the received map. It can be thought as if traffic were colored depending on the received map. The application of TWM to complex traffic scenarios may lead to significant improvements in terms of global travel time, congestion mitigation, emissions reduction, incident avoidance, per fleet routing, time-based routing, and others. One of the main benefits of TWM is the ability to be easily integrated with existing traffic control frameworks as a traffic map server.

In [38] it is discussed how to create optimal TWM distributions depending on the network topology, the planned traffic demand, and various optimization criteria. These optimal TWM distributions can be generated by heuristic optimization algorithms where multiple criteria can be applied to reduce complexity, and leading to pseudo optimal solutions. This optimal TWM provides static traffic assignment scenarios very close to the system optimum (SO) in terms of total travel time (TTS), though other optimality criteria may also be added in TWM calculus. Other similar works have appeared later, presenting a similar idea with randomized maps applied to different traffic networks [39].

In our work, we consider a dynamic traffic assignment with daily stable traffic demands (flows). The utility model assumes that every driver takes individual routing decisions (planning) before starting a trip by considering the following aspects:

- 1) Social awareness of TWM: knowledge of the existence of the TWM app.
- 2) Qualified user of TWM: considering if the driver has ever used the system (registered user).
- 3) Comparison against the optimal travel time that would be achieved when a free-flow scenario is considered.
- 4) Current network status information and travel time forecast for the next trip.

- 5) Previous driving experiences using TWM: positive or negative compared to the congested or non-congested situation.
- 6) TTS improvement or worsening in the latest driving experience, considering TWM usage or not.

These aspects are modeled as fuzzy rules generating probability distributions that estimate the utility of using TWM. This utility model feeds the final decision-making process that makes the routing decision. This process is implemented with a Multinomial Logit Model (MLM) taken from discrete choice theory. Specifically, in this work, the selection process is focused on choosing between the route generated by the shortest-path algorithm and the route provided by TWM. MLM has been widely used to model human behavior in route selection models [1] and other areas such as economics or evacuation scenarios [40]–[42]. The main advantages of the proposed model are its generality, versatility, open and flexible character, its ability to be adapted to empirical values obtained from direct feedback from users, and that it can be easily simulated.

Simulation experiments are conducted in synthetic and real urban traffic networks under congestion conditions. Synthetic traffic networks allow a fast model development isolating the utility model assumptions and policies from the real network constraints. The real urban traffic network is then used for empirical validation and traffic prediction. The experiments allow us to measure:

- How the TWM adherence evolves, and how long it takes its convergence.
- Which are the most valuable fuzzy rules and their relevance in time.
- How social awareness affects ITS adoption.

The rest of the paper is organized as follows. Section II describes the user utility model, the multiple ITS evaluation rules for route choice, and their application to the optimal traffic multi-maps (TWM) routing mechanism. Section III describes the experimental use cases and results, and finally, Section IV points out conclusions and future research lines.

II. MODELING THE UTILITY OF ROUTING APPS

Given a certain number of traffic routing policies or applications $\{\mathbb{R}_n\}$ available, drivers need to choose between them at the planning time of the trip to decide which route to take. This choice can be expressed as a combination of beliefs (including the available information), obligations, intentions, and desires, in the so-called BOID model, described in the classical intelligent agent approaches [43], which can be extended to a BOID+S model if it is expected that social media may have a relevant impact on user adherence. In our approach, each driver takes a strategical routing decision combining a fuzzy logic model with a discrete choice method. The sequence of steps involved are:

- 1) Collect the necessary observations for the accounted variables.
- 2) Fuzzy evaluation of these variables using fuzzy membership functions.

- 3) Application a fuzzy behavior rule-set to obtain the utility values for the considered routing strategies $\{\mathbb{R}_n\}$, showing how useful would be any of the available choices when the driver's decision is taken. A global rule-set wrapping function is used to aggregate the utility value obtained from all the rules together with their relevance (weight).
- 4) A discrete choice model is then applied to obtain the usage probability of the routing strategies $\{\mathbb{R}_n\}$. A previous linear scaling is required to adapt utilities to the probability ranges.
- 5) A stochastic decision is then taken, where the driver selects which routing strategies $\{\mathbb{R}_n\}$ to use.
- 6) Differentiation between decision making and execution is then applied, as users experience resistance to change. It is modeled using a stochastic process.
- 7) Select the appropriate routing method R_i for the next trip.

This section covers the utility model and its application to the TWM routing strategy.

A. FUZZY UTILITY MODEL

A routing strategy, method, or application $\{\mathbb{R}_n\}$ is supposed to provide a particular utility value $[U_n^k] = [U_1^k, U_2^k \dots U_n^k]$ to the driver k at a specific time ($[U_n]$ from now on), which considers the experience gained by the driver in previous trips. Discarding those vehicles that have fixed routes such as regular urban buses, it is reasonable to consider that drivers use at least one routing policy when planning a trip. Thus, we define the standard trivial routing method \mathbb{R}_0 that considers the minimum cost route under free-flow conditions, ignoring or not knowing the traffic status. Its utility is represented by \bar{U} (no ITS usage).

Utility values $[U_n]$ are independently evaluated considering BOID+S components represented by the variables $[X_i]$. They can be implemented as fuzzy variables, which can be multi-valued with the value sets $[c_{ij}]$, which numerically represent the membership to the fuzzy categories $[C_{ij}]$ specific to each variable. The values $[c_{ij}]$ are obtained through fuzzy-set evaluation functions $[m_{ij}]$ (1):

$$X_i \rightarrow x_i \approx [c_{ij}], \quad c_{ij} \rightarrow m_{ij}(x_i) \quad (1)$$

For instance, let us consider the driving factor $X_{FF-ITTS} \approx$ "Individual Last-Trip to Free-Flow Travel time Similarity" (X_1), which measures the ratio between the individual free-flow travel time (best possible travel time using the minimum cost route) and the previous travel time experience. It may be evaluated by the fuzzy categories $[C_{11}, C_{12}, C_{13}] \approx \{ \text{"optimum"}, \text{"acceptable"}, \text{"bad"} \}$ depending on the ratio value obtained for a given vehicle at a specific time. Every fuzzy category has its membership function $[m_{11}, m_{12}, m_{13}]$, so from the fuzzy perspective, any X_1 value x_1 is evaluated by the evaluating tuple $[m_{11}(x_1), m_{12}(x_1), m_{13}(x_1)]$, for example: $x_1 = 0.8915 \approx [0.99, 0.23, 0.01]$.

TABLE 1. TWM adoption rule R_3 .

Rule	Trigger condition		Evaluation		Weight
R_3	WHEN	The free-flow individual travel time similarity IS <i>bad</i> (very long travel time compared to free-flow) AND The driver IS an <i>unregistered TWM user</i> AND TWM popularity IS <i>high</i>	THEN	Utility of TWM routing IS <i>high</i> AND Utility of standard routing (non-TWM) IS <i>low</i>	WEIGHT=0.5

In the same way, the utility variable set $[U_n]$ is also described by fuzzy variables which also are multi-valued value sets $[u_{nj}]$ that represent the membership to the fuzzy categories $[UC_{ij}]$ using fuzzy-set evaluation functions $[um_{ij}]$ (2):

$$U_n \rightarrow u_n \approx [u_{nj}], u_{nj} \rightarrow um_{nj}(U_n) \quad (2)$$

Following the previous example, the utility of using TWM, U_{TWM} , may be modeled as {"high","mid", "low", "very low"} and also \bar{U} may be modeled as {"great","normal", "small"} (they do not need to map to the same categories).

Driver behavior is modeled by evaluation rules $\{R_r\}$ that estimate the utility values $[U_n]$ considering the driver and context variables $[x_i]$ and their fuzzy categories $[C_{ij}]$. Rule evaluation is done by the rule processing method \mathcal{F} (3). The BOID+S model is implemented by multiple rules, each one returning its own evaluation set $[u_i]_r$, so it is necessary to provide unique evaluation values to a rule-set wrapping method \mathcal{Q} (4), considering the returned utilities and the corresponding rule weights w_i :

$$R_r : [u_n]_r \rightarrow \mathcal{F}([x_i]) \quad (3)$$

$$[u_i] \rightarrow \mathcal{Q}([u_n]_r, w_r), \quad \forall R_r \quad (4)$$

For instance, using our behavior fuzzy rules we can easily define the rule described in Table 1.

Fuzzy engines offer multiple evaluation strategies that could be used depending on the problem to be solved. We use an additive resolution model, considering that utility is usually an additive process. The fuzzy utility model returns normalized values in the [0,1] range that needs to be linearly scaled before the probability calculus for traffic routing method \mathbb{R}_i , generating $[u_i^*]$.

B. DISCRETE CHOICE MODEL

Once the utility values have been obtained, a discrete choice model based on random utility theory is applied [1], [44], [45] under the following assumptions:

- 1) Individuals belong to a homogeneous population in terms of objectives (mainly reduce travel time), use perfect information about the traffic status and previous experiences, and make rational decisions (based on behavior rules).
- 2) There is a predefined set of routing $\{\mathbb{R}_n\}$ ITS alternatives expressed by value attributes $[c_{ij}]_k$ for every

individual. Individuals need to make choices considering these valued attributes.

- 3) Utility perceived by each driver k over each routing alternative is expressed by the expression (5,6) that combines the systematic evaluation of the attributes and an ε_n^k observational error.

$$u_n^k = v_n^k + \varepsilon_n^k \quad (5)$$

$$v_n^k = \sum \beta_{ij} * x_{ij}^k \quad (6)$$

- 4) The travelers select the maximum utility alternative when $v_n^k - v_m^k \geq \varepsilon_m^k - \varepsilon_n^k$ and then the probability $P(u_n^k)$ of choosing the alternative n is described by (7):

$$P(u_n^k) = Prob \left\{ \varepsilon_n^k \leq \varepsilon_m^k + (v_n^k - v_m^k), \forall U_m \right\} \quad (7)$$

When the observational errors ε_n^k are independent and identically distributed (IID), the Weibull/Gumbel distribution can be used (Extreme Vale Type I), and the Multinomial Logit Model (MLM) can be applied [46]. It provides a simplified expression to calculate the probabilities $P(u_i^k)$ that a driver will use a traffic routing method \mathbb{R}_i at a time (8):

$$P(u_i^k) = \frac{\exp(u_i^k)}{\sum_k \exp(u_k^k)} \quad (8)$$

Calibration of logic models with fuzzy reasoning mechanisms applied to transportation scenarios is discussed in [47] and [48]. More recently, [35] describes a dual fuzzy-logit model calibrated with user data.

In this paper, we use MLM to model the routing method choice of a driver at time t , which is then achieved using the probability distribution $[P(u_n^k)]$ for a stochastic experiment that returns the usage of a specific routing method or app \mathbb{R}_k^t . Resistance to change is modeled independently of the routing method choice model. This final decision-making process decides whether to apply \mathbb{R}_k^t or stay using the previous routing method \mathbb{R}_k^{t-1} .

C. USER EXPERIENCE PARAMETERS

The BOID+S model is a fuzzy model described by the fuzzy input variables $[X_i]$, the fuzzy output utilities $[U_n]$, the fuzzy reasoning rules $\{R_r\}$ together with their weights, the rule evaluation policies $[\mathcal{F}, \mathcal{Q}]$ and the user resistance to change Y .

The fuzzy input variables $[X_i]$ considered are:

- *Individual Last-Trip to Free-Flow Travel Time Similarity* (X_{FF-TTS}^t): represents how close has been the previous travel time to the ideal free-flow minimum value. It is measured by the ratio (9) between the individual free-flow travel time (best possible travel time using the minimum cost route) and the previous travel time experience (TT_k^t). It is described by the categories (10).

$$X_{FF-TTS}^t = \frac{TT_k^{FF}}{TT_k^t} \quad (9)$$

$$C_{FF-TTS} \in \{“Optimum”, “Acceptable”, “Bad”\} \quad (10)$$

- *Individual Last-Trip Travel Time Experience* (X_{LT-TT}^t): represents the most influencing short-term experience, comparing the two latest experiences and checks if the latest decision was worthy. It compares the latest trip TT_k^t improvement over the previous one TT_k^{t-1} . Improvement (11) is effective when its value is over a certain subjective threshold δ . X_{LT-TT} categories are described in (12).

$$X_{LT-TT} = \left(TT_k^t < TT_k^{t-1} * (1 - \delta) \right) \quad (11)$$

$$C_{LT-TT} \in \{“Yes”, “No”\} \quad (12)$$

- *Individual Awareness of ITS R_k* (X_{RU-K}^t): reflects if a user actively knows about the routing method R_k . This knowledge can be measured by the vehicle’s registration status in the routing application or by the individual memory flag recording if it has been ever used. It is described by the categories described in (13).

$$C_{RU-K} \in \{“NoUser”, “PotencialUser”, “ActiveUser”\} \quad (13)$$

- *Individual Mean Travel Time Experience using ITS R_k* (X_{MTT-K}^t): reflecting the mid-term individual perception about R_k usage. It is measured as the ratio of trips that improved their travel time using R_k in the latest m executions (14). It is described by the categories (15).

$$X_{MTT-K}^t = \frac{\sum_i X_{LT-TT}^i}{m}, i \in [t - m, t] \quad (14)$$

$$C_{MTT-K} \in \{“Improved”, “Neutral”, “Worsened”\} \quad (15)$$

- *Last-Trip Has Used ITS R_k* (X_{LTU-K}^t): expresses if an ITS routing mechanism has been used in the previous trip. Previous trip experience is critical, and the routing method that has been used needs to be evaluated to make the next decision. It is measured as a yes/no option for the R_k routing methods (16).

$$C_{RU-K} \in \{“Yes”, “No”\} \quad (16)$$

- *ITS R_k Social Influence* (X_{SOC}^t): reflecting the influence of the driver’s community over the individual decision.




FIGURE 1. Strict distribution of driver resistance to change, $Y_{bin} \rightarrow 0.75 * binary(0.6)$.




FIGURE 2. Normal distribution of driver resistance to change, $Y_{norm} \rightarrow 0.75 * norm(0.6, 0.1)$.

This parameter aggregates all the social influencing factors. It can be initially approached as the adoption ratio of the routing method in the global population (17): percentage of drivers using R_k , where N is the number of drivers. It is described by the categories (18).

$$X_{SOC}^t = \frac{\sum X_{LTU-K}^t}{N} \quad (17)$$

$$C_{SOC} \in \{“Low”, “Mid”, “High”\} \quad (18)$$

The fuzzy output variables are the utility values $[U_n]$ obtained from the fuzzy rules evaluation. They are evaluated by the fuzzy engine (4), and are described by the categories $[C_U]$ (19):

$$C_U \in \{“Low”, “Mid”, “High”\} \quad (19)$$

Besides the fuzzy variables, the *Individual Resistance to Change* (X_{RC}) is also considered. It reflects the personal attitude to maintain the previous routing method decision taken. Resistance to change is modeled over the vehicle population, assigning a certain probability for X_{RC} to every vehicle with a p_{max} maximum probability. Several probability distributions may be used. Our work is focused on:

- The strictly receptive model where the driver simply accepts or rejects the routing decision to be taken with probability $Y_{bin} : p_{max}, m \rightarrow p_{max} * binary(m)$ where $binary(m)$ is a $[0, 1]$ experiment for the m percentage of vehicles. Figure 2 illustrates the probability values distribution for X_{RC} where only 60% of the vehicles may

TABLE 2. Weight categories for the fuzzy rules.

Category	Very High	High	Normal	Low
Weight	1	0.75	0.50	0.25

have a X_{RC} probability of 0.75. Values are randomly assigned to the vehicles.

- The normal resistance mode, where ability to adopt changes is modeled with a normal distribution $Y_{norm} : p_{max}, m, d \rightarrow p_{max} * norm(m, d)$, where $norm(m, d)$ is the normal random distribution with mean m and standard deviation d . Figure 2 shows the X_{RC} histogram for the whole population with $p_{max} = 0.75$, $norm(0.6, 0.1)$.

If the resulting decision at the trip planning stage is a change of routing criteria, then a probabilistic experiment is executed with the individual X_{RC} probability to decide whether to change or not. The flexibility of our BOID+S model allows easy definition of new parameters. We are mainly focused on travel-time related factors, but other parameters may be added directly, such as:

- Trip length, comparing \mathbb{R}_k use or not, both in short-term and mid-term experiences.
- Congested areas traversal, in percentage ratio of total trip length.
- Freeways usage.

D. USER EXPERIENCE RULES

For the sake of conciseness and understanding, we will limit ourselves to describing the rules that affect the existence of a single routing method \mathbb{R}_{TWM} . All the fuzzy rules are evaluated at every driver decision-making iteration, whose relative impact is weighted as shown in Table 2. The rules are shown in Table 3, which are grouped by their similar behavior into the following rule-sets:

- 1) TWM non-users behavior (rules 1-5): when the driver is not a TWM user, depending how valuable is the last-trip experience compared to the free-flow driving conditions, and the social acceptance of TWM, the utility of using TWM (U_{TWM}) or not using it (\bar{U}) will vary. The TWM utility condition the new-adopters policy.
- 2) TWM users behavior considering short-term experience (rules 6-15): when the driver is a TWM user (registered user or has ever used it), last-trip experience conditions if it was worthy TWM usage or not, considering if the travel time has improved or not. Social acceptance of TWM is less important here. This rule-set controls if the driver keeps using TWM or rejects using depending the traffic experiences when adoption is increasing and congestion conditions evolve.
- 3) TWM users behavior considering mid and long term experience (rules 16-19): when the driver is a TWM user, mid and long term experience using TWM is valuable to represent driver's confidence to the routing method. Regardless of what has happened on the

driver's last trip, he learns from other previous experiences. These rules limit as well oscillations in the decision process.

The traffic routing adoption model is very open and new rules can be easily added referring to the existing fuzzy variables or to new add-ons.

E. OPTIMAL TWM ROUTING OVERVIEW

Traffic Weighted Multi-Maps (TWM) is a routing technique based on the usage and distribution of complementary views (maps) of the traffic network to create alternative paths for the planned trips. It was introduced in [36] and [37], where its application was applied to global travel times, individual mean travel time, and congestion reduction.

TWM decouples the physical topology of the traffic network from the logical usage view of the network (map), assuming that it is based on traffic logical rules, constraints, and recommendations. TWM is based on the generation of a set of static link weights that the drivers use to calculate route costs. TWM provides differentiated views (maps) to the vehicles with specific link weights, inducing them to select scattered routes. TWM maps are selectively distributed to the traffic groups through standard traffic services. It assures backward compatibility with other traffic routing services, as their core is always based on a network map. TWM is compatible with centralized and distributed traffic routing mechanisms.

Use cases studied so far with TWM are congestion mitigation, per fleet differential routing, real-time incident management [36], and more recently, optimal traffic assignment [38]. This latest work demonstrates that it is possible to apply optimization algorithms to generate TWM map-sets that provide quasi-optimum traffic assignment when the traffic demand is estimated in advance and a certain usage ratio (adherence) is considered.

Explored TWM optimization mechanisms are based on evolutionary algorithms, where link weights in the traffic maps are distributed to achieve minimum global travel time (TTS) for a given demand. TWM optimization uses static traffic assignment models, using volume-delay functions (VDF) [49]. VDF provides a macroscopic approximation of the travel time and traffic flows.

The most commonly used VDF function is (20) defined by the Bureau of Public Research [50] that describes link travel times as a function of the free-flow travel time tt_0 , link capacity q_{max} and link usage q .

$$tt_i = (tt_0 + \alpha * (\frac{q}{q_{max}})^\beta) \quad (20)$$

Considering the k-shortest paths (KSP) for the traffic flows, it can be defined traffic routing areas containing the KSP nodes and all the link-connected nodes at a distance d from them. This algorithm is called Extended Flow-Path Optimal TWM (EFP-TWM) [38]. Optimal TWM designed for these routing areas has lower complexity since they use a much smaller volume of links to optimize, focusing on the

TABLE 3. TWM adoption rules.

Group	Id	Description	Weight	X_{FF-TTS}	X_{MTT-K}	X_{RU-K}	X_{LTU-K}	X_{SOC}	X_{LT-TT}	U_{TWM}	\bar{U}
Never used TWM	1	TWM non-users. Good routing experience. No need to change.	Very high	Optimum		NoUser	No			very low	high
	2	TWM non-users. Could improve routing performance. May change.	Normal	Acceptable		NoUser	No			low	mid
	3	TWM non-users. Bad routing performance. TWM unknown. Hardly change.	Normal	Bad		NoUser	No	low		very low	mid
	4	TWM non-users. Bad routing performance. TWM mid-popular. Could change.	Normal	Bad		NoUser	No	mid		low	mid
	5	TWM non-users. Bad routing performance. TWM very popular. Try to change.	Normal	Bad		NoUser	No	high		high	mid
TWM users	6	TWM user. Recently improved relative experience with TWM. Keep using.	High			ActiveUser	Yes		improved	high	low
	7	TWM user. Recently worsened relative experience using TWM. Reject using.	Normal			ActiveUser	Yes		worsened	very low	high
	8	TWM user. Didn't use recently TWM, and had good experience. Reject using.	Normal			ActiveUser	No		improved	very low	high
	9	TWM user. Didn't use recently TWM, and had poor experience. Return to TWM.	Normal			ActiveUser	No		worsened	high	low
	10	TWM user. Recently good absolute results with TWM. Keep using.	Normal	Optimum		ActiveUser	Yes			high	low
	11	TWM user. Recently good absolute results without TWM. Reject using.	Very High	Optimum		ActiveUser	No			low	mid
	12	TWM user. Recently mid absolute results with TWM. Indifferent.	Normal	Acceptable		ActiveUser	Yes			low	low
	13	TWM user. Recently mid absolute results without TWM. Detractor.	Normal	Acceptable		ActiveUser	No			low	mid
	14	TWM user. Recently poor absolute results with TWM. Strong detractor.	Normal	Bad		ActiveUser	Yes			low	high
	15	TWM user. Recently poor absolute results without TWM. Promoter.	Very High	Bad		ActiveUser	No			high	low
TWM Mean Usage	16	TWM user. Latest TWM experiences are good. Promoter	High		Improved	ActiveUser	Yes			high	low
	17	TWM user. Latest TWM experiences are good, even if last day didn't use it. Promoter.	High		Improved	ActiveUser	No			high	low
	18	TWM user. Latest TWM experiences are bad. Detractor	High		worsened	ActiveUser	Yes			very low	high
	19	TWM user. Latest TWM experiences are bad, even if last day didn't use it. Detractor.	High		worsened	ActiveUser	No			very low	high

most relevant links. EFP-TWM distributions provide traffic assignment distributions very close to the system optimum at a reasonable computing cost.

F. USING THE FUZZY UTILITY MODEL WITH TWM ROUTING

The effectiveness of the optimal TWM distributions depends mainly on the driver's adherence to TWM usage. Nevertheless, adherence evolves depending on several factors, especially when previous experiences are taken into account, including social TWM awareness. For system optimum traffic assignment, some of the vehicles will inevitably be harmed for the benefit of the majority. This is called the route unfairness effect [18]–[20]. So, TWM usage will have promoter and detractor driver profiles, considering these drivers that improved or worsened their planned trips. Despite having received a TWM routing recommendation, some drivers may decide not to change their routing strategies due to behavioral inertia or a biased utility perception [13], [34].

TWM adherence can be studied considering repetitive traffic flows such as regular daily trips, considering the peak hour. This simplification of the problem is acceptable as there could be time-framed TWM sets distributed to the vehicles. So, for the sake of conciseness and simplicity, we will consider repetitive traffic flows during the peak hour and study the dynamics of driver adherence concerning the global travel time.

Our utility model provides two main variables $[U_{TWM}, \bar{U}]$, representing the utility of using TWM routing or not using it, thus using the standard method \mathbb{R}_0 (21).

$$[U_n] = [U_{TWM}, \bar{U}] \tag{21}$$

According to the MLM expression described in (8) for the probability of TWM usage, we obtain (22)

$$P(U_{TWM}) \rightarrow \frac{\exp(U_{TWM})}{\exp(U_{TWM}) + \exp(\bar{U})} \tag{22}$$

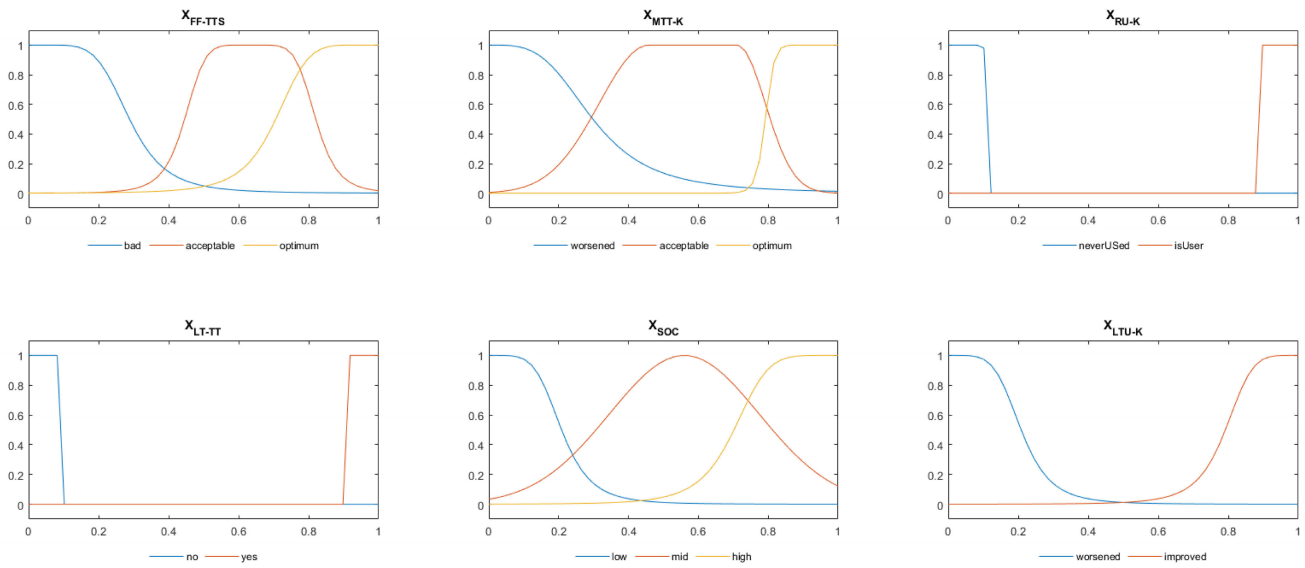


FIGURE 3. $[X_i]$ evaluation functions for TWM.

The evaluation functions for the $[X_i]$ to $[C_i]$ categories are shown in Figure 3, using mainly Gaussian distributions to represent user behavior. The specific values for the parameters of the functions are taken from the extensive experiments that have been developed in the study, though they may be taken from real data usage or user surveys. $[U_{TWM}, \bar{U}]$ evaluation functions are shown in Figure 4.

III. EXPERIMENTS

Deploying new ITS applications in a massive scope is a complex task that requires intensive research, testing, investment, and marketing effort. To validate the effectiveness of new ITS systems, existing traffic simulation software plays a pivotal role by enabling simulating diverse traffic demand and driver behavior conditions, including the simulation of advanced ITS applications.

In our work, two different simulation scenarios are studied:

- 1) A synthetic reference traffic network, where traffic demand generates congested links and nodes. Synthetic scenarios allow a fast model development isolating the utility model assumptions and policies from the real network constraints.
- 2) A real urban traffic network is fed with a synthetic traffic demand to reproduce congestion conditions, used to validate results.

A. SIMULATION ENVIRONMENT

The experimental results are evaluated in Matlab R2020b (update 5) [51] together with some python 3.7 scripts to process map formats. The Matlab environment uses the Simulink package and the Matlab Fuzzy Logic Toolbox [52] which is used to model the driver’s fuzzy utility model. Optimization of TWM maps is achieved by means of the Matlab’s package

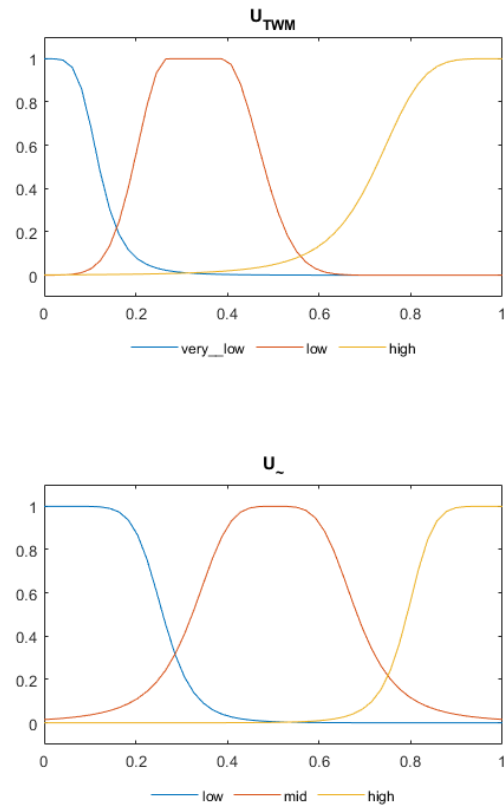


FIGURE 4. $[U_{TWM}, \bar{U}]$ evaluation functions.

for Genetic Algorithm processing [53]. The whole simulation runs in a Window10 hosted Intel iCore7 quad-core architecture with 16Gb RAM.

B. EXPERIMENTAL SETUP

Experiments are focused on how ITS adoption evolves, attending to the BOID+S model for the driving experience. We consider a specific traffic demand formed by the origin-destination flows that are repeated every day. These flows correspond to a congested time frame where drivers are looking for routing alternatives to reduce travel time.

The experiments model the evolution of the first D days, starting from an empty adoption distribution and considering a specific resistance to change, following a probabilistic distribution. A time frame of $D = 50$ labor days is considered, though real experiences could differ in time extension depending on concrete circumstances.

Every day, drivers take the routing decision considering the BOID+S model, and, at the end of the trip, they register how was the driving experience considering the observed parameters. In the same way, the traffic authority takes daily snapshots on global traffic parameters: global adherence to TWM, total travel time, and others. The authority may take some action to influence TWM adherence.

At the beginning of the simulation period, an optimized TWM map is generated. It uses the traffic network and the traffic demand forecast, which is known in advance. With the TWM generation process, a TWM distribution policy for every vehicle is selected among the available policy set: pure random assignment, random per flow, sequential per flow, or some other. Our experiments use the pure random assignment policy for simplicity.

To be able to make consistent comparisons between simulation scenarios the homogeneous parameter sets are considered. Optimal TWM map sets are based on a TWM-3-2-2 schema [38]: 3 weighted network maps in the TWM, two shortest-paths based on the free-flow minimal cost paths, and consideration of 2-distance radius from the KSP paths. The shortest paths are obtained based on Dijkstra’s algorithm with the implementation proposed by Yen [54].

For the optimum TWM generation, a static traffic assignment criteria is used, using the volume-delay function (VDF) (20) using $\alpha = 0, 15$ and $\beta = 4$. Link capacities are adapted from [55] and [56].

The genetic algorithm (GA) that computes the optimal TWM map uses 50 individuals and 500 evolutionary generations, bounding maximum and minimum weight variation between $[-50\%$ of the original weights. Details of the GA can be found in [38].

We used two different user resistance to change models: the binary mode Y_{bin} and the normal mode Y_{norm} with $p_{max} = 0.5$. These are shown in Figures 5 and 6. Different values $p_{max} \in [0, 1)$ values are considered for the maximum probability amplitude in the normal distribution. Value 0 provides the zero resistance to change.

The simulations consider that the drivers have a mid-term memory of the last 10 executions.




FIGURE 5. Strict distribution of driver resistance to change, $Y_{bin} \rightarrow 0.5 * \text{binary}(0.5)$.




FIGURE 6. Normal distribution of driver resistance to change, $Y_{norm} \rightarrow 0.5 * \text{norm}(0.5, 0.1)$.

TABLE 4. GRID64: O/D matrix.

Source/Destination	N_{73}	N_{75}	N_{77}
N_{23}	1000	500	1000
N_{26}	500	1000	500

C. SYSTEM DYNAMICS IN THE GRID64 SYNTHETIC NETWORK

The synthetic scenario selected for experimental simulation is the GRID64 described in [38], where the different algorithms and criteria for obtaining an optimal TWM distribution are detailed for a particular traffic demand. We refer to this work for the calculation details.

GRID64 is a rectangular grid-shaped network defined by 8×8 nodes $[N_{xy}]$ connected by bi-directional links. It contains 64 nodes and 224 bidirectional links whose weights are randomly assigned in the $[4, 12]$ range (uniform) (Figure 7). Traffic demand is formed by 6 traffic flows $\mathbb{T} = [f_1, f_2 \dots f_6]$ connecting 3 traffic origins and 2 traffic sinks. Total traffic payload contains 4,500 vehicles (Table 4). An initial adoption rate of 0.1% of TWM adherence is assumed.

1) TWM ADOPTION EVOLUTION

For this experiment the Extended Flow-Path for TWM algorithm has been used [38], using a 3 maps structure with 3 shortest-paths, and a distance radius $d = 2$ for the KSP routing area (EFP-KSP-3-2-2). Optimal TWM distribution is




FIGURE 7. GRID64: traffic network and demand flows.




FIGURE 8. GRID64: Evolution of TWM adherence with $Y_{norm}(0.5, 0.5, 0.1)$.

generated with the Matlab Genetic Algorithm package using an evolutionary population of 50 members and 500 generations. TWM creation process converges quickly providing an optimal TWM distribution.

Figure 8 shows the adherence using $rc_{norm}(0.5, 0.5, 0.1)$. As we can see, travel time differences during congestion scenarios force the drivers to look for alternative routing methods (TWM in this case), which is initially almost unknown. The drivers that start using it find that the travel time experience with the new routes is much better than the travel time with the shortest path under current traffic conditions. This usage reinforces TWM usage for the future, and they keep on using it.

Regardless of how TWM adherence behaves, it is interesting to observe in Figure 9 that TTS gets stationary, close to the system optimum, despite the changes of decision that the vehicles are taking. For the selected simulation, at period 15, TTS stabilizes.

The Fuzzy Utility Rules popularity is shown in Figure 10. Rule 6 states that those vehicles using TWM and obtaining a good result in travel time will keep on using this routing method. In the same situation, rule 15 states that those vehicles that are qualified TWM users, and on the last day did not use it obtaining poor results, will retake TWM usage.

It is interesting to deep dive into the early adoption phase, where the most used rules are 3, 4, and 6. Rule 3 states that




FIGURE 9. GRID64: Evolution of TTS $Y_{norm}(0.5, 0.5, 0.1)$.




FIGURE 10. GRID64: popularity of BOID+S rules.




FIGURE 11. GRID64: popularity of BOID+S rules in early times.

under low TWM popularity, non-TWM users will not use the new routing method. Rule 4 states that when TWM popularity raises, drivers will slightly tend to use it. Of course, as has been already pointed, rule 6 states that if TWM provides reasonable solutions, drivers will keep on using it.

After an initial period of early adopters (up to day 15), the drivers' community observes that TWM adoption is relevant, and new drivers are attracted by this new method, quickly reaching 65% usage. At this point, many users are selecting the same alternative routes, so some of them return to the original routing strategy. Figure 12 shows how the fuzzy rules are fired for a concrete individual.

Figure 13 outlines how TWM usage decisions affect the individual travel times, where the impact of changing the




FIGURE 12. GRID64: Individual fuzzy decision sequence.




FIGURE 13. GRID64: Travel time evolution related to TWM usage.




FIGURE 14. GRID64: Drivers resistance to change.

routing decision is exposed. Drivers that start using TWM and decide to change their decision suffer a travel time penalty that forces them to roll back their decision.

Considering the user resistance to change (Figure 14), we can observe that the distribution of drivers that should have changed the routing strategy is divided into the distribution of drivers accepting changes (blue) and drivers deciding not to change their actual routing strategy.

Figure 15 represents the number of vehicles that have changed their routing decision during the whole simulation, where we can see how previous decisions and their impact on travel experience make them change and adapt their subsequent decision to a subjectively better scenario.

It can be observed in Figures 16 and 17 that the system has a strong tendency to converge towards stable values, besides the effect of user resistance to change. Several probabilities




FIGURE 15. GRID64: Number of vehicles changing routing strategy.




FIGURE 16. GRID64: TWM adherence evolution at different p_{max} values $Y_{norm}(p_{max}, 0.5, 0.1)$.




FIGURE 17. GRID64: global travel time evolution at different p_{max} values $Y_{norm}(p_{max}, 0.5, 0.1)$.

of change are used, ranging from 0 to 0.9. Interestingly, when drivers are prone to accept changes, they use alternate traffic methods depending on the concrete traffic conditions. After several peak adoption oscillations, TWM adoption converges towards a system optimum status.

D. SYSTEM DYNAMICS IN A REAL TRAFFIC NETWORK

A real traffic network scenario is shown in Figure 18 describing the new district of Las Tablas in the north of Madrid,

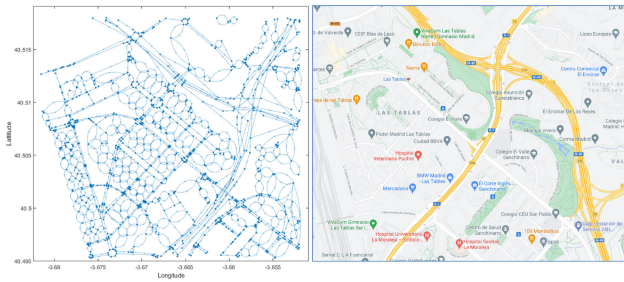


FIGURE 18. Madrid-Las Tablas traffic network and Google maps view.




FIGURE 19. Las tablas main traffic flows.

Spain. This district, with more than 24,300 hectares, occupies almost half of the municipal term of Madrid. Added to this particularity, its 30,000 inhabitants make it, by demographic weight, the city’s third district. It also contains large business and financial centers that cause significant inbound and outbound traffic during business hours. The district is bounded by large expressways to the north, south, and east, while to the west, it is blocked by railways.

A synthetic traffic demand of 15,000 vehicles is created for the experiment, crossing the network and creating congested areas. They are grouped in 30 flows of 500 vehicles and are represented in Figure 19. The traffic network contains 971 nodes and 1583 links. The GA that creates the optimal TWM for the traffic demand selects a sub-network of 420 nodes and 691 links when an EFP-KSP-3-2-2 strategy is considered (3 traffic maps, 2 shortest paths, and 2 node-distance for alternative routing area). It takes 160 evolutionary generations to converge. An initial adoption rate of 0.1% of TWM adherence is assumed.

1) TWM ADOPTION EVOLUTION

Figure 20 shows how TWM adherence evolves depending on the resistance to change selected for the vehicle population, while Figure 21 shows global travel time evolution.




FIGURE 20. Madrid las tablas: TWM adherence evolution at different P_{max} values $Y_{norm}(P_{max}, 0.5, 0.1)$.




FIGURE 21. Madrid las tablas: global travel time (TTS) evolution at different P_{max} values $Y_{norm}(P_{max}, 0.5, 0.1)$.




FIGURE 22. Madrid las tablas: popularity of BOID+S rules.

TWM adherence evolves to a quasi-constant value that varies considerably depending on the propensity to change of the population. Nevertheless, it can be observed that global travel time optimization is quickly achieved, and what is most interesting, it hardly depends on the resistance to change. It is enough that a small of the population adopts TWM to obtain a highly significant value of TTS for the majority.




FIGURE 23. Madrid las tablas: popularity of BOID+S rules in early times.

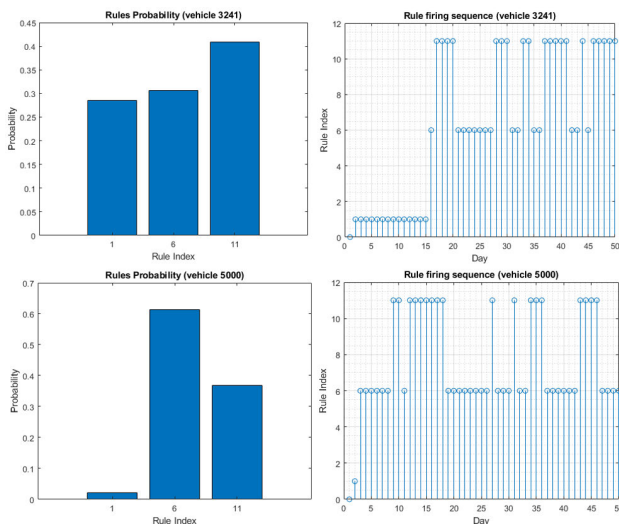


FIGURE 24. Madrid las tablas: behavior of individuals 3241 and 5000.

Figure 22 show BOID+S rules popularity for the whole simulation, while Figure 23 shows the same concept during the seven first TWM deployment days. Results are consistent with those obtained in the synthetic scenario: those drivers adopting TWM and experiencing a significant improvement in their travel time will keep using it. Early adoption is limited by the knowledge of the drivers about TWM.

If we analyze individual behavior, Figure 24 shows two different behaviors for individuals 3241 and 5000. The first individual habitually uses a route with good travel times (rule 1 is elicited). Eventually, this individual becomes a TWM user (rule 6) and gets a new route, but the experience is not so good as the previous, so this driver uses the standard non-TWM routing mechanism (rule 11). On the other hand, individual 5000 suffers congestion regularly, so this driver quickly starts using TWM (rule 6) and keeps on using it as a preferred strategy. Sometimes, the route gets affected by others' decisions and tries back to the standard routing strategy (rule 11), but returns quickly to TWM when it is noticed that it provides better routes (rule 6).

IV. CONCLUSION AND FUTURE WORK

Our study proposes a flexible framework for modeling and evaluating driving experience in Intelligent Transportation

Systems (ITS). When a traffic population is offered a set of traffic routing applications, drivers individually use their subjectively better app to select the recommended route. The paper considers driver behavior as a set of beliefs, obligations, intentions, desires, and social influences (BOID+S), evaluated through multi-valued fuzzy criteria.

Individuals evaluate the fuzzy utility of each routing strategy for each trip. So, when these fuzzy subjective utilities are available, then a discrete choice over the routing alternatives can be applied. A Multinomial Logit Model (MLM) is suitable to estimate the probabilities of making routing decisions.

This behavioral routing decision model poses a reasonable concern about the convergence and stability over time of the ITS strategies that are considered. If they propose subjectively good routing alternatives, such app adoption would increase in time and lead to a system optimum.

The adoption rate (adherence) to ITS in the traffic population determines the effectiveness of their algorithms. However, this adherence evolves, where the decisions made by the rest of the population constantly change the decision-making processes.

Our paper applies the ITS evaluation model to the Traffic Multi-Map Routing with optimal link weights (TWM) described in [38], using a concrete set of travel-time related parameters and fuzzy rules.

TWM adherence convergence, stability, and global travel times obtained are studied over two different network scenarios:

- A reference synthetic grid-based network that enables detailed analysis of the BOID+S model.
- A real urban traffic network where the same TWM strategy is applied.

The experimental results are consistent between them, showing that optimal TWM usage provides a good traffic solution that significantly impacts the global travel time of the traffic network from the system optimum perspective. Traffic network performance evolves based on individual decisions that lead to a constant TWM adoption rate.

Macroscopic convergence of TWM adoption is based on the microscopic individual behavior model. Individuals make their own decisions considering their circumstances that are modeled by fuzzy rules.

The main advantages of the proposed analysis model are its generality, its versatility, its open and flexible character, its ability to be adapted to empirical values obtained from direct feedback from users, and that the results can be easily simulated:

- It can be applied to any traffic routing strategy, not only to traffic-weighted multi-maps. Moreover, multiple traffic routing strategies can be used and compared at the same time based on user experiences.
- The user utility model is very flexible, where multiple utility objectives can be added and managed efficiently. The fuzzy utility modeling approach decouples value categories from the numerical evaluation functions.

- The user behavior model is open, where new variables, as user considerations, can be added and managed easily. As well, its fuzzy modeling provides a natural way to express behaviors decoupled from their numerical expressions.
- User decisions are modeled as weighted fuzzy rules that can also be easily edited and managed, adding generic behaviors and specific constraints when required.

It is worth noting that using fuzzy rules in conjunction with discrete choice methods (in this case, using a multinomial logit model) may be easily linked to field analysis based on user experience surveys or application feedback methods. The users can directly inform the user utility variables and expectations on the routing methods. This study is left for future field research work, together with the analysis of other user impact variables such as trip distances, tolls, electric recharge stations, and other factors.

REFERENCES

- [1] J. D. D. Ortuzar and L. G. Willumsen, *Modelling Transport*, 3rd ed. Hoboken, NJ, USA: Wiley, 2001.
- [2] J. Chow and W. Recker, *Informed Urban Transport Systems: Classic and Emerging Mobility Methods Toward Smart Cities*, 1st ed. Amsterdam, The Netherlands: Elsevier, Apr. 2018.
- [3] A. L. Bazzan and F. Klugl, *Introduction to Intelligent Systems in Traffic and Transportation* (Synthesis Lectures on Artificial Intelligence and Machine Learning). San Rafael, CA, USA: Morgan & Claypool, Dec. 2013.
- [4] C. G. Prato, "Route choice modeling: Past, present and future research directions," *J. Choice Model.*, vol. 2, no. 1, pp. 65–100, 2009.
- [5] A. Sarker, H. Shen, M. Rahman, M. Chowdhury, K. Dey, F. Li, Y. Wang, and H. Narman, "A review of sensing and communication, human factors, and controller aspects for information-aware connected and automated vehicles," *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 1, pp. 7–29, Mar. 2019.
- [6] G. de Moraes Ramos, T. Mai, W. Daamen, E. Frejinger, and S. Hoogendoorn, "Route choice behaviour and travel information in a congested network: Static and dynamic recursive models," *Transp. Res. C, Emerg. Technol.*, vol. 114, pp. 681–693, May 2020.
- [7] A. Cheng, M.-S. Pang, and P. Pavlou, "Mitigating traffic congestion: The role of intelligent transportation systems," *Inf. Syst. Res.*, vol. 31, pp. 653–674, Jun. 2019.
- [8] J. G. Wardrop and J. I. Whitehead, "Correspondence. Some theoretical aspects of road traffic research," *Proc. Inst. Civil Eng.*, vol. 1, no. 5, pp. 767–768, Oct. 1952.
- [9] G. Ramos, W. Daamen, and S. Hoogendoorn, "A state-of-the-art review: Developments in utility theory, prospect theory and regret theory to investigate travellers' behaviour in situations involving travel time uncertainty," *Transp. Rev.*, vol. 34, pp. 46–67, Feb. 2014, doi: 10.1080/01441647.2013.856356.
- [10] A. Dhanapal and V. E. Sobana, "A survey on fuzzy transportation problems," *IOP Conf. Series, Mater. Sci. Eng.*, vol. 263, Nov. 2017, Art. no. 042105.
- [11] J. Macfarlane. Your Navigation App is Making Traffic Unmanageable—IEEE Spectrum. IEEE Spectrum: Technology, Engineering, and Science News. Accessed: May 20, 2021. [Online]. Available: <https://spectrum.ieee.org/computing/hardware/your-navigation-app-is-making-traffic-unmanageable>
- [12] G. Bianchin and F. Pasqualetti, "Routing apps may cause oscillatory congestions in traffic networks," in *Proc. 59th IEEE Conf. Decis. Control (CDC)*, Dec. 2020, pp. 253–260.
- [13] J. Cockburn, A. G. E. Collins, and M. J. Frank, "A reinforcement learning mechanism responsible for the valuation of free choice," *Neuron*, vol. 83, no. 3, pp. 551–557, Aug. 2014.
- [14] F. Trapsilawati, T. Wijayanto, and E. Jourdy, "Human-computer trust in navigation systems: Google maps vs waze," *Commun. Sci. Technol.*, vol. 4, pp. 38–43, Jul. 2019.
- [15] H. Abbass and J. Scholz, "Foundations of trusted autonomy: An introduction," in *Proc. Stud. Syst., Decis. Control*, Jan. 2018, pp. 1–12.
- [16] F. Aloulou, *The Application Discrete Choice Models Transportation*. London, U.K.: IntechOpen, Nov. 2018.
- [17] N. Noerkaisar, B. Suharjo, and L. N. Yulianti, "The adoption stages of mobile navigation technology waze app as Jakarta traffic jam solution," *Independ. J. Manage. Prod.*, vol. 7, no. 3, pp. 914–925, Sep. 2016.
- [18] E. Angelelli, V. Morandi, and M. Speranza, "Minimizing the total travel time with limited unfairness in traffic networks," *Comput. Oper. Res.*, vol. 123, Art. no. 105016, Jun. 2020.
- [19] A. S. Schulz and N. E. Stier-Moses, "Efficiency and fairness of system-optimal routing with user constraints," *Networks*, vol. 48, no. 4, pp. 223–234, 2006.
- [20] T. Roughgarden, "How unfair is optimal routing?" in *Proc. 13th Annu. ACM-SIAM Symp. Discrete Algorithms (SODA)*, Nov. 2001, pp. 203–204.
- [21] S. Chanas, W. Kolodziejczyk, and A. Machaj, "A fuzzy approach to the transportation problem," *Fuzzy Sets Syst. Int. J. Inf. Sci. Eng.*, vol. 13, pp. 211–221, Aug. 1984.
- [22] D. Teodorovic and S. Kikuchi, "Transportation route choice model using fuzzy inference technique," in *Proc. 1st Int. Symp. Uncertainty Model. Anal.*, Jan. 1991, pp. 140–145.
- [23] M. Luisa De Maio and A. Vitetta, "Route choice on road transport system: A fuzzy approach," *J. Intell. Fuzzy Syst.*, vol. 28, no. 5, pp. 2015–2027, Jun. 2015.
- [24] P. De Wilde, "Fuzzy utility and equilibria," *IEEE Trans. Syst., Man, Cybern. B. Cybern.*, vol. 34, no. 4, pp. 1774–1785, Aug. 2004.
- [25] R. Aliev, W. Pedrycz, B. Fazlollahi, O. H. Huseynov, A. Alizadeh, and B. Guirimov, "Fuzzy logic-based generalized decision theory with imperfect information," *Inf. Sci.*, vol. 189, pp. 18–42, Apr. 2012.
- [26] A. Quattrone and A. Vitetta, "Random and fuzzy utility models for road route choice," *Transp. Res. E, Logistics Transp. Rev.*, vol. 47, pp. 1126–1139, Nov. 2011.
- [27] K. Yamada, J. Ma, and D. Fukuda, "Simulation analysis of the market diffusion effects of risk-averse route guidance on network traffic," *Procedia Comput. Sci.*, vol. 19, pp. 874–881, Aug. 2013.
- [28] L. Xiao and H. Lo, "Adaptive vehicle routing for risk-averse travelers," *Transp. Res. C, Emerg. Technol.*, vol. 36, pp. 460–479, Nov. 2013.
- [29] M. Miralinaghi, Y. Lou, Y. Hsu, R. Shabanpour, and Y. Shafahi, "Multi-class fuzzy user equilibrium with endogenous membership functions and risk-taking behaviors," *J. Adv. Transp.*, vol. 50, no. 8, pp. 1716–1734, Oct. 2016.
- [30] S. Gao, E. Frejinger, and M. Ben-Akiva, "Adaptive route choices in risky traffic networks: A prospect theory approach," *Transp. Res. C, Emerg. Technol.*, vol. 18, no. 5, pp. 727–740, Oct. 2010.
- [31] H. Xu, Y. Lou, Y. Yin, and J. Zhou, "A prospect-based user equilibrium model with endogenous reference points and its application in congestion pricing," *Transp. Res. B, Methodol.*, vol. 45, no. 2, pp. 311–328, Feb. 2011.
- [32] M. Miralinaghi, Y. Shafahi, and R. Shabanpour, "A fuzzy network assignment model based on user equilibrium condition," *Scientia Iranica*, vol. 22, pp. 2012–2023, Dec. 2015.
- [33] M. Binetti, M. Mitri, and M. Ottomanelli, "Analysis of imprecise perception in route choice considering fuzzy costs," in *Advances in Intelligent Systems and Computing*. Cham, Switzerland: Springer, Jul. 2018, pp. 452–467.
- [34] C. Alós-Ferrer, S. Hágelschäfer, and J. Li, "Inertia and decision making," *Frontiers Psychol.*, vol. 7, p. 169, Feb. 2016.
- [35] M. Hassan, T. Rashidi, and N. Nassir, "Consideration of different travel strategies and choice set sizes in transit path choice modelling," *Transportation*, vol. 48, pp. 1–24, Apr. 2021.
- [36] A. Paricio and M. A. Lopez-Carmona, "Urban traffic routing using weighted multi-map strategies," *IEEE Access*, vol. 7, pp. 153086–153101, 2019.
- [37] A. Paricio and M. A. Lopez-Carmona, "Multimap routing for road traffic management," in *Advances in Practical Applications of Survivable Agents and Multi-Agent Systems: The PAAMS Collection* (Lecture Notes in Computer Science). Avila, Spain: Springer, Jun. 2019, pp. 188–199.
- [38] A. Paricio and M. A. Lopez-Carmona, "Application of traffic weighted multi-map optimization strategies to traffic assignment," *IEEE Access*, vol. 9, pp. 28999–29019, 2021.
- [39] D. Cheng, O. Gkoutouna, A. Züfle, D. Pfoser, and C. Wenk, "Shortest-path diversification through network penalization: A Washington DC area case study," in *Proc. Int. Workshop Comput. Transp. Sci.*, Nov. 2019, pp. 1–10.
- [40] M. A. Lopez-Carmona and A. Paricio-García, "CellEVAC: An adaptive guidance system for crowd evacuation through behavioral optimization," *Saf. Sci.*, vol. 139, Jul. 2021, Art. no. 105215.

- [41] M. A. Lopez-Carmona and A. Paricio-Garcia, "LED wristbands for cell-based crowd evacuation: An adaptive exit-choice guidance system architecture," *Sensors*, vol. 20, no. 21, p. 6038, 2020.
- [42] M. Haghani and M. Sarvi, "Crowd behaviour and motion: Empirical methods," *Transp. Res. B, Methodol.*, vol. 107, pp. 253–294, Jul. 2017.
- [43] J. Broersen, M. Dastani, J. Hulstijn, Z. Huang, and L. van der Torre, "The BOID architecture: Conflicts between beliefs, obligations, intentions and desires," in *Proc. 5th Int. Conf. Auto. Agents*. New York, NY, USA: Association for Computing Machinery, 2001, pp. 9–16.
- [44] M. Ben-Akiva and M. Bierlaire, "Discrete choice methods and their applications to short term travel decisions," in *Handbook of Transportation Science*, vol. 26, R. W. Hall, Ed. Boston, MA, USA: Springer, Feb. 2000, pp. 5–33, doi: 10.1007/978-1-4615-5203-1_2.
- [45] M. Ben-Akiva, A. D. Palma, D. McFadden, M. Abou-Zeid, P.-A. Chiappori, M. D. Lapparent, S. Durlauf, M. Fosgerau, D. Fukuda, S. Hess, C. Manski, A. Pakes, N. Picard, and J. Walker, "Process and context in choice models," *Marketing Lett.*, vol. 23, no. 2, pp. 439–456, Jun. 2012.
- [46] D. McFadden and P. E. Zarembka, "Conditional logit analysis of qualitative choice behavior," in *Proc. Frontiers Econometrics*, Jan. 1974, pp. 105–142.
- [47] T. Lotan and H. Koutsopoulos, "Models for route choice behavior in the presence of information using concepts from fuzzy set theory and approximate reasoning," *Transportation*, vol. 20, pp. 129–155, Jun. 1993.
- [48] P. C. Vythoukka and H. N. Koutsopoulos, "Modeling discrete choice behavior using concepts from fuzzy set theory, approximate reasoning and neural networks," *Transp. Res. C, Emerg. Technol.*, vol. 11, no. 1, pp. 51–73, Feb. 2003.
- [49] R. Kucharski and A. Drabicki, "Estimating macroscopic volume delay functions with the traffic density derived from measured speeds and flows," *J. Adv. Transp.*, vol. 2017, pp. 1–10, Jan. 2017.
- [50] B. U. P. Division, *Traffic Assignment Manual*. Washington, DC, USA: Bureau of Public Roads U.S. Department of Commerce, 1964.
- [51] *MATLAB (R2019b)—MATLAB and Simulink Product Families Update*. Accessed: Sep. 2020. [Online]. Available: <https://mathworks.com>
- [52] *Fuzzy Logic Toolbox*. Accessed: Sep. 2020. [Online]. Available: <https://es.mathworks.com/products/fuzzy-logic.html>
- [53] *MATLAB—Genetic Algorithms*. Accessed: Sep. 2020. [Online]. Available: <https://mathworks.com/discovery/genetic-algorithm.html>
- [54] J. Yen, "Finding the K shortest loopless paths in a network," *Manage. Sci.*, vol. 17, pp. 712–716, Jan. 1970.
- [55] T. R. Board, *Highway Capacity Manual, 6th Edition: A Guide for Multimodal Mobility Analysis*, 6th ed. Washington, DC, USA: The National Academies of Sciences, Engineering, and Medicine, 2016.
- [56] *Technical Note 10—What is the Capacity of the Road Network for Private Motorised Traffic and How Has This Changed Over Time*. Transport for London, London, U.K., 2015, p. 15.



ALVARO PARICIO received the double M.S. degree in computer science and communications from the Universidad Politecnica de Madrid, Madrid, Spain, in 1992. He is currently pursuing the Ph.D. degree in information and communications technologies with the Universidad de Alcalá (UAH), Madrid. He is a Lecturer in computer science with UAH and a Lecturer in digital transformation with the Escuela de Organización Industrial, depending of the Spanish Ministry of Industry. He has developed a wide professional career in private held companies. He joined Telefonica Research and Development, in 1994, as an AI Expert. In 1999, he is a co-founded the Company IAPsolutions (Spain, USA) a technology startup for an AI agents, the IoT and edge-computing leading the company as the CTO. In 2014, he joined SecuritasDirect, a global leader for home-security, as the Development Director for EMEA and LATAM. Since 2017, he leads Digital Transformation Offices with the Telecom Group MasMovil, the fastest growing telecom operator in Europe, since 2017. His main research interests include optimization algorithms, traffic routing optimization, safety and evacuation strategies, the IoT architectures, and massive data analytics.



MIGUEL A. LOPEZ-CARMONA received the B.S. degree in electronics engineering from the University of Alcalá, in 1994, the M.S. degree in telecommunication engineering from the Polytechnic University of Madrid, in 1999, and the Ph.D. degree in telecommunication engineering from the University of Alcalá, in 2006. From 1995 to 2000, he held positions in Logytel and Alcatel as the Project Manager and a Research Scientist in the areas of railways and defense. Since 2000, he has been an Associate Professor with the Department of Computer Engineering, University of Alcalá. From 2010 to 2017, he was the Vice-Dean of the Polytechnic School, University of Alcalá. He has been a Visiting Researcher with the Center for Collective Intelligence, Massachusetts Institute of Technology (MIT), where he did research in complex automated negotiations and optimization of complex networks. His research interests include intelligent transport systems, safety and evacuation strategies, automated negotiation, multi-agent systems, and optimization of complex networks.

...

6

Otras publicaciones relacionadas

6.1. Multimap Routing for Road Traffic Management

Este artículo de congreso, titulado “Multimap Routing for Road Traffic Management”, se presentó en el Congreso PAAMS’19, 17th International Conference on Practical Applications of Agents and Multi-Agent Systems, celebrado en Ávila, España en julio 2019. Se incluye en la tesis pues es el trabajo preliminar introductorio de TWM (Traffic Weighted Multi-Mpas) donde se introduce la idea, sobre escenarios sintéticos, que darán lugar al resto de la investigación objeto de la tesis.

Tras una breve resumen del artículo, se muestran los datos sobre la publicación y su relevancia. Por último, se ha incluido una copia de la versión publicada del artículo.

6.1.1. Introducción

Uno de los principales retos en el modelado y diseño de sistemas y servicios de gestión del tráfico es la dificultad de controlar la toma de decisiones de los conductores a la hora de elegir sus rutas, con el fin de adecuar los recursos a la demanda de forma óptima y automatizada. Los conductores, por su parte utilizan cada vez más sistemas avanzados de navegación basados en agentes que se adaptan y reaccionan en tiempo real al estado del tráfico [91]. Así, la mayoría de los

vehículos reciben recomendaciones y estímulos muy similares, trasladando las situaciones de congestión [20, 49].

El concepto de *Urban Computing* [137] integra perspectivas globales que se centran no sólo en los vehículos y su contribución al tráfico, sino también en los objetivos colectivos de los ciudadanos, la movilidad multimodal de los individuos y los intereses de los grupos en conflicto.

El objetivo de la ponencia presentada al congreso PAAMS'19 era presentar la idea central del enrutamiento mediante mapas de pesos diferenciados (TWM) como una técnica válida para la reducción de los tiempos globales de totales viaje en los vehículos que circulan por una red de tráfico. Así cada agente vehicular recibe una visión personalizada de de la red de tráfico. La ponencia presenta TWM como una técnica novedosa para disminuir la congestión de tráfico mediante la aleatorización de los pesos de la red para la obtención de KSP diferenciados. La propuesta de TWM se anticipa por varios meses otras propuestas publicadas [34].

Los experimentos realizados emplean la red GRID16 para analizar el efecto de los multi-mapas sobre la congestión usando diferentes tipos de tráficos, tanto de fondo como flujos direccionales. Los resultados obtenidos y su discusión en el congreso fomentan la investigación en TWM dando lugar al primer artículo [98].

6.1.2. Artículo

Multimap Routing for Road Traffic Management

Alvaro Paricio Garcia¹[0000-0002-9162-4147] and Miguel A. Lopez-Carmona²[0000-0001-9228-1863]

Universidad de Alcalá, Madrid, Spain. <http://www.uah.es> *
alvaro.paricio@uah.es, miguelangel.lopez@uah.es

Abstract. TWM -*Traffic Weighted Multi-maps*- is presented as a novel traffic route guidance model to reduce urban traffic congestion, focusing on individual trip and collective objectives considering citizens, individual multi-modal mobility, and heterogeneous traffic groups. They have different interests, goals and regulation, so new multi-objective cost functions and control systems are required. TWM is structured around a novel control paradigm, based on the generation and distribution of complementary cost maps for traffic collectives (fleets), oriented towards the application of differentiated traffic planning and control policies. Agents receive a customized view TWM of the network that is used to calculate individual route using standard means and tools. The research describes the TWM theoretical model and microscopic simulations over standard reference traffic network grids, different traffic congestion scenarios, and several driver's adherences to the mechanism. Travel-time results show that TWM can have a high impact on the network performance, leading to enhancements from 20% to 50%. TWM is conceived to be compatible with existing traffic routing systems. The research has promising future evolution applying new algorithms, policies and network profiles.

Keywords: Dynamic Traffic Assignment · Traffic Control · Traffic Simulation · Vehicle Routing · Traffic Big Data · Decision Making · Multi-agent systems

1 Introduction

One of the main challenges in the modeling and design of traffic management systems and services is the difficulty of controlling driver's decision making regarding the choice of their routes, in order to match resources and demand in an optimal and automated way. Currently, Traffic Control System (TCS) coordinate demand through direct intervention in the network, online information systems, panels, regulatory policies or restrictions [21]. Drivers, for their part, are increasingly using advanced agent-based navigation systems that adapt and react in real time to the state of traffic [20]. Thus, the majority of vehicles receive very similar recommendations and stimuli, which make it difficult to optimize demand and transfer situations of congestion [22, 16].

* This work was supported in part by the Spanish Ministry of Economy and Competitiveness under Grant TIN2016-80622-P and Grant TEC2013-45183-R.

There are many proposals and commercial systems that generate individual route recommendations and re-planning from data sent by users to a TCS [16]. However, these solutions raise multiple deployment questions due to computational resource demands, complexity, and privacy implications. The active participation of vehicles in the generation of data, and the use of Big Data as an element of mobility management, allow the design of alternative demand control models [13].

Smart-Cities require global perspectives that focus not only on traffic individuals (agents) and their contribution to traffic, but also on collective objectives considering citizens, individual multi-modal mobility, and conflicting group interests, leading to the concept of Urban Computing as described in [29]. This fact involves designing new multi-objective cost functions and the corresponding control models that optimize them.

The main objective of this research is to reduce average travel time of all the vehicles in the traffic network, fulfilling individual, collective and regulatory goals and constraints, reducing congestion times in the network. It describes a novel route guidance model called *TWM -Traffic Weighted Multi-maps-*, that is shown to be scalable, technically and economically viable, easy to deploy, compatible with existing platforms, and has a low impact on privacy. TWM is structured around a new control paradigm, based on the generation and distribution of complementary cost maps. Every individual agent receives a customized view of the traffic network. Vehicles are grouped in classes (fleets) that share the same network view. The aggregation of individual decision making tends to satisfy the predefined control policy.

TWM proposal takes into account the individual traffic agent ability to take its own decisions a) for using any of the known algorithms for K-shortest path (Dijkstra, A, A*, or any variant [8, 15, 7]) in case of individual route calculation, or b) having received a TWM-based route calculation, follow it (that will diverge in many occasions from the standard ones). Compatibility with existing routing frameworks based on route-queries for origin/destination (O/D) is direct, as TWM is then applied at the TCS back-end. TWM model is also of application with hyperpaths calculations.

Research main contributions include: (1) a novel traffic route guidance model based on multimaps distribution that enable differentiated route selection for individuals and collectives; (2) a microscopic simulation framework for TWM evaluation and algorithm comparisons, and (3) macroscopic and microscopic performance analysis based on the simulations performed for the most basic algorithm and network model. The research has promising future evolution applying new algorithms, policies and network profiles.

1.1 Literature review

MuTraff deals with the development of an intelligent traffic control system, made up of the design of congestion management mechanisms, from which many parameters susceptible to optimization and control are derived, such as pollution level, noise footprint, prioritization of vehicle type, contingency plans, etc. [2],

combined with a hybrid approach of individual vehicle agents that take into account the routing recommendations based on intention-aware policies [5, 26]. There are numerous proposals aimed at control and optimization of distributed and centralized type that are data driven [14, 25]. [1, 20] show a review of this type of multi-agent systems that address the problem using different approaches: automatic negotiation, distributed optimization, predictive routing, predictive control models, and others.

Among the centralized approaches, the proposals for signaling control stand out, proposing the application of predictive control models (MPC) combined with multi-agent models in the urban management of traffic lights at intersections or dynamic control in the incorporation of traffic flows [17], [18]. More specific proposals deal for example with the differential criteria applied to electric vehicles and charging stations [27], [25].

[12, 4] and others have proposed and evolved the hyperpaths formulation and evaluation where not a single route is received by the vehicle agents, but a tree of alternative routes for each origin and destination. Hyperpaths route calculus focuses on the uncertainty and variability of traffic dynamics, and is evaluated based on historical data and applying different analysis techniques [19, 9]. Our proposal is complementary to this approach as it focus on the network view that every individual receives and used at hyperpaths calculus. Hyper-path is conceived for individual risk-averse policies design (minimizing travel-time variance), in contrast with TWM that is multi-purpose and combines individual, group and global policies.

MuTraff is a centralized architecture that implements a distributed control for TWM in closed loop of routes of the vehicles [16, 22], with capacities of re-planning. MuTraff feedback is not given explicitly at the microscopic level (of individual routes), and both performance and signaling are given at the mesoscopic level.

Standard navigation system offer shortest routes, derived from real-time density information and historical traffic. Agents (vehicles) make decisions individually, taking as a reference the same source of information, which transfers situations of congestion. This is the so-called "*common resource distribution problem*", from which the so-called "*Minority Game*" or "*Farol Bar Problem*" derives [24]. It is therefore clear that there is a need for more precise control of vehicle routes, that requires precise individuals feedback and/or highly distributed sensor networks [28, 23]. This control could be exercised through individualised management at the microscopic level of each route. However, microscopic control entails problems of scalability, deployment and privacy, so MuTraff proposes an alternative, scalable, non-disruptive control and management methodology with fewer implications for users' privacy. Agent routing decisions may change during the travel, mainly based on the dynamic information received [6] not affecting the aggregated information available at the TCS.

Similar strategies are used in other routing problems such as IP traffic routing strategies (MSTP, SDN) [11] by using distribution of maps with differentiated link weights (link-costs) and shortest-path routing strategies.

2 TWM - Traffic Weighted Multi-maps

Current vehicle traffic agents share the same traffic network maps (roads, paths) whose main path attributes are their physical conditions (number of lanes, length) and also their logical constraints (max speed, traffic allowance, directional senses and others). When we consider the path cost function we cannot modify physical attributes, but we can definitively modify logical ones. If we replace the max speed concept with a cost function that is different for each traffic group of agents, we could generate differentiated network maps for them. Even more, we could have time-dependent maps for them.

The main feature of our proposal, is to generate a traffic management framework (named MuTraff) that can provide differentiated traffic maps (called Traffic Weighted Maps, TWM) for the same area that can fulfill the specific needs of every traffic class. These maps are delivered to the vehicles, depending on multiple factors that are evaluated in a central-station back-end based on multiple criteria. These maps are to be composed in dynamic way combining several sources: historical data, real-time traffic data, real-time events affecting mobility (non-traffic data, but affecting the demand. For instance, a sport event, or a critical incident), and of course, synthetic data extracted from big-data sources. Figure 1 illustrates the basics for TWM generation.

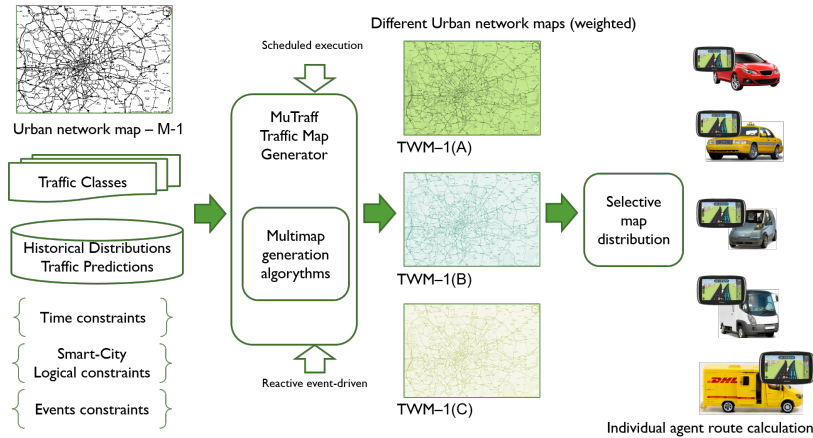


Fig. 1. TWM generation model. .

Traffic classes recognize the fact that every type of traffic has specific a) traffic goals, b) network constraints, c) regulations, d) traffic indicators and e) individual behaviors, so having a single traffic network map that considers only road descriptions, real-time conditions and traffic density is not enough to cover these specific features. Moreover, though some traffic classes have specific paths

(such as bikes), most of the traffic classes share the same paths; management of these specific paths is accomplished by regulation and signaling. But, it can also be covered by specific maps. Multi-map routing strategy shows that this approach is a valid tool to get a better, easy and dynamic traffic management model. Instead of having a heavy set of regulation, signaling, time and geofenced constraints that every individual should process, evaluate, and execute, it is easier to have them collected into traffic map collections that are used by the individuals for route selection.

Route selection is the ultimate decision to be taken by traffic individuals and all the preceding issues mentioned can be seen as just factors that influence on it. Traffic individuals behave as agents that take routing decisions based on the available information, their own experience, habits, beliefs, desires and intentions. Available information is formed by the routes proposed by the routing engines, the map information, traffic and road status both real-time and historical data. Multi-maps skew this available information for every fleet, considering the best resource allocation (paths) to conform pseudo-optimal routers that are offered to every fleet. These multi-maps provide a different traffic routing weight for each fleet at each path. For instance, a city center will have different network maps for the fleets taxi, electric vehicles, logistic distributions, and conventional cars. The path weights will be different for each fleet, promoting or penalizing traffic for each path. Of course, these maps can be static or time-dynamic, depending on multiple strategies.

Traffic routes can be generated by the individuals using the network maps and the computing application [16], but also can be generated by a TCS that receives the origin-destination requests for route and delivers a set of possible routes. TWM approach is valid for them as it considers optimal route evaluation against a weighted map. This weighted map can be processed both at the individual and the central station. It is always the individual who decides which route/path to use, but usage of MuTraff will always use a weighted network map.

Individual privacy and data protection is also a main concern in routing systems[10]. No individual route tracking is made as MuTraff is just publishing weighted maps for vehicles groups at certain areas, and then routes and multi-path graphs recommendations contains no individual data. Privacy is preserved. Real-time data is obtained from city sensors and is used to calculate traffic density and congestion.

2.1 Model formulation

A TWM multimap I^n is a collection of network maps $[\mu_i^n]$ referring to the same urban area Θ^n and traffic vehicle groups $[\Omega_k^n]$ (called *fleets*) as denoted in 1. Each urban area should have its own set of multimaps. This area could cover a whole city or just sectors.

$$I^n = \{[\mu_i^n]\}(\Theta^n, [\Omega_k^n]) \quad (1)$$

Each map instance μ_i^n that belongs to a multimap Π^n is a version Θ_i^n of the traffic network Θ^n , affected by a time constraint set I_i^n and applicable for some traffic vehicle groups $[\Omega_k^n]_i$ that are a subset of $[\Omega_k^n]$.

Each urban area Θ^n has a standard traffic network representation formed by a graph of geographical nodes η_k^n connected by edges, being each edge $\epsilon_{k,j}^n$ the traffic link with $l_{k,j}^n$ lanes that connects nodes η_k^n and η_j^n with a weight $\beta_{k,j}^n$. MuTraff multimaps use multiple weight distribution functions \mathcal{F}^n for assigning geographical values to the $\beta_{k,j}^n$ factor for each edge. With this formulation, standard traffic maps use the function \mathcal{F}_{std}^n that just consider lane-speed $S_{k,j}$ for providing the edge weight $\beta_{k,j}^n$.

$$\beta_{k,j}^n = F_{std}^n(\epsilon_{k,j}^n) = \alpha * S_{k,j} \quad (2)$$

In our initial experiments, we have tried statistical distributions such as normal-N 3 to create weight distributions in the maps that allow traffic dispersion in the network, enabling vehicles to use route alternatives recommendations for each fleet $[\Omega_k^n]$. We scale weights with factor δ ($\delta_{normal.a.b} = normal(a, b)$).

$$F_{normal.a.b}^n(\epsilon_{k,j}^n) = \alpha * S_{k,j} * (1 + \delta_{normal.a.b}) \quad (3)$$

There will be a population of $[v_i^k]$ vehicles grouped by $[\Omega_k^n]$ fleets. Those vehicles that do not belong explicitly to a fleet, will be assigned to the standard Ω_0^n fleet. The percent of vehicles that use MuTraff at any time is called the adherence factor ψ^n and is calculated as the percent of vehicles not using Ω_0^n .

Vehicles will generate $[T_j^k]$ trips during observations times. Each trip in general is composed by the vehicle identification, the starting timestamp, the starting point (origin node) O_j , the final destination point (node) D_j and tuple with possible intermediate stops P_j .

For the map-distribution approach, depending on each concrete time epoch, each fleet has a specific map μ_i^n that belongs to a multimap Π^n . This map is distributed to its individuals (on-demand or by publication to subscriptions). Vehicles not classified or in general belonging to standard Ω_0^n fleet will use the standard map Θ^n . The vehicle's agent calculate for each trip the shortest-path $r(T_j^k)$ route or hyper-path using the corresponding map (standard or ad-hoc received multimap) valid for this time-interval. This calculation will use some of the available routing algorithms \mathcal{f} (Dijkstra, A*, etc).

The agent confidence factor φ_j is a utility function that evolves in time based on previous experiences or available road and traffic information. Agent's route recommendation usage will vary for every individual based on the confidence factor φ_j that should overpass certain subjective threshold K^i .

3 Experiments and results

Though Traffic Weighted Maps (TWM Π^n) effects on traffic are suitable to be integrated with current macro, meso and microscopic traffic simulators [21], they all use Θ^n maps as urban network representation. We have developed MuTraff

simulator MTS over SUMO [3] that implements a car-following microscopic simulation environment.

3.1 Experiments design

GRID16 network is composed of a matrix of horizontal and vertical roads of 16 horizontal x 16 vertical paths, with uniform edges of 50 mts and single or double lanes. The maximum speed is limited to 50km/h (13,9m/s). It uses 5 traffic assignment zones (TAZ [3]): TAZ 1 to 4 are located in the external sides of the grid, TAZ 5 covers the whole grid 2.




Fig. 2. GRID16 network and TAZ configuration for experiments.

The traffic demand we will use in the experiments is composed by 4 different fleets: cars (44%), taxis (33%), buses (11%) and motorbikes (11%). Zones 1-4 generate directional crossing traffic from side to side, originating from one edge TAZ to an opposite edge TAZ (directional), zone 5 generates random internal traffic. As a reference value we will use the XS and M-size for standard traffic demand. TWM parameters used are: 8 maps per TWM, static weights with $F_{std}^n(\epsilon_{k,j}^n)$ and $F_{normal.0.5,0.5}^n(\epsilon_{k,j}^n)$ (random distribution centered on 0.5 and amplitude of 0.5, named as random05). *Route selection* algorithm $f = Dijkstra$.

Current experiments consider global traffic network enhancement, using thus, non-paired statistics. They are checked for the whole network at the end of the simulation and also for each edge in the network at every time-step of the simulation: *Routed traffic demand*, as number of vehicles successfully routed against the total traffic demand (global and per fleet). *Mean and median travel time*, as a measure of global travel durations. *Mean and median route distance*, as a measure of global travel distances. *Travel time dispersion*, as an histogram of travel durations, to check how many vehicles have been affected during the

experiments. *Variance* would provide us a single measure but a dispersion measure will give us a better insight into how this variance is occurring inside the population.

3.2 Non-TWM routing in congested GRID16 network

This simulation provides the reference for network traffic performance using a full traffic scenario combining internal random and directional traffics without applying the multimaps algorithm. Agents use shortest-path algorithm to select the route without predictive routing. Those agents traveling the same trip will use the same route. Figure 3 shows how *traffic congestion starts at the edges* as traffic is trying to enter the network and progressively the network gets congested, and due to the fact that traffic is fully internal, *congestion gets stationary*. Getting deeper inside the initial congestion scenario, we can appreciate how preferred edges selected for the trip routes are being blocked (number of halted vehicles).




Fig. 3. Grid16. Full traffic not using multimaps, evolution and details.

3.3 TWM routing applied to non-congested GRID16 network

In order to analyze the effects of applying TWM on the congested network, we will use several drivers confidence factors to reflect TWM adoption (ψ^n 5%, 10%, 20%, 50% and 100%). Simulation uses XS-size full traffic formed by 1300 vehicles (internal and directional trips). Multi-maps use random05 distribution (normal distributed random) with 8 TWM maps.

Figure 4 shows the histograms corresponding to the different ψ^n mentioned. Each histogram compares no-TWM and 8 maps TWM application scenarios. We can see that even in a low adoption schema as $\psi^n_{0.05}$, travel time starts to enhance. When ψ^n increases over 50% enhancements in mean travel-time are really relevant (23% travel time) growing to 48% for a 100% adoption of TWM. Last histogram shows perfectly how congested trips (green graph) have been reduced or even disappeared (blue graph). Mean route lengths have not changed significantly.

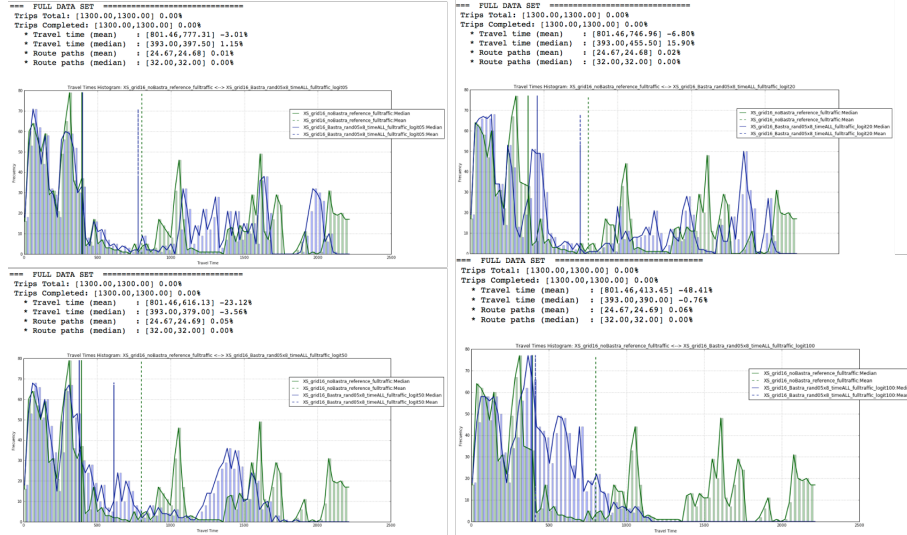


Fig. 4. GRID16 routing XS traffic with $\psi_{0.05}^n$, $\psi_{0.2}^n$, $\psi_{0.5}^n$, ψ_1^n

3.4 TWM routing applied to congested GRID16 network

Now we check the impact of TWM distribution on traffic performance using a congested full traffic scenario (M size, 2800 vehicles). In order to approach a more realistic scenario we use 2 lane paths for the whole network. We use the same random05 maps (uniformly distributed random) with 8 maps distribution. We study just adherence factor $\psi_{0.5}^n = 50\%$ and $\psi_1^n = 100\%$ values, as they show how much multi-maps can enhance congestion.

As we can see from 5 histogram, applying multimaps to the near-congested network with $\psi_{0.5}^n$ enhances mean travel-time 19,65% and median over 13%. ψ_1^n raises up to 42% and 28% respectively. As shown, when ψ^n increases, the whole network gets enhanced. Drivers that were having good traffic performance are not affected by the multi-maps, but congested drivers acquire better routers to get to their destination. Specific congestions are cleared and overall travel-time increases. And, moreover, no mean router length is affected. Global metrics for gas emissions and noise are dramatically reduced.

4 Conclusions and future works

Studies and previous tests in reduced scenarios and with a random map generation, oriented to traffic balancing, have obtained satisfactory results leading to traffic indicators enhancements between 20% and 50%. Experiments conducted with ideal canonical traffic network show that multimap approach im-

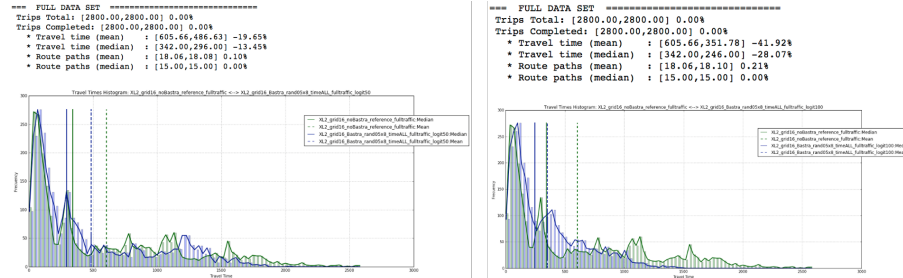


Fig. 5. Grid16-lanes. Congested network with $\psi_{0.5}^n$ and ψ_1^n .

proves highly global traffic travel-time, starting at low adoption scenarios, and providing best performance in high-adoption and highly congested situations.

The benefits of multimap approach include the following: 1) the possibility of automating early and real-time decision making for drivers and authorities, 2) generation of an integral model for the application of management and control policies, 3) can be offered as a service (SaaS model), 4) it is conceived as an evolutionary planning model, based in traffic feed back and learning cycles, 5) is non-intrusive and compatible with existing traffic management frameworks and traffic agents, 6) reuses existing data (Smart-Cities, OpenData) adding value over them, 7) is compatible with other existing algorithms and techniques, 8) drivers' agents autonomy and privacy is preserved as the multimap model takes into account individual freedom of route choice, 9) it allows for the articulation of contingency plans and the integration of traffic prognosis models.

MuTraff stands out from an innovative perspective in the following: a) it offers an integrated planning and re-planning model, extensible and open; b) it enables traffic categorization for application to very different groups and situations: electric vehicle, pay-to-drive and car-sharing fleets, commercial distribution, disabled people, pollutants, dangerous transport, routing due to weather, timetables, etc. c) It is replenished and self-learning.

Future TWM work will cover several directions: a) adding user-perspective for evaluation of TWM impact (non only global indicators) that will condition the adherence factor (revealed as critical); b) simulation on real cities scenarios; c) generation of hyper-paths based on TWM; d) design of a platform architecture for MuTraff real deployment and e) adding new simulation engines: microscopic and mesoscopic for fast TWM generation responding to real-time incidents. They will be accomplished in future research works.

References

1. Bazzan, A., Klügl, F.: A review on agent-based technology for traffic and transportation. *The Knowledge Engineering Review* **29**, 375–403 (2013). <https://doi.org/10.1017/S0269888913000118>

2. Bazzan, A.L., Klügl, F.: Introduction to Intelligent Systems in Traffic and Transportation. *Synthesis Lectures on Artificial Intelligence and Machine Learning* **7**(3), 1–137 (Dec 2013). <https://doi.org/10.2200/s00553ed1v01y201312aim025>, <http://www.morganclaypool.com/doi/abs/10.2200/S00553ED1V01Y201312AIM025>
3. Behrisch, M., Bieker, L., Erdmann, J., Krajzewicz, D.: SUMO - Simulation of Urban MObility: An Overview. In: Omerovic, S., U.o.O.A., Simoni, R.I.R.T.P.D.A., Bobashev, R.I.R.T.P.G. (eds.) *SIMUL 2011, The Third International Conference on Advances in System Simulation*. pp. 63–68. ThinkMind, Barcelona, Spain (Oct 2011), <http://elib.dlr.de/71460/>
4. Chen, Y., Bell, M.G., Bogenberger, K.: Reliable pretrip multipath planning and dynamic adaptation for a centralized road navigation system. *IEEE Transactions on Intelligent Transportation Systems* **8**(1), 14–20 (2007)
5. Claes, R., Holvoet, T.: Traffic Coordination Using Aggregation-Based Traffic Predictions. *Intelligent Systems, IEEE* **29**, 96–100 (2014). <https://doi.org/10.1109/MIS.2014.73>
6. Dell’Orco, M., Marinelli, M.: Modeling the dynamic effect of information on drivers’ choice behavior in the context of an Advanced Traveler Information System. *Transportation Research Part C Emerging Technologies* **85**, 168–183 (2017). <https://doi.org/10.1016/j.trc.2017.09.019>
7. Dere, E., Durdu, A.: Usage of the A* Algorithm to Find the Shortest Path in Transportation Systems (2018)
8. Dijkstra, E.: A Note on Two Problems in Connexion with Graphs. *Numb. Math.* **1** (1958)
9. Fukuda, D., Ma, J., Yamada, K., Shinkai, N.: Tokyo: Simulating Hyperpath-Based Vehicle Navigations and its Impact on Travel Time Reliability. In: *The Multi-Agent Transport Simulation MATSim*, pp. 517–522. Ubiquity Press Ltd (2016). <https://doi.org/10.5334/baw.92>, <https://www.oapen.org/download?type=document&docid=613715>
10. Gkoulalas-Divanis, A., Bettini, C.: *Handbook of Mobile Data Privacy* (2018). <https://doi.org/10.1007/978-3-319-98161-1>
11. Guleria, A.: Traffic Engineering in Software Defined Networks: A Survey. *Journal of Telecommunications and Information Technology* **4**, 3–14 (2016)
12. H, B.M.G.: Hyperstar: a multi-path astar algorithm for risk averse vehicle navigation. *Transportation Research Part B—Methodological* **43**, 97 (2009)
13. Hu, W., J Jin, P.: Dynamic Origin-Destination Estimation based on Time Delay Correlation Analysis on Location-based Social Network (LBSN) Data. In: *Transportation Research Board 97th Annual Meeting* (2018), <http://amonline.trb.org/>
14. Ibrahim, H., Far, B.H.: Data-oriented intelligent transportation systems. In: *Proceedings of the 2014 IEEE 15th International Conference on Information Reuse and Integration (IEEE IRI 2014)*. pp. 322–329 (Aug 2014). <https://doi.org/10.1109/IRI.2014.7051907>
15. Iqbal, M., Zhang, K., Iqbal, S., Tariq, I.: A Fast and Reliable Dijkstra Algorithm for Online Shortest Path. *International Journal of Computer Science and Engineering* **5**, 24–27 (2018). <https://doi.org/10.14445/23488387/IJCSE-V5I12P106>
16. Liang, Z., Wakahara, Y.: A route guidance system with personalized rerouting for reducing traveling time of vehicles in urban areas. *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)* pp. 1541–1548 (2014). <https://doi.org/10.1109/ITSC.2014.6957652>

17. Lin, S., Schutter, B.D., Zhou, Z., Xi, Y.: Multi-agent model-based predictive control for large-scale urban traffic networks using a serial scheme. *IET Control Theory & Applications* **9**(3), 475–484 (Feb 2015). <https://doi.org/10.1049/iet-cta.2014.0490>, <https://digital-library.theiet.org/content/journals/10.1049/iet-cta.2014.0490>
18. Luo, R., Bourdais, R., van den Boom, T.J., De Schutter, B.: Multi-agent model predictive control based on resource allocation coordination for a class of hybrid systems with limited information sharing. *Engineering Applications of Artificial Intelligence* **58**, 123–133 (Feb 2017). <https://doi.org/10.1016/j.engappai.2016.12.005>, <https://linkinghub.elsevier.com/retrieve/pii/S0952197616302330>
19. MA, J., FUKUDA, D.: A hyperpath-based network generalized extreme-value model for route choice under uncertainties. *Transportation Research Part C: Emerging Technologies* (2015)
20. Namazi-Rad, M.R., Padgham, L., Perez, P., Nagel, K., Bazzan, A.L.C. (eds.): *Agent Based Modelling of Urban Systems - First International Workshop, ABMUS 2016, Held in Conjunction with AAMAS, Singapore, Singapore, May 10, 2016, Revised, Selected, and Invited Papers, Lecture Notes in Computer Science*, vol. 10051. Springer (2017). <https://doi.org/10.1007/978-3-319-51957-9>, <https://doi.org/10.1007/978-3-319-51957-9>
21. Ortúzar, J.d.D., Willumsen, L.G.: *Modelling Transport*. John Wiley & Sons, 3rd edn. (2001)
22. Pan, J., Sandu Popa, I., Zeitouni, K., Borcea, C.: Proactive Vehicular Traffic Rerouting for Lower Travel Time. *Vehicular Technology, IEEE Transactions on* **62**, 3551–3568 (2013). <https://doi.org/10.1109/TVT.2013.2260422>
23. Rezaei, M., Noori, H., Rahbari, D., Nickray, M.: ReFOCUS: A hybrid fog-cloud based intelligent traffic re-routing system. In: *2017 IEEE 4th International Conference on Knowledge-Based Engineering and Innovation (KBEI)*. pp. 0992–0998 (Dec 2017). <https://doi.org/10.1109/KBEI.2017.8324943>, bibtex*[number=] ISSN:
24. Sagara, H., Tanimoto, J.: A study on social diffusive impacts of a novel car-navigation-system sharing individual information in Urban traffic systems. pp. 836 – 842. *IEEE Xplore* (2007). <https://doi.org/10.1109/CEC.2007.4424557>
25. Sarker, A., Shen, H., A. Stankovic, J.: MORP: Data-Driven Multi-Objective Route Planning and Optimization for Electric Vehicles. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* **1**, 1–35 (2018). <https://doi.org/10.1145/3161408>
26. Varga, L.: On Intention-Propagation-Based Prediction in Autonomously Self-Adapting Navigation. *Proceedings - 2014 IEEE 8th International Conference on Self-Adaptive and Self-Organizing Systems Workshops, SASOW 2014* **16**, 38–43 (2015). <https://doi.org/10.1109/SASOW.2014.17>
27. Weerdts, M., Stein, S., Gerding, E., Robu, V., R. Jennings, N.: Intention-Aware Routing of Electric Vehicles. *IEEE Transactions on Intelligent Transportation Systems* **17**, 1–11 (2015). <https://doi.org/10.1109/TITS.2015.2506900>
28. Zhe Cong, De Schutter, B., Burger, M., Babuska, R.: Monitoring of traffic networks using mobile sensors. In: *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*. pp. 792–797. IEEE, Qingdao, China (Oct 2014). <https://doi.org/10.1109/ITSC.2014.6957786>, <http://ieeexplore.ieee.org/document/6957786/>
29. Zheng, Y., Capra, L., Wolfson, O., Yang, H.: Urban Computing. *ACM Transactions on Intelligent Systems and Technology* **5**, 1–55 (2014). <https://doi.org/10.1145/2629592>

6.1.3. Relevancia de la publicación

Título	Multimap Routing for Road Traffic Management		
Autores	Paricio, A. y Lopez-Carmona M.A.		
Estado	Publicado	Fecha	15/jun/2019
DOI	publicación: https://doi.org/10.1007/978-3-030-24209-1_16		
Congreso	17th International Conference on Practical Applications of Agents and Multi-Agent Systems		
	URL	https://link.springer.com/conference/paams	
	Ávila, España. Junio 2019.		
Publicación	Nombre	LNCS - Lecture Notes in Computer Science Series Advances in Practical Applications of Survivable Agents and Multi-Agent Systems: The PAAMS Collection	
	URL	https://link.springer.com/conference/paams	
	Editorial	Springer Verlag	
	País	Alemania	
Relevancia	Revista (*)	Factor de Impacto:	1.17
		CiteScore	Q2 (95/221)
	Artículo	Lecturas:	80
		Citas:	0

(*)Lecture Notes in Computer Science is a book series covering the technologies/fields/categories related to Computer Science (miscellaneous) (Q2); Theoretical Computer Science (Q3). It is published by Springer Verlag. The overall rank of Lecture Notes in Computer Science is 14328. According to SCImago Journal Rank (SJR), this book series is ranked 0.283. LNCS has an h-index of 324. The best quartile for this book series is Q2.

Parte III

Conclusiones

El último capítulo de la tesis recoge la revisión de resultados y consecución de los objetivos reflejados en las publicaciones incluidas, así como una revisión de los casos de uso identificados inicialmente. Se incluye también la difusión científica de los resultados en publicaciones, congresos y contribuciones. Los trabajos realizados ofrecen prometedores resultados que podrán ser desarrollados en futuras líneas de investigación futuras identificadas que se relacionan en esta sección.

Como complemento a las conclusiones añaden varios apéndices que En el apéndice D se describen los productos y desarrollos generados para la parte experimental, y en el apéndice A los distintos escenarios y *datasets* generados.

7

Discusión y conclusiones

En esta sección se realiza una visión crítica de los resultados obtenidos tras los correspondientes trabajos de investigación. Dicha revisión comienza con el análisis de cumplimiento de los objetivos inicialmente planteados y una reflexión sobre la validez y aplicabilidad de los resultados. Posteriormente se comenta la difusión de los resultados en forma de publicaciones, ponencias, congresos, etc. No menos importante es la identificación de nuevas líneas de trabajo que se generan a raíz de la investigación realizada, que son expuestas en un epígrafe específico.

7.1. Revisión de los objetivos planteados

A la hora de revisar los resultados y conclusiones, debemos revisar inicialmente el grado de consecución de los objetivos abordados en la tesis:

1. Modelado, generación y distribución de TWM

Este modelo ha sido desarrollado en detalle en los trabajos [98, 99] siendo posteriormente enriquecido en los sucesivos trabajos publicados. TWM ha sido integrado en diferentes plataformas, como python y MatLab, y se ha demostrado su compatibilidad con simuladores microscópicos y macroscópicos. El modelo de mapas puede trabajar de forma sencilla con servidores de mapas estándares, como OpenStreetMaps [93], habiéndose generado un plataforma MuTraff de herramientas para su gestión.

El modelo es un aspecto básico necesario para el resto de la investigación.

2. Asignación dinámica de tráfico por diversificación de caminos mediante TWM aleatorizados:

El modelo de DTA empleando TWM ha sido desarrollado en el trabajo [98], donde se han aplicado numerosos experimentos de aleatorización de mapas para la reducción de los tiempos de viaje y por tanto de la congestión. Entre las conclusiones obtenidas se ha verificado que los mapas TWM aleatorizados generan la suficiente diversificación de caminos entre los vehículos de una red de tráfico urbana compleja como para mitigar entre un 20 % y un 40 % la congestión de tráfico. Estos resultados validan los objetivos inicialmente planteados. Obviamente, TWM funciona mejor en situaciones de redes congestionadas; en otros casos, sus resultados son menos apreciables ya que la diversificación de rutas es menos necesaria.

		Adherence		
		No TWM	50%	100%
ROUTED TRIPS	Trips planned	18694	18694	18694
	Trips routed	17895	18042	18447
	TWM enhancement		0.82%	3.08%
TRAVEL TIME	Mean	2169.13	1970.22	1744
	TWM enhancement		-9.17%	-19.60%
	Median	1297	1021	847
ROUTE LENGTH	Mean	48.19	48.96	49.11
	TWM enhancement		1.60%	1.91%
	Median	44	45	45
	TWM enhancement		2.27%	2.27%

Tabla 7.1.: Alcalá de Henares: mejora del enrutamiento usando TWM

De igual manera se ha identificado con claridad que la efectividad de TWM viene determinada en primer lugar por la adherencia de los vehículos al guiado mediante los multi-mapas, aunque esta es una característica común a cualquier sistema de optimización de tráfico. Adicionalmente, con niveles relativamente bajos de adherencia (a partir del 20% de los vehículos), el impacto de TWM comienza a ser muy relevante, por el efecto de liberación de rutas que generan los vehículos que toman las rutas alternativas TWM sobre los enlaces de las rutas convencionales. En la tabla 7.1 se muestran los resultados de mejora para el escenario de simulación de Alcalá de Henares para diversos niveles de adherencia. En ese mismo sentido, la figura 7.1 muestra la distribución de probabilidad de mejora del TTS en función de la adherencia, aumentando considerablemente la probabilidad de mejorar conforme aumenta la adherencia.

Asimismo se ha estudiado el efecto de las rutas malas para algunos conductores que ven empeorado su enrutamiento respecto a las condiciones originales. Este efecto requiere el estudio dinámico y evolutivo del modelo de experiencia que se trata en el artículo [2].




Figura 7.1.: Alcalá de Henares: probabilidad de mejora del TTS en función de la adherencia a TWM

3. Simulación microscópica de escenarios de uso de TWM

El objetivo es cubierto en las publicaciones [98, 99]. Dado que TWM es una propuesta novedosa no implementada en los sistemas ITS actuales o simuladores de tráfico existentes, se ha tenido que realizar la implementación de una *suite* completa de aplicaciones y herramientas para la generación, distribución y simulación de TWM. Este conjunto de herramientas se detalla en el apéndice D, teniendo especial importancia la herramienta *mutraff_simulator* para la integración de la simulación TWM con el simulador microscópico SUMO [76] y la herramienta *mutraff_simprofiler* que nos permite generar de forma sencilla configuraciones para los escenarios experimentales. La figura 7.2 muestra la arquitectura del simulador MuTraff.

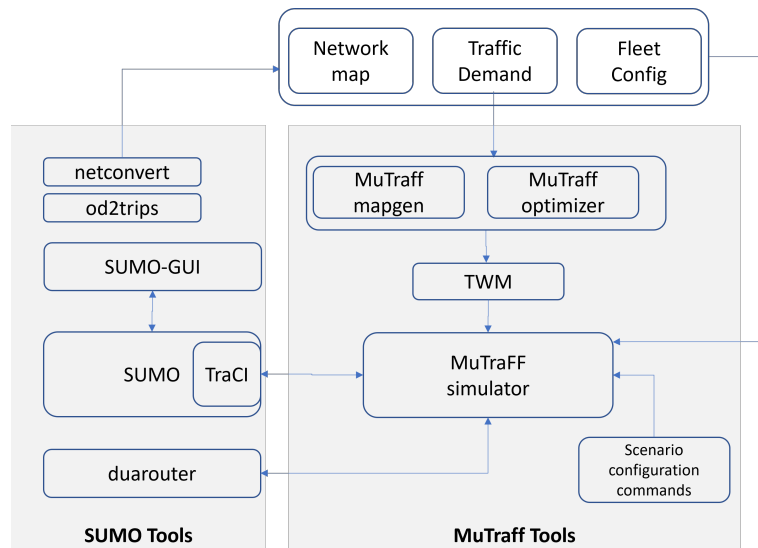


Figura 7.2.: Diagrama general de funcionamiento de *mutraff_simulator*

4. Asignación estática de tráfico mediante TWM optimizados: caracterización del óptimo del sistema

Este objetivo se cubra en la publicación [97]. TWM puede ser empleado tanto en la asignación dinámica de tráfico como en la asignación estática. La ventaja de la asignación estática estriba en la rapidez de obtención de una estimación del tiempo total de viaje de caso mejor. Esta característica es usada para dos propósitos principales: 1) evaluar de forma rápida la función de optimización en los algoritmos genéticos empleados, y 2) comparar la calidad de la solución obtenida con las estimaciones de asignación estática habituales. En ese sentido podemos comprobar cómo la asignación de TWM óptimos genera soluciones próximas al equilibrio de usuario (UE) calculado con otras aproximaciones.




Figura 7.3.: Alcalá de Henares: Comparativa absoluta y relativa de métodos de asignación estática incluyendo TWM

En la figura 7.3 se puede observar para el escenario de Madrid-Retiro el valor de TTS entregado por los métodos de asignación estática, en comparación con el escenario de referencia AON y comparando, asimismo, con el escenario de mapas TWM aleatorios. Vemos que la solución de TWM aleatorios mejora el TTS pero queda lejos del óptimo del sistema indicado por TWM y de las soluciones de equilibrio de usuario. Adicionalmente, vemos que la solución de SO aportada por TWM es muy próxima a los valores entregados por las estimaciones de equilibrio de usuario, ofreciendo por tanto una alternativa de calidad.

En el apartado de cálculo de las distribuciones de TWM óptimos, hemos visto que los algoritmos evolutivos nos ofrecen una solución viable para su cálculo, donde vemos que no todos los enlaces de la red contribuyen de igual manera a su rendimiento, e incluso algunos de dichos enlaces no contribuyen en

absoluto. En ese sentido, se han propuesto varios algoritmos GA para el cálculo que ofrecen un balance adecuado entre complejidad y eficiencia, manteniendo la calidad de la solución aportada.

5. Modelado de la experiencia de usuario en entornos complejos de múltiples ITS

Este modelado es cubierto en la publicación [2]. Ya hemos visto que en los entornos urbanos conviven numerosas propuestas de ITS y navegación personal que no están integradas entre sí, y que por tanto, el usuario debe considerar en el momento de la elección. Una de estas propuestas es TWM. Se ha definido un modelo de cálculo de la utilidad para el usuario con foco en el tiempo de viaje, empleando técnicas de razonamiento difuso. Una vez que se ha calculado la utilidad de las opciones disponibles, dado que el conductor debe realizar una elección independiente sobre ellas, se plantea un modelo de elección discreta sobre logit multinomial para obtener la decisión de elección entre las distintas opciones en función de su utilidad. El conjunto de variables y reglas difusos es específico del caso de uso seleccionado, pero el modelo de análisis es genérico, aplicable a cualquier otro problema expresado por su conjunto de variables y reglas por lo que es posible aplicarlo a otros problemas y escenarios de tráfico.

6. Dinámica de la adopción de TWM en sistemas complejos

El modelo de experiencia del conductor ante su toma de decisión de enrutamiento nos permite analizar el efecto de las rutas inciertas (*route unfairness*) descrito en la tesis, al poder dividir a los usuarios entre promotores, detractores y neutros en función de la experiencia que tienen al usar TWM. Esta dinámica es estudiada en la publicación [2]. El objetivo final es predecir la adherencia de los conductores en el tiempo a TWM y estudiar su modelo de convergencia. El modelo incluye un parámetro conductual importante en la toma de decisión: la resistencia al cambio. En la figura 7.4 podemos observar cómo evoluciona el sistema de tráfico en el tiempo, adoptando TWM de forma mayoritaria conforme los conductores descubren y valoran la aportación de TWM. El sistema evoluciona hacia niveles muy aceptables de adherencia al mismo superando con creces los umbrales mínimos requeridos por los modelos de asignación estática y dinámica de tráfico, y por tanto haciendo de TWM un sistema viable.




Figura 7.4.: Madrid-LasTablas: adherencia a TWM en el tiempo para diferentes niveles de resistencia al cambio

7.2. Discusión y conclusiones

La estrategia de enrutamiento mediante multi-mapas TWM es eminentemente una estrategia práctica, implementable en sistemas reales y compatible con los sistemas actuales. Proporciona una nueva manera de plantear el enrutamiento de tráfico urbano, actuando sobre los propios mapas que pueden ser entregados directamente a los sistemas de navegación de los vehículos o de los usuarios, y a otros ITS. Por este motivo la integración de TWM con otros sistemas es directa.

TWM ofrece una respuesta a numerosos casos de uso entre los que se encuentran la reducción de la congestión de tráfico, la respuesta dinámica a incidentes, el enrutamiento selectivo de flotas, la creación de zonas restringidas o penalizadas, el enrutamiento selectivo en el tiempo, la creación de rutas favorecidas (corredores), el enrutamiento de vehículos autónomos, el enrutamiento diferencial de vehículos eléctricos, y muchos otros escenarios.

Adicionalmente se plantean numerosas cuestiones. La primera de ellas es cuestionarse si distribuir la distribución de mapas diferentes a los usuarios de una red es ético desde el punto de vista de los conductores. Los detractores

podrían argumentar que sus mapas son «peores» que los de los promotores. Sin embargo, esto es similar a otras políticas que ya se usan en la gestión de tráfico: ¿por qué un semáforo penaliza más que otro? ¿por qué una vía tiene una restricción mayor que otra? ¿por qué está restringida la circulación a ciertos vehículos en ciertas áreas? Y la respuesta está en el propio modelo: el mapa de la red contiene una vista física y otra vista lógica que es un conjunto de políticas, restricciones, reglas y convenciones. TWM no hace sino añadir una dimensión nueva que es la multiplicidad de vistas lógicas de la misma naturaleza que los mecanismos mencionados.

La siguiente cuestión a plantear es la viabilidad de la propuesta TWM y la capacidad de ser desplegada en entornos heterogéneos y sobre aplicativos existentes. En este caso, la respuesta es mucho más directa, ya que absolutamente todos los sistemas de planificación de tráfico, de enrutamiento estático y dinámico, de navegación personal, emplean como información básica un mapa de la red. Y aquí es donde aparece TWM: TWM puede ser aportado como una plataforma de servidores de mapas, es decir, *Traffic-map-as-a-service* (TMaaS) donde en una nube de servicios (*cloud*) se implementen las políticas necesarias que sirvan para generar mapas TWM desplegables e integrables en otros aplicativos. Imaginemos algo parecido a un TWM-OpenStreetMaps ...

Podemos imaginar un futuro de gestión mixta público-privado de infraestructuras de tráfico urbano, similar al que se produce en otros mercados, donde empresas privadas realicen la gestión y planificación del tráfico urbano con criterios de optimización y de calidad. Servicios TMaaS como TWM serían cruciales para su desarrollo.

La aportación de TWM es significativa: mientras que los métodos de estimación de la asignación de tráfico en equilibrio están basados en modelos matemáticos, TWM está basado en un modelo práctico de generación y distribución de mapas, realizable y compatible con los sistemas existentes.

De la misma manera, el modelo de experiencia de usuario es generalista, muy flexible, que permite de forma directa la introducción de nuevas variables, reglas y criterios, así como el estudio de utilidad comparada con cualquier ITS. La tesis se ha enfocado a un modelo de utilidad centrado en el tiempo, pero podríamos generar modelos mixtos.

El origen de las reglas es un modelo ad-hoc adaptado al caso de uso de TWM en base a los comportamientos de promoción/detracción esperados. Este modelo debería ser generado desde un trabajo de campo previo basado en encuestas a la población de conductores y desde un trabajo comparativo de comportamientos en el tiempo. El objetivo de la investigación es el propio modelo de gestión BOID+S, que es general y permite añadir fácilmente nuevas reglas referidas a las variables difusas existentes o a nuevas adiciones.

8

Difusión de las contribuciones

Esta sección expone la difusión de las contribuciones realizadas durante el desarrollo de la tesis. En los capítulos 3, 4, 5 y 6 de la parte II de la tesis, se comentan e incluyen las publicaciones que de forma directa ha generado la tesis, y que pasamos a revisar desde el punto de vista de su contribución y difusión:

- **Urban Traffic Routing Using Weighted Multi-Map Strategies.** [98] Este artículo de revista (*IEEE Access*) desarrolla con detalle el mecanismo de enrutamiento mediante multi-mapas de tráfico TWM y se analiza el problema de la asignación dinámica de tráfico (DTA) aplicando diversificación de caminos mediante TWM básicos. Estos multi-mapas básicos son generados aleatorizando pesos. Asimismo se aborda el caso de uso de la respuesta dinámica a incidentes de tráfico. Se incluyen experimentos sobre redes reales urbanas de carácter extenso.

A. Paricio y M. A. Lopez-Carmona. «Urban traffic routing using weighted multi-map strategies». En *IEEE Access*, IEEE, 7:153086–153101, 2019.

- **Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment.** [97] Este artículo de revista (*IEEE Access*) desarrolla con detalle diversos algoritmos de generación de TWM óptimos para escenarios concretos de tráfico y analiza la calidad de la solución generada frente al óptimo del sistema, empleando para ello asignación estática de tráfico, y comparándose con otros algoritmos. El artículo muestra con detalle cómo aplicar diferentes estrategias basadas en algoritmos evolutivos a la generación de mapas TWM. Las estrategias son aplicadas inicialmente

sobre redes sintéticas para mayor claridad, para posteriormente aplicarse a redes urbanas reales para validar los resultados.

A. Paricio y M. A. Lopez-Carmona. «Application of traffic weighted Multi-Map optimization strategies to traffic assignment». *IEEE Access*, IEEE 9:28999–29019, 2021.

- **Modeling Driving Experience with Smart Traffic Routing Strategies: Application to Traffic Multimap Routing.** [2] Este artículo de revista (*IEEE Access*) propone un modelo de análisis de experiencia de usuario aplicado a los entornos reales de convivencia de múltiples ITS, mediante aplicación de técnicas de razonamiento difuso y teoría de elección discreta. El modelo se aplica al análisis de la adopción de TWM en el tiempo teniendo en cuenta un modelo de evaluación de la experiencia de usuario orientado a creencias, deseos, intenciones, restricciones e impactos social (BOID+S). La generalidad del modelo hace que sea aplicable a numerosos entornos de ITS. Al igual que en resto de publicaciones, el modelo inicialmente se aplica sobre redes sintéticas para mayor claridad y luego se extiende a redes urbanas reales para validar los resultados.

A. Paricio y M. A. Lopez-Carmona. «Modeling Driving Experience in Smart Traffic Routing Scenarios: Application to Traffic Multi-Map Routing». *IEEE Access*, IEEE, 9:90170–90184, 2021.

- **Multimap Routing for Road Traffic Management.** [99] En este artículo preliminar fue presentado en el congreso PAAMS'19 y posteriormente recogido en sus actas publicadas en LNCS (*Lecture Notes For Computer Science*). El artículo presentaba de forma introductoria el mecanismo básico de TWM como nueva propuesta de trabajo para enrutamiento de tráfico urbano, mostrando las ventajas que podría aportar para la gestión de la congestión. Los experimentos recogidos son relativos a redes sintéticas como demostradores de la propuesta.

A. Paricio y M. A. Lopez-Carmona. «Multimap Routing for Road Traffic Management». En *Advances in Practical Applications of Survivable Agents and Multi-Agent Systems: The PAAMS Collection*, volume 17th International Conference, PAAMS 2019. Lecture Notes in Computer Science. Springer International Publishing, Avila, Spain, 17th international conference, paams 2019, june 26–28, 2019, proceedings edition, June 2019.

Líneas de investigación futuras

La innovadora, original y sobre todo conceptualmente sencilla idea de la gestión del tráfico urbano mediante multi-mapas TWM, abre las puertas a numerosas propuestas en múltiples direcciones: la aplicación de TWM en múltiples casos de uso, la aplicación de TWM para diferentes aproximaciones de enrutamiento (centralizado, distribuido, mixto), nuevas propuestas de diseño de los mapas, nuevas propuestas de distribución de los mapas, y muchos otros ámbitos.

Desde el punto de vista de la aplicabilidad de multi-mapas TWM se abre la puerta a los estudios de aplicación para a numerosos escenarios:

1. Aplicación de TWM sobre diferentes tipologías de ITS, como servidor de mapas, para generar sus propuestas de planificación y enrutamiento de red. El ITS debe ser alimentado en cada momento por el TWM adecuado en función del caso de uso a gestionar entre los casos identificados. En realidad TWM es aplicable con independencia de la tipología del ITS ya que en todos los casos emplean mapas como fuente original de datos, y es éste el parámetro principalmente abordado por TWM.
2. Aplicación de TWM sobre los sistemas de navegación embarcados de los vehículos.
3. Aplicación de TWM sobre los sistemas de enrutamiento y navegación personales.
4. De especial interés resulta la aplicación de TWM sobre los sistemas de enrutamiento de vehículos autónomos, donde los ITS o los propios vehículos toman las decisiones de forma autónoma y se puede controlar

de forma sistemática uno de los parámetros críticos que hemos visto, como es la adherencia al sistema.

Desde el punto de vista del diseño y generación de multi-mapas TWM optimizados se identifican numerosas posibilidades:

5. Utilización de nuevos algoritmos de optimización de TWM para los entornos complejos de congestión. Los algoritmos genéticos son complejos y algo lentos, al buscar soluciones de forma extensa.
6. Sería muy interesante el diseño de TWM optimizando la reducción de la huella de carbono y emisión de contaminantes en las ciudades.
7. De la misma manera, parece muy atractiva la idea de aplicar TWM para la conducción de vehículos eléctricos en base a la optimización de su rendimiento y minimizar los momentos de recarga. Esta propuesta puede ser muy interesante para flotas estilo Uber o de car-sharing urbano.
8. Igualmente sería de interés la generación de mapas TWM optimizados que tuvieran en cuenta la precisión y predictibilidad del transporte público urbano.

Existen otras variantes al diseño de TWM actual que no se han abordado en la tesis:

9. Diseño de TWM óptimos basados en los flujos de demanda y no en los enlaces de la red.
10. Diseño de TWM aplicando *disjoint shortest-paths*.
11. En las funciones de evaluación del rendimiento se ha empleado hasta ahora asignación AON con multi-mapa, aunque sería más interesante generar asignaciones basadas en DTA por los mejores resultados que podrían aportar, a pesar de una mayor lentitud de los algoritmos.

Desde el punto de vista de la distribución de TWM, la tesis no ha desarrollado las diferentes alternativas de entrega: individual, grupal, V2V, por difusión etc. Especialmente interesante es este aspecto en distribución de mapas para

respuestas a incidentes y replanificaciones en tiempo real. Aquí se abre todo un espacio completo de investigación.

12. Algoritmos de distribución de TWM.

Desde el punto de vista del modelo de experiencia del usuario también encontramos múltiples posibilidades de futuros trabajos de investigación:

13. Modelos fuzzy de selección de TWM para otros casos de uso distintos a la congestión global.

14. Estudio y modelado del modelo de adopción de ITS para entornos mixtos de vehículos autónomos y tráfico estándar.

Parte IV

Referencias

Glosario de Términos y Acrónimos

AON *All-Or-Nothing*, método de cálculo aproximado de la asignación estática de tráfico mediante asignación directa bajo condiciones AONC.

AONC *All-Or-Nothing Conditions*, condiciones de planificación de los tiempos de viaje en una red cargada, sin tener en cuenta los impactos provocados por dicha carga.

AON-TT *All-Or-Nothing Travel Time*, tiempo de viaje de un vehículo bajo condiciones AONC.

BOID+S *Beliefs, Obligations, Intentions, Desires and Social Influence*, Creencias, Obligaciones, Intenciones, Deseos e Influencia Social.

BPR *Bureau of Public Roads, USA*.

BRUE *Boundedly Rational User Equilibrium*, principio de equilibrio de usuario con racionalidad limitada para asignación de tráfico.

CAM *Cummulative Assignment Method*, método de cálculo aproximado de la asignación estática de tráfico mediante tramos acumulativos.

CA *Congested Area*, porcentaje de área geográfica congestionada.

CDR *Congestion Delay Rate* tasa media de retraso por congestión.

CellEVAC *Cell-based Crowd Evacuation*

CGP *Cartesian Genetic Programming*, programación genética cartesiana.

DTA *Dynamic Traffic Assignment*, asignación dinámica de tráfico.

DTD *Dispatched Traffic Demand*, cantidad de demanda tráfico que ha completado su trayecto en un cierto intervalo de tiempo.

DUE *Dynamic User Equilibrium*, criterio de asignación dinámica de tráfico para el equilibrio de los usuarios de una red de tráfico.

- DVHC** *Daily Vehicle-Hours of Delay*, horas perdidas idariamente por congestión.
- FCC** *Individual relative consumption change*, mejora en el consumo de energía de un vehículo para un trayecto individual.
- FFC** *Free-Flow Conditions*, condiciones ideales de una red de tráfico sin carga, en la que los vehículos pueden circular a su máxima velocidad permitida sin paradas ni bloqueos.
- FF-TT** *Free-Flow Travel time*, tiempo de viaje de un vehículo bajo condiciones FFC.
- HBEFA** *Handbook Emission Factors for Road Transport*, Manual de factores de emisiones para el transporte por carretera.
- ITS** *Intelligent Transportation System*, sistemas de gestión y control inteligente del tráfico.
- KSP** *K-Shortest Paths*, conjunto de los K mejores caminos más cortos entre un origen y un destino.
- MFD** *Macroscopic Fundamental Diagrams*, diagramas macroscópicos fundamentales.
- MS** *Mean Speed*, velocidad media en la red.
- MSA** *Successive Averages Method*, método de cálculo aproximado de la asignación estática de tráfico mediante medias sucesivas.
- NHD** *Number of Halted Demand*, volumen de vehículos detenidos, con velocidad debajo de cierto umbral.
- NHL** *Number of Halted Links*, volumen de enlaces congestionados.
- OD,O/D** Tupla origen-destino que define el trayecto de un vehículo en una red de tráfico.

- OTTD(UE)** *Optimal Travel Time Deviation respect UE*, desviación del tiempo de tránsito respecto a T_{UE}
- OTTD(SO)** *Optimal Travel Time Deviation respect SO*, desviación del tiempo de tránsito respecto a T_{SO}
- PDTIC-UAH** Programa de Doctorado de Tecnologías de la Información y las Comunicaciones de la Universidad de Alcalá
- SO** *System Optimum*, criterio de asignación del tráfico para el óptimo del sistema.
- SUE** *Stochastic User Equilibrium*, criterio de asignación estocástica de tráfico para el equilibrio de los usuarios de una red de tráfico..
- SUMO** *Simulator of Urban Mobility*, simulador microscópico de código abierto.
- TAP** *Traffic Assignment Problem*, el problema de la asignación de tráfico.
- T_{AON}** *All-Or-Nothing Travel Time*, tiempo de tránsito sin considerar el estado y la ocupación de la red.
- TAZ** *Traffic Area Zones*, agrupación lógica de nodos y enlaces de la red de tráfico, habitualmente asociada a los orígenes y destinos de la demanda de tráfico.
- TCC** *Traffic under Congested Conditions*, condiciones de congestión de tráfico inaceptable.
- T_{FF}** *Free-Flow Travel Time*, tiempo de tránsito ideal en condiciones FFC.
- T_{ITS}** *ITS Travel Time*, tiempo de tránsito de un vehículo usando un ITS.
- THS** *Total Halting Time*, tiempo total en que la velocidad de los vehículos está por debajo de un cierto umbral.
- TLOC** *Traffic under Low-Occupation Conditions*, condiciones de tráfico en baja ocupación de la red.

- T_{LO}** *Travel time under Traffic under Low-Occupation Conditions*, condiciones de tráfico en baja ocupación de la red.
- TMS** *Traffic Map Server*, servidor de mapas de tráfico.
- TRACI** *Sumo Traffic Control Interface*, interfaz de control y gestión del simulador SUMO.
- TRB** *Transportation Research Board*.
- T_{SO}** *Traffic under System Optimum*, tiempo de tránsito en condiciones de óptimo del sistema.
- TTC** *Individual relative travel time*, mejora en el tiempo de tránsito individual.
- RLC** *Individual relative route length*, mejora en la distancia recorrida por un trayecto individual.
- TTI** *Travel Time Index*, índice de tiempo de tránsito que compara los tiempos de viaje reales con los tiempos bajo FFC.
- TTS** *Total Travel Time*, tiempo de tránsito acumulado (total) de todos los vehículos de una red de tráfico.
- TTT** *Travel Time Tax*, penalización en el tiempo de tránsito.
- T_{UE}** *Traffic under User Equilibrium*, tiempo de tránsito en condiciones de equilibrio de usuario.
- TWM** *Traffic Weighted Multi-Maps*, mapas de enrutamiento de tráfico por pesos.
- UE** *User Equilibrium*, criterio de asignación de tráfico para el equilibrio de los usuarios de una red de tráfico.
- V2I** Redes de comunicación vehiculares entre el vehículo y la infraestructura.
- V2V** Redes de comunicación vehiculares entre vehículos.

VANET Redes de comunicación vehiculares.

VKT,VMT *Total Distance Traveled*, distancia total recorrida por los vehículos de una red de tráfico en un cierto período de tiempo.

VTC Vehículos de transporte con conductor (flotas tipo Uber, Cabify y similares).

WLP *Wei's Linear Programming Method*, método de cálculo aproximado de la asignación estática de tráfico mediante programación lineal, propuesto por Wei et al .

Bibliografía

- [1] 9th DIMACS Implementation Challenge: Shortest Paths. <http://users.diag.uniroma1.it/challenge9/> (vid. pág. 237).
- [2] A. Paricio y M. A. Lopez-Carmona. “Modeling Driving Experience in Smart Traffic Routing Scenarios: Application to Traffic Multi-Map Routing”. En: *IEEE Access* 9 (2021), págs. 90170-90184 (vid. págs. XII, XVI, 36, 37, 183, 186, 192).
- [3] Hussein Abbass y Jason Scholz. “Foundations of Trusted Autonomy: An Introduction”. En: *Studies in Systems, Decision and Control*. Ene. de 2018, págs. 1-12 (vid. pág. 79).
- [4] Adam, Wears. *Smart Traffic Management: Technologies, Use Cases & Market Forecasts 2021-2025*. Inf. téc. Juniper Research, feb. de 2021 (vid. págs. XI, XV, 3).
- [5] Valentín Alberti Cuesta. “Tecnicas de Balanceo Del Trafico de Vehiculos Basadas En Mapas Dinamicos”. En: (2016). Ed. por Miguel Angel Lopez-Carmona y Universidad de Alcala Departamento de Automatica, 145 p. (Vid. pág. 44).
- [6] Vito Albino, Umberto Berardi y Rosa Dangelico. “Smart Cities: Definitions, Dimensions, Performance, and Initiatives”. En: *Journal of Urban Technology* 22 (feb. de 2015), pág. 2015 (vid. pág. 17).
- [7] Carlos Alos-Ferrer, Sabine Hugelschafer y Jiahui Li. “Inertia and Decision Making”. En: *Frontiers in Psychology* 7 (feb. de 2016) (vid. págs. 86, 143).
- [8] Foued Aloulou. “The Application of Discrete Choice Models in Transport”. En: nov. de 2018 (vid. págs. 29, 79, 142).
- [9] Mahyar Amirgholy, Nima Golshani, Craig Schneider, Eric Gonzales y H Oliver Gao. “An Advanced Traveler Navigation System Adapted to Route Choice Preferences of the Individual Users”. En: *International Journal of Transportation Science and Technology* 6 (oct. de 2017) (vid. pág. 29).
- [10] Yash Aneja y K.P. K. Nair. “The Constrained Shortest Path Problem”. En: *Naval Research Logistics Quarterly* 25 (sep. de 1978), págs. 549-555 (vid. pág. 8).
- [11] Enrico Angelelli, Valentina Morandi y M.Grazia Speranza. “Minimizing the Total Travel Time with Limited Unfairness in Traffic Networks”. En: *Computers & Operations Research* (jun. de 2020), pág. 105016 (vid. págs. XIII, XVII, 56, 78, 98, 142).
- [12] Anonymous. *Urban Mobility*. en. https://ec.europa.eu/transport/themes/urban/urban_mobility_en. Text. Sep. de 2016 (vid. pág. 17).

- [13] Sandhya Armoogum y Shevam Munchetty-Chendriah. “Using the MapReduce Approach for the Spatio-Temporal Data Analytics in Road Traffic Crowd-sensing Application: 13th International Conference, CollaborateCom 2017, Edinburgh, UK, December 11–13, 2017, Proceedings”. En: sep. de 2018, págs. 405-415 (vid. pág. 17).
- [14] Ana L. C. Bazzan, Daniel Cagara y Björn Scheuermann. “An Evolutionary Approach to Traffic Assignment”. En: *2014 IEEE Symposium on Computational Intelligence in Vehicles and Transportation Systems, CIVTS 2014, Orlando, FL, USA, December 9-12, 2014*. IEEE, 2014, págs. 43-50 (vid. págs. 15, 37, 66, 225, 227).
- [15] MJ Beckmann, C. McGuire y C Winston. *Studies in Economics of Transportation*. Vol. 26. Yale University Press, ene. de 1956 (vid. págs. 5, 13).
- [16] Michael Behrisch, Laura Bieker, Jakob Erdmann y Daniel Krajzewicz. “SUMO - Simulation of Urban MObility: An Overview”. En: *SIMUL 2011, The Third International Conference on Advances in System Simulation*. Ed. por SINTEF & University of Oslo Aida Omerovic, RTI International-Research Triangle Park Diglio A. Simoni y RTI International-Research Triangle Park Georgiy Bobashev. Barcelona, Spain: ThinkMind, oct. de 2011, págs. 63-68 (vid. págs. XIV, XVII, 99, 232, 236).
- [17] M. G. H. Bell. “Hyperstar: A Multi-Path Astar Algorithm for Risk Averse Vehicle Navigation”. En: *Transportation Research Part B—Methodological, Elsevier* 43 (2009), pág. 97 (vid. págs. 8, 17).
- [18] Moshe Ben-Akiva y Michel Bierlaire. “Discrete Choice Methods And Their Applications To Short Term Travel Decisions”. En: *Handbook of Transportation Science* 26 (feb. de 2000) (vid. págs. 29, 85, 142).
- [19] Moshe Ben-Akiva, Andre De Palma, Dainiel McFadden y col. “Process and Context in Choice Models”. En: *Marketing Letters* (2012) (vid. pág. 85).
- [20] Gianluca Bianchin y Fabio Pasqualetti. *Routing Apps May Cause Oscillatory Congestions in Traffic Networks*. Dic. de 2020, pág. 260 (vid. págs. 79, 162).
- [21] Laura Bieker. “Emergency Vehicle Prioritization Using Vehicle-To-Vehicle Communication”. En: *Young Researchers Seminar*. Jun. de 2011 (vid. pág. 16).
- [22] Mario Binetti, Marco Mitri y Michele Ottomanelli. “Analysis of Imprecise Perception in Route Choice Considering Fuzzy Costs”. En: *Advances in Intelligent Systems and Computing*. Switzerland: Springer, Cham, jul. de 2018, págs. 452-467 (vid. pág. 14).
- [23] Transportation Research Board. *Highway Capacity Manual, 6th Edition: A Guide for Multimodal Mobility Analysis*. 6th Ed. Washington, U.S.: The National Academies of Sciences, Engineering, and Medicine, 2016 (vid. pág. 9).
- [24] Celso Brennand, Allan Souza, Guilherme Maia y col. “An Intelligent Transportation System for Detection and Control of Congested Roads in Urban Centers”. En: jun. de 2015 (vid. pág. 16).

- [25] Jan Broersen, Mehdi Dastani, Joris Hulstijn, Zisheng Huang y Leendert van der Torre. "The BOID Architecture: Conflicts between Beliefs, Obligations, Intentions and Desires". En: *Proceedings of the Fifth International Conference on Autonomous Agents*. AGENTS '01. New York, NY, USA: Association for Computing Machinery, 2001, págs. 9-16 (vid. pág. 79).
- [26] R. M. Brown y H. H: Weaver. "Traffic Assignment Using IBM Computations and Summation". En: *Highway Research Board*. Highway Research Board Bulletin 130 (1956), págs. 47-58 (vid. pág. 11).
- [27] D Brownstone y David Hensher. "Discrete Choice Modelling for Transportation". En: ene. de 2001, págs. 97-124 (vid. pág. 29).
- [28] M. Bruton. "Introduction to Transportation Planning". En: London: Routledge, 1970 (vid. pág. 4).
- [29] Nam Bui Khac Hoai y Jason Jung. "ACO-Based Dynamic Decision Making for Connected Vehicles in IoT System". En: *IEEE Transactions on Industrial Informatics*. IEEE 15 (oct. de 2019), págs. 5648-5655 (vid. pág. 15).
- [30] M.E. Campbell y National Research Council (U.S.). Highway Research Board. *Route Selection and Traffic Assignment: A Compendium of Correspondence Relating to a Suggested Technique*. Highway Research Board, 1950 (vid. págs. 5, 11).
- [31] José Capela, Penousal Machado, Daniel Silva y Pedro Henriques Abreu. "An Inverted Ant Colony Optimization Approach to Traffic". En: *Engineering Applications of Artificial Intelligence*, Elsevier 36 (jul. de 2014), págs. 122-133 (vid. pág. 15).
- [32] Stefan Chanas, Waldemar Kolodziejczyk y Anna Machaj. "A Fuzzy Approach to the Transportation Problem. Fuzzy Sets and Systems". En: *Fuzzy Sets and Systems* 13 (ago. de 1984), págs. 211-221 (vid. pág. 14).
- [33] Yanyan Chen, Michael GH Bell y Klaus Bogenberger. "Reliable Pretrip Multipath Planning and Dynamic Adaptation for a Centralized Road Navigation System". En: *IEEE Transactions on Intelligent Transportation Systems* 8.1 (2007), págs. 14-20 (vid. pág. 17).
- [34] Dan Cheng, Olga Gkountouna, Andreas Züfle, Dieter Pfoser y Carola Wenk. "Shortest-Path Diversification through Network Penalization: A Washington DC Area Case Study". En: *12th ACM SIGSPATIAL International Workshop*. ACM, nov. de 2019, págs. 1-10 (vid. págs. 24, 162).
- [35] Camelia Chira y Ana Bazzan. "Route Assignment Using Multi-Objective Evolutionary Search". En: sep. de 2015, págs. 141-148 (vid. pág. 15).
- [36] Camelia Chira, Ana L. C. Bazzan y Rosaldo J. F. Rossetti. "Multi-Objective Evolutionary Traffic Assignment". En: *IEEE 18th International Conference on Intelligent Transportation Systems, ITSC 2015, Gran Canaria, Spain, September 15-18, 2015*. 2015, págs. 1177-1182 (vid. pág. 15).

- [37] Joseph Chow y Will Recker. *Informed Urban Transport Systems: Classic and Emerging Mobility Methods toward Smart Cities*. 1st. Elsevier, abr. de 2018 (vid. págs. 3, 4, 15, 52).
- [38] Jeffrey Cockburn, Anne Collins y Michael Frank. “A Reinforcement Learning Mechanism Responsible for the Valuation of Free Choice”. En: *Neuron* 83 (jul. de 2014) (vid. pág. 86).
- [39] L. Cruz-Piris, I. Marsa-Maestre y M. A. Lopez-Carmona. “A Variable-Length Chromosome Genetic Algorithm to Solve a Road Traffic Coordination Multipath Problem”. En: *IEEE Access* 7 (2019), págs. 111968-111981 (vid. pág. 16).
- [40] Luis Cruz-Piris, Miguel Lopez-Carmona e Ivan Marsa-Maestre. “Automated Optimization of Intersections Using a Genetic Algorithm”. En: *IEEE Access* PP (ene. de 2019), págs. 1-1 (vid. pág. 16).
- [41] C.F Daganzo e Y. Sheffi. “On Stochastic Models of Traffic Assignment”. En: *Transportation Science* 11.3 (ago. de 1977), págs. 253-274 (vid. págs. 7, 58).
- [42] Enrique de la Hoz, Ivan Marsa-Maestre y Miguel A. Lopez-Carmona. “Simulation of Coordinated Anticipatory Vehicle Routing Strategies on MATSim”. En: *Proceedings of the 14th International Conference on Agent Based Simulation for a Sustainable Society and Multi-Agent Smart Computing*. PRIMA'11. Berlin, Heidelberg: Springer-Verlag, 2012, págs. 90-108 (vid. pág. 16).
- [43] Philippe De Wilde. “Fuzzy Utility and Equilibria”. En: *IEEE transactions on systems, man, and cybernetics. Part B, Cybernetics : a publication of the IEEE Systems, Man, and Cybernetics Society* 34 (sep. de 2004), págs. 1774-85 (vid. pág. 142).
- [44] Nilanjan Dey y Sharvari Tamane. *Big Data Analytics for Smart and Connected Cities*. Sharvari Chandrashekhar Tamane’s Lab. GI Global, 2019. 1-348., mayo de 2018 (vid. pág. 17).
- [45] E.W. Dijkstra. “A Note on Two Problems in Connexion with Graphs”. En: *Numerische Mathematik* 1 (1959), págs. 269-271 (vid. págs. 8, 39).
- [46] *Distritos en cifras (Información de Barrios) - Ayuntamiento de Madrid*. es. <https://www.madrid.es/portales/munimadrid/es/Inicio/El-Ayuntamiento/Estadistica/Distritos-en-cifras> (vid. págs. 238, 241).
- [47] BPR Urban Planning Division. *Traffic Assignment Manual*. Washington D.C.: Bureau of Public Roads. U.S. Department of Commerce, 1964 (vid. págs. 10, 11).
- [48] Tali Eilam. “The Disjoint Shortest Paths Problem.” En: *Discrete Applied Mathematics, Elsevier* 85 (jun. de 1998), págs. 113-138 (vid. págs. 8, 71).
- [49] Sara El Hamdani y Nabil Benamar. “A Comprehensive Study of Intelligent Transportation System Architectures for Road Congestion Avoidance”. En: *Lecture Notes in Computer Science*. Springer-Verlag, nov. de 2017, págs. 95-106 (vid. pág. 162).

- [50] Hesham El-Sayed, Gokulnath Thandavarayan y Yaser Hawas. “A Cost Effective Route Guidance Method for Urban Areas Using Histograms”. En: *Wireless Communications and Mobile Computing 2017* (feb. de 2017) (vid. pág. 16).
- [51] *EMEP/EEA Air Pollutant Emission Inventory Guidebook 2019 — European Environment Agency*. en. <https://www.eea.europa.eu/publications/emep-eea-guidebook-2019>. Publication (vid. págs. 52, 222).
- [52] David Eppstein. “Finding the k Shortest Paths”. En: *SIAM Journal on Computing, ACM 28* (feb. de 1970) (vid. pág. 8).
- [53] Zeynep Erzurum Cicek y Zehra Kamisli Ozturk. “The Future of IoT and Big Data Analytics in Traffic Problems”. En: *Societal Complexity, Data Mining and Gaming State-of-the-Art 2017*. Greenhill & Waterfront, dic. de 2017 (vid. pág. 17).
- [54] ETSI. *ETSI EN 302 665 - Intelligent Transport Systems (ITS); Communications Architecture, v1.1.1*. English. Sep. de 2010 (vid. págs. 4, 15).
- [55] John Falcocchio y Herbert Levinson. *Road Traffic Congestion: A Concise Guide*. Vol. 7. Ene. de 2015 (vid. pág. 18).
- [56] Massilon Fernandes, Thiago Gomides, Fernanda Sumika Souza, Rodolfo Meneguetto y Daniel Guidoni. “A Traffic Management Service Based on V2I Communication for Vehicular Ad-Hoc Networks”. En: oct. de 2018, págs. 25-31 (vid. pág. 17).
- [57] Simon Fischer y Berthold Vöcking. *On the Evolution of Selfish Routing*. Vol. 3221. Sep. de 2004, pág. 334 (vid. pág. 14).
- [58] Terry Friesz, Javier Luque, Roger Tobin y Byung-Wook Wie. “Dynamic Network Traffic Assignment Considered as a Continuous Time Optimal Control Problem”. En: *Operations Research, JSTOR 37* (dic. de 1989), págs. 893-901 (vid. pág. 7).
- [59] Fu L.P y Rilett L.R. “Expected Shortest Paths in Dynamic and Stochastic Traffic Networks”. En: *Transportation Research Part B—Methodological 32* (1998), pág. 499 (vid. pág. 8).
- [60] Daisuke Fukuda, Jiangshan Ma, Kaoru Yamada y Norihito Shinkai. “Tokyo: Simulating Hyperpath-Based Vehicle Navigations and Its Impact on Travel Time Reliability”. En: *The Multi-Agent Transport Simulation MATSim*. Ubiquity Press Ltd, ago. de 2016, págs. 517-522 (vid. págs. 8, 17).
- [61] *Fuzzy Logic Toolbox*. es. <https://es.mathworks.com/products/fuzzy-logic.html> (vid. págs. 82, 94, 254).
- [62] Song Gao. “Modeling Strategic Route Choice and Real-Time Information Impacts in Stochastic and Time-Dependent Networks”. En: *Intelligent Transportation Systems, IEEE Transactions on 13* (sep. de 2012), págs. 1298-1311 (vid. pág. 58).

- [63] Posted 19 Sep 2019 | 15:00 GMT. *Your Navigation App Is Making Traffic Unmanageable - IEEE Spectrum*. en. <https://spectrum.ieee.org/computing/hardware/your-navigation-app-is-making-traffic-unmanageable> (vid. pág. 79).
- [64] Bin Guo, Zhu Wang, Zhiwen Yu y col. "Mobile Crowd Sensing and Computing: The Review of an Emerging Human-Powered Sensing Paradigm". En: *ACM Computing Surveys* 48 (ago. de 2015) (vid. pág. 17).
- [65] Hongliang Guo, Zhiguang Cao, Madhavan Seshadri y col. "Routing Multiple Vehicles Cooperatively: Minimizing Road Network Breakdown Probability". En: *IEEE Transactions on Emerging Topics in Computational Intelligence* 1 (abr. de 2017), págs. 112-124 (vid. págs. 14, 16).
- [66] Michael Haberl, Daniel Krajzewicz, Peter Wagner y col. "COLOMBO Deliverable 4.3: Pollutant Emission Models and Optimisation". En: (feb. de 2015) (vid. pág. 52).
- [67] P.E. Hart, N. J. Nilsson y B. Raphael. "A Formal Basis for the Heuristic Determination of Minimum Cost Paths". En: *IEEE Transactions on Systems Science and Cybernetics* 4.2 (jul. de 1968), págs. 100-107 (vid. pág. 8).
- [68] *HBEFA - Handbook Emission Factors for Road Transport. V4.1*. <https://www.hbefa.net/>. 2019 (vid. págs. 52, 222).
- [69] H. Ibrahim y B. H. Far. "Data-Oriented Intelligent Transportation Systems". En: *Proceedings of the 2014 IEEE 15th International Conference on Information Reuse and Integration (IEEE IRI 2014)*. Ago. de 2014, págs. 322-329 (vid. pág. 17).
- [70] *INE. Instituto Nacional de Estadística*. es. <https://www.ine.es/> (vid. pág. 243).
- [71] Takahiro Koita y Shota Suzuki. "Crowdsourcing and Its Application for Traffic Survey Work". En: *4th IEEE International Conference on Big Data Analytics. IEEE Xplore*, mar. de 2019, págs. 375-378 (vid. pág. 17).
- [72] G Kotusevski y Ken Hawick. "A Review of Traffic Simulation Software". En: *Res. Lett. Inf. Math. Sci.* 13 (ago. de 2009) (vid. pág. 249).
- [73] Daniel Krajzewicz, Stefan Hausberger, Peter Wagner, Michael Behrisch y Mario Krumnow. "Second Generation of Pollutant Emission Models for SUMO". En: vol. 13. *Lecture Notes in Control and Information Sciences*. Mayo de 2014 (vid. pág. 52).
- [74] Reinhardt L.B y Pisinger D. "Multicriteria and Multi-Constrained Non-Additive Shortest Path Problems". En: *Computers & Operations Research, ACM* 38 (2011), pág. 605 (vid. págs. 8, 17).
- [75] T Lomax, S. Turnber y G. Shunk. *Quantifying Congestion, Volume 1. Final Report*. Inf. téc. 398. Washington D.C., USA: Transportation Research Board, 1997 (vid. págs. 18, 38).

- [76] Pablo Alvarez Lopez, Michael Behrisch, Laura Bieker-Walz y col. “Microscopic Traffic Simulation Using SUMO”. En: *The 21st IEEE International Conference on Intelligent Transportation Systems*. IEEE Intelligent Transportation Systems Conference (ITSC). IEEE, 2018 (vid. págs. 93, 183, 250, 262).
- [77] Yingyan Lou, Yafeng Yin y Siriphong Lawphongpanich. “Robust Congestion Pricing under Boundedly Rational User Equilibrium”. En: *Transportation Research Part B: Methodological* 44 (ene. de 2010), págs. 15-28 (vid. págs. 7, 14).
- [78] Jiangshan MA y Daisuke FUKUDA. “A Hyperpath-Based Network Generalized Extreme-Value Model for Route Choice under Uncertainties”. En: *Transportation Research Part C: Emerging Technologies* (2015) (vid. pág. 17).
- [79] Jiangshan Ma, Daisuke Fukuda y J.-D. Schmocker. “Faster Hyperpath Generating Algorithms for Vehicle Navigation”. En: *Transportmetrica* (2013) (vid. pág. 8).
- [80] Jiangshan Ma, Daisuke Fukuda y Jan-Dirk Schmöcker. “Faster Hyperpath Generating Algorithms for Vehicle Navigation”. En: *Transportmetrica* 149 (ene. de 2012), págs. 1-24 (vid. pág. 17).
- [81] *Madrid Traces*. <http://www.it.uc3m.es/madrid-traces/> (vid. pág. 237).
- [82] Mamta Mahiya y C K. “Urban Computing: Key Challenges and Issues of Traffic Management System”. En: *International Journal of Computer Applications* 179 (mar. de 2018), págs. 18-21 (vid. pág. 17).
- [83] Gilberto Marzano y Velta Lubkina. “CityBook: A Mobile Crowdsourcing and Crowdsensing Platform”. En: ene. de 2020, págs. 420-431 (vid. pág. 17).
- [84] *MatLab - Genetic Algorithm Options - MATLAB & Simulink - MathWorks España*. Accessed: Sep.2020 [Online]. <https://es.mathworks.com/help/gads/genetic-algorithm-options.html#f6633> (vid. págs. 65, 254).
- [85] *MatLab - Genetic Algorithms*. Accessed: Sep.2020 [Online]. es. <https://mathworks.com/discovery/genetic-algorithm.html> (vid. pág. 94).
- [86] *MatLab (R2019b) - MATLAB and Simulink product families update*. Accessed: Sep.2020 [Online]. es. https://mathworks.com/products/new_products/release2019b.html (vid. págs. 94, 238, 241, 244, 254).
- [87] D McFadden y P E. Zarembka. “Conditional Logit Analysis of Qualitative Choice Behaviour”. En: *Frontiers in Econometrics*. Ene. de 1974, págs. 105-142 (vid. pág. 86).
- [88] Giorgos Mellios, Stefan Hausberger, Mario Keller y col. *Parameterisation of Fuel Consumption and CO2 Emissions of Passenger Cars and Light Commercial Vehicles for Modelling Purposes*. en. Vol. The European Commission’s science and knowledge service. EU SCIENCE HUB. Luxembourg: Publications Office - EUROPEAN COMMISSION, 2009 (vid. pág. 52).

- [89] Rodolfo Meneguette, Geraldo Filho, Luiz Fernando Bittencourt y col. “Enhancing Intelligence in Inter-Vehicle Communications to Detect and Reduce Congestion in Urban Centers”. En: jun. de 2015 (vid. pág. 16).
- [90] *Models/Emissions/PHEMlight - Sumo*. <https://sumo.dlr.de/wiki/Models/Emissions/PHEMlight> (vid. pág. 52).
- [91] Mohammad R. NamaziRad, Lin Padgham, Pascal Perez, Kai Nagel y Ana L. C. Bazzan, eds. *Agent Based Modelling of Urban Systems - First International Workshop, ABMUS 2016, Held in Conjunction with AAMAS, Singapore, Singapore, May 10, 2016, Revised, Selected, and Invited Papers*. Vol. 10051. Lecture Notes in Computer Science. Springer, 2017 (vid. pág. 161).
- [92] Lars Relund Nielsen, Kim Allan Andersen y Daniele Pretolani. “Finding the K Shortest Hyperpaths”. English. En: *Computers and Operations Research* 32.6 (2005), págs. 1477-1497 (vid. pág. 17).
- [93] *OpenStreetMa*. Accessed: Sep.2020. [Online]. <https://www.openstreetmap.org> (vid. págs. 181, 237, 238, 241, 244, 266).
- [94] Juan de Dios Ortuzar y Luis G. Willumsen. *Modelling Transport*. 3rd. John Wiley & Sons, 2001 (vid. págs. 3, 4, 10, 37, 52, 79, 85, 118, 225, 227).
- [95] Jane Pan, Iulian Popa y Cristian Borcea. “DIVERT: A Distributed Vehicular Traffic Re-Routing System for Congestion Avoidance”. En: *IEEE Transactions on Mobile Computing* 16 (ene. de 2016), págs. 1-1 (vid. pág. 16).
- [96] Jane Pan, Iulian Sandu Popa, Karine Zeitouni y Cristian Borcea. “Proactive Vehicular Traffic Rerouting for Lower Travel Time”. En: *Vehicular Technology, IEEE Transactions on, IEEE* 62 (oct. de 2013), págs. 3551-3568 (vid. pág. 16).
- [97] A. Paricio y M. A. Lopez-Carmona. “Application of Traffic Weighted Multi-Map Optimization Strategies to Traffic Assignment”. En: *IEEE Access* 9 (2021), págs. 28999-29019 (vid. págs. XII, XVI, 36, 37, 184, 191).
- [98] A. Paricio y M. A. Lopez-Carmona. “Urban Traffic Routing Using Weighted Multi-Map Strategies”. En: *IEEE Access, IEEE* 7 (2019), págs. 153086-153101 (vid. págs. XII, XVI, 36, 37, 162, 181-183, 191, 233, 236).
- [99] Alvaro Paricio y Miguel A. Lopez-Carmona. “Multimap Routing for Road Traffic Management”. En: *Advances in Practical Applications of Survivable Agents and Multi-Agent Systems: The PAAMS Collection*. 17th International Conference, PAAMS 2019, June 26–28, 2019, Proceedings. Vol. 17th International Conference, PAAMS 2019. Lecture Notes in Computer Science. Avila, Spain: Springer International Publishing, jun. de 2019 (vid. págs. XII, XVI, 32, 98, 181, 183, 192, 233, 234, 236, 237).
- [100] Michael Patriksson. *The Traffic Assignment Problem: Models and Methods*. Dover Publications Inc. NY, feb. de 2015 (vid. págs. XI, XV, 5, 117).
- [101] Andreas Pell, Andreas Meingast y Oliver Schauer. “Trends in Real-Time Traffic Simulation”. En: *Transportation Research Procedia* 25 (dic. de 2017), págs. 1477-1484 (vid. pág. 249).

- [102] Olga Petrik, Filipe Moura y Joao de Abreu e Silva. "The Influence of the Volume-Delay Function on Uncertainty Assessment for a Four-Step Model". En: *Advances in Intelligent Systems and Computing* 262 (nov. de 2014), págs. 293-306 (vid. pág. 10).
- [103] Agata Quattrone y Antonino Vitetta. "Random and Fuzzy Utility Models for Road Route Choice". En: *Transportation Research Part E-logistics and Transportation Review - TRANSP RES PT E-LOGIST TRANSP* 47 (nov. de 2011), págs. 1126-1139 (vid. págs. 14, 142).
- [104] Giselle Ramos, Winnie Daamen y Serge Hoogendoorn. "A State-of-the-Art Review: Developments in Utility Theory, Prospect Theory and Regret Theory to Investigate Travellers' Behaviour in Situations Involving Travel Time Uncertainty". En: *Transport Reviews* 34 (feb. de 2014) (vid. pág. 142).
- [105] Arpita Ray, Sakil Mallick, Sukanta Mondal y col. "A Framework for Mobile Crowd Sensing and Computing Based Systems". En: *IEEE International Conference on Advanced Networks and Telecommunications Systems (ANTS)*. IEEE Computer Society, dic. de 2018, págs. 1-6 (vid. pág. 17).
- [106] Lars Relund Nielsen, Kim Andersen y Daniele Pretolani. "Finding the K Shortest Hyperpaths". En: *Computers & Operations Research* 32 (jun. de 2005), págs. 1477-1497 (vid. pág. 8).
- [107] A. Rosenbaum. *Evaluation of Modeling Tools for Assessing Land Use Policies and Strategies*. USA: U.S. Environmental Protection Agency, Air and Radiation, Office of Mobile Sources, 1997 (vid. pág. 4).
- [108] Tim Roughgarden. "How Unfair Is Optimal Routing?" En: *Proceedings of the 13th Annual ACM-SIAM Symposium on Discrete Algorithms (SODA)* (nov. de 2001), págs. 203-204 (vid. págs. XIII, XVII, 56, 78, 98, 142).
- [109] Ammar Saric, Sanjin Albinovic, Suada Dzebo y Mirza Pozder. "M Proceedings of the International Symposium on Innovative and Interdisciplinary Applications of Advanced Technologies (IAT), Volume 2". En: *Advanced Technologies, Systems, and Applications III*. Springer, ene. de 2019, págs. 3-12 (vid. pág. 10).
- [110] Ankur Sarker, Haiying Shen y John A. Stankovic. "MORP: Data-Driven Multi-Objective Route Planning and Optimization for Electric Vehicles". En: *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* 1 (ene. de 2018), págs. 1-35 (vid. pág. 17).
- [111] Andreas Schulz y Nicolas Stier-Moses. "Efficiency and Fairness of System-Optimal Routing with User Constraints". En: *Networks* 48 (dic. de 2006), págs. 223-234 (vid. pág. 78).
- [112] Kaveh Shafiee, Jinwoo Brian Lee, Victor Leung y Garland Chow. "Modeling and Simulation of Vehicular Networks". En: (nov. de 2011) (vid. pág. 249).
- [113] Yossi Sheffi. *Urban Transportation Networks: Equilibrium Analysis with Mathematical Programming Methods*. Prentice-Hall, ene. de 1984 (vid. págs. 4, 5, 52, 117).

- [114] Deepinder Sidhu, Raj Nair y Shukri Abdallah. "Finding Disjoint Paths in Networks." En: *SIGCOMM '91: Proceedings of the Conference on Communications Architecture & Protocols*. Vol. 21. Computer Communication Review - CCR. ACM, ago. de 1991, págs. 43-51 (vid. págs. 8, 71).
- [115] *Simplified Highway Capacity Calculation Method - Table of Contents - Policy* | Federal Highway Administration. <https://www.fhwa.dot.gov/policyinformation/pubs/pl18003/chapter1> (vid. pág. 9).
- [116] Jaehyun So, Nassim Motamedidehkordi, Yingjie Wu, Fritz Busch y Keechoo Choi. "Estimating Emissions Based on the Integration of Microscopic Traffic Simulation and Vehicle Dynamics Model". En: *International Journal of Sustainable Transportation* 12 (ago. de 2017), págs. 286-298 (vid. pág. 52).
- [117] Allan Souza, Nelson Fonseca y Leandro Villas. "A Fully-Distributed Advanced Traffic Management System Based on Opportunistic Content Sharing". En: mayo de 2017 (vid. pág. 17).
- [118] Allan Souza, Roberto Yokoyama, Guilherme Maia, Antonio Loureiro y Leandro Villas. "Real-Time Path Planning to Prevent Traffic Jam through an Intelligent Transportation System". En: jun. de 2016, págs. 726-731 (vid. pág. 16).
- [119] Heinz Spiess. "Conical Volume-Delay Functions". En: *Transportation Science* 24 (mayo de 1990), págs. 153-158 (vid. pág. 10).
- [120] Fernando Stefanello, Luciana Buriol, M. Hirsch y col. "On the Minimization of Traffic Congestion in Road Networks with Tolls". En: *Annals of Operations Research, JSTOR* (feb. de 2017), págs. 1-21 (vid. pág. 14).
- [121] Daniel H. Stolfi y Enrique Alba. "Smart Mobility Policies with Evolutionary Algorithms: The Adapting Info Panel Case". En: jul. de 2015 (vid. págs. 15, 17).
- [122] W. Szeto y Shuai Wang. "Dynamic Traffic Assignment: Model Classifications and Recent Advances in Travel Choice Principles". En: *Central European Journal of Engineering, Springer* 2 (mar. de 2011) (vid. págs. 8, 11, 13, 14).
- [123] *TAPASCologne - SUMO Documentation*. en. <https://sumo.dlr.de/docs/Data/Scenarios/TAPASCologne> (vid. págs. 237, 238).
- [124] Dusan Teodorovic y S. Kikuchi. "Transportation Route Choice Model Using Fuzzy Inference Technique". En: *Proceedings of ISUMA'90, The First International Symposium on Uncertainty Modeling and Analysis*. IEEE, ene. de 1991, págs. 140-145 (vid. pág. 14).
- [125] *TraCI - SUMO Documentation*. en. <https://sumo.dlr.de/docs/TraCI.html> (vid. págs. 262, 263).
- [126] Fitri Trapsilawati, Titis Wijayanto y Eggie Jourdy. "Human-Computer Trust in Navigation Systems: Google Maps vs Waze". En: *Communications in Science and Technology* 4 (jul. de 2019), págs. 38-43 (vid. págs. 58, 79, 143).
- [127] European Union. *Clean Transport, Urban Transport: Urban Mobility*. en. <https://ec.europa.eu/>. Text. Sep. de 2016 (vid. págs. xi, xv, 3, 4).

- [128] Univerisdad de Alcala. *Guía para la elaboración y la defensa de la Tesis Doctoral*. es. https://escuela-doctorado.uah.es/tesis/documentos/guia_tesis.pdf (vid. pág. 30).
- [129] Jelmer van Ast, Robert Babuška y Bart De Schutter. “Particle Swarms in Optimization and Control”. En: *IFAC Proceedings Volumes* 41.2 (2008), págs. 5131-5136 (vid. pág. 65).
- [130] Mariska van Essen, Tom Thomas, Eric van Berkum y Caspar Chorus. “From User Equilibrium to System Optimum: A Literature Review on the Role of Travel Information, Bounded Rationality and Non-Selfish Behaviour at the Network and Individual Levels”. En: *Transport Reviews* 36 (ene. de 2016), págs. 1-22 (vid. pág. 7).
- [131] Shen Wang, Soufiene Djahel, Zonghua Zhang y Jennifer Mcmanis. “Next Road Rerouting: A Multiagent System for Mitigating Unexpected Urban Traffic Congestion”. En: *IEEE Transactions on Intelligent Transportation Systems* 17 (mar. de 2016), págs. 1-12 (vid. pág. 16).
- [132] J Wardrop y J Whitehead. “Correspondence. Some Theoretical Aspects of Road Traffic Research”. En: *Proceedings of the Institution of Civil Engineers, ICE Virtual Library* 1 (ene. de 1952), págs. 767-768 (vid. págs. 6, 117).
- [133] Wei Wei, Longxian Hu, Qiuwei Wu y Tao Ding. “Efficient Computation of User Optimal Traffic Assignment via Second-Order Cone and Linear Programming Techniques”. En: *IEEE Access, IEEE PP* (sep. de 2019), págs. 1-1 (vid. págs. 13, 118, 268).
- [134] *weplan-analytics-corporate*. es-ES. /es (vid. págs. 238, 272).
- [135] Jin Yen. “Finding the k Shortest Loopless Paths in a Network”. En: *Management Science, JSTOR* 17 (ene. de 1970), págs. 712-716 (vid. pág. 8).
- [136] Biao Yu, Yingwen Chen, Shaojing Fu, Wanrong Yu y Xiaoli Guo. “Building Trustful Crowdsensing Service on the Edge”. En: *International Conference on Wireless Algorithms, Systems, and Applications, WASA2019*. Springer, jun. de 2019, págs. 445-457 (vid. pág. 17).
- [137] Yu Zheng, Licia Capra, Ouri Wolfson y Hai Yang. “Urban Computing”. En: *ACM Transactions on Intelligent Systems and Technology* 5 (sep. de 2014), págs. 1-55 (vid. pág. 162).

Parte V

Apendices

En los siguientes apéndices recogemos algunos de los detalles que amplían parcialmente y sustentan el contenido expuesto anteriormente. Dada la extensión de los trabajos y su naturaleza de compendio de publicaciones, resulta inviable desarrollar en profundidad cada uno de los aspectos tratados por la extensión del contenido. No obstante confiamos en dar una visión completa de los mismos.

Así, para el desarrollo de la parte experimental que avala los resultados de la tesis, se han empleado diversos tipos de simuladores y escenarios de redes tráfico vehicular, con datos sintéticos basados en datos reales. Los datos reales que se han empleado proceden tanto de fuentes abiertas como de cesion de datos basados en *crowd-sensing*. El uso de simuladores se hace imprescindible por la dificultad de desplegar sistemas reales de gestión de tráfico con propuestas experimentales, siendo además, una práctica estándar y habitual no sólo en la investigación en el área sino también en su aplicación real, tal y como se ha comentado en la introducción conceptual de la tesis.

- El primer apéndice detalla parcialmente los escenarios de tráfico considerados, tanto en la descripción de las propias redes sobre las que se construirán los mapas, como en las demandas de tráfico de los distintos escenarios desarrollados sobre ellas.
- El segundo apéndice enumera las herramientas y recursos de investigación empleados en la tesis. Entre las herramientas contemplaremos específicamente los simuladores de tráfico empleados.
- El tercer apéndice incluye el detalle de las reglas de comportamiento *fuzzy* empleadas en el modelo de experiencia de usuario en la adopción de TWM.
- El cuarto apéndice relaciona el conjunto de desarrollos generados durante la realización de la investigación.
- El quinto y último apéndice incluye una breve introducción a la adquisición de datos de *crowd-sensing* y al *data-set* privado donado para la investigación.

A

Escenarios de análisis

Para el desarrollo de la parte experimental que avala los resultados de la tesis, se han empleado diversos tipos de simuladores y escenarios de redes tráfico vehicular, con datos sintéticos basados en datos reales. Los datos reales que se han empleado proceden tanto de fuentes abiertas como de cesión de datos basados en aplicaciones de *crowd-sensing*. El uso de simuladores se hace imprescindible por la dificultad de desplegar sistemas reales de gestión de tráfico con propuestas experimentales, siendo además, una práctica estándar y habitual no sólo en la investigación en el área sino también en su aplicación real.

A la hora de establecer los flujos de tráfico se definen normalmente áreas de origen o destino del mismo (*Traffic Area Zones*, TAZ), asignando a cada área un cierto conjunto de nodos. Así se puede establecer un flujo de tráfico entre TAZ o entre nodos concretos.

En los diferentes escenarios se han contemplado dos tipologías de tráfico superpuesto:

- Flujos de tráfico entre TAZ o entre nodos, indicando su direccionalidad. Estos flujos hacen referencia a los patrones de comportamiento observables en los datos extraídos de las redes.
- Tráfico de fondo, normalmente modelado como un tráfico aleatorio.

En un epígrafe inicial se comentan los grupos de tráfico configurados (denominados flotas) y sus criterios de agrupación. Tras él, se presentan los escenarios de tráfico ordenados por complejidad creciente. Inicialmente se presentan los escenarios de tráfico sobre redes sintéticas, que nos permiten modelar de forma

sencilla los casos de uso a resolver, desacoplándolos de los efectos propios derivados de la no-uniformidad de las redes de tráfico reales. Posteriormente, se muestran los escenarios de redes de tráfico reales empleados, igualmente en orden de complejidad creciente.

En la Tabla A.1 se muestra un resumen de los diferentes escenarios contemplados, su complejidad medida en número de nodos y enlaces en la red, y la tipología de experimentos realizados en ellos junto al tipo de simulación empleado.

Escenario	Categoría	#Nodos	#Enlaces	TWM Aleatorios	TWM Óptimos	Evolución TWM
Ortúzar-Willumsen	Sintético	13	48	Microscópico		
Paricio-LópezCarmona	Sintético	21	91	Microscópico		
Grid-64	Sintético	64	224	Microscópico	Macroscópico	Macroscópico
Grid-256	Sintético	256	960	Microscópico		
Radial-241	Sintético	241	992	Microscópico		
Madrid-Retiro	Red urbana	191	259		Macroscópico	
Madrid-LasTablas	Red urbana	971	1583		Macroscópico	Macroscópico
Alcalá de Henares	Red urbana	4150	7830	Microscópico		

Tabla A.1.: Resumen de escenarios, complejidad y tipología de simulación.

Tipología de los vehículos

En los estándares europeos de gestión de emisiones [68, 51] se establecen diversas categorías de vehículos por sus emisiones. Los diferentes grupos de vehículos considerados se han establecido considerando su clasificación de emisiones y su uso, con el objetivo de diseñar experimentos basados en enrutamientos diferenciales, y permitir medir y optimizar los niveles de consumos y emisión.

Grupo	Clasificación emisiones	Clase SUMO	Peso	Descripción
g-car	HBEFA3/PC_G_EU4	passenger	15 %	Turismo gasolina
d-car	HBEFA3/LDV_D_EU4	passenger	15 %	Turismo diesel
motorcycle	HBEFA3/PC_G_EU4	motorcycle	10 %	Motocicleta
d-delivery	HBEFA3/LDV_D_EU5	delivery	10 %	Furgoneta de reparto
d-taxi	HBEFA3/LDV_D_EU4	taxi	10 %	Taxi diesel
bus	HBEFA3/bus	bus	10 %	Autobus diesel
e-car	zero	evehicle	10 %	Turismo eléctrico
coach	HBEFA3/Coach	coach	0 %	Autocar
d-vtc	HBEFA3/LDV_D_EU4	passenger	5 %	Vehículo de flota diesel
e-vtc	zero	evehicle	5 %	Vehículo de flota eléctrico
emergency	HBEFA3/bus	emergency	0 %	Ambulancia
firemen	HBEFA3/bus	emergency	5 %	Bomberos
policemen	HBEFA3/PC_G_EU4	emergency	5 %	Policía
school-bus	HBEFA3/bus	bus	0 %	Autobus escolar
school-car	HBEFA3/PC_G_EU4	passenger	0 %	Turismo reparto escolar

Tabla A.2.: Agrupaciones de vehículos usados en los escenarios

Para la distribución del tráfico en los experimentos, empleamos la distribución de grupos de tráfico que se describen en la Tabla A.2 y en la Figura A.1. Los grupos se definen mediante la combinación de tipologías de consumo junto a clasificación por uso. Numerosos nuevos grupos podrían ser definidos y configurados, aunque quedan fuera del alcance de esta tesis que se centra en la propuesta de los mapas de pesos de tráfico.




Figura A.1.: Distribución porcentual de la demanda de tráfico en los experimentos

En algunos experimentos se han empleado distribuciones simplificadas de grupos de tráfico como la indicada en la Tabla A.3:

Grupo	Clasificación emisiones	Clase SUMO	Peso	Descripción
g-car	HBEFA3/PC_G_EU4	passenger	25 %	Turismo gasolina
d-car	HBEFA3/LDV_D_EU4	passenger	25 %	Turismo diesel
motorcycle	HBEFA3/PC_G_EU4	motorcycle	20 %	Motocicleta
d-taxi	HBEFA3/LDV_D_EU4	taxi	20 %	Taxi diesel
bus	HBEFA3/bus	bus	10 %	Autobus diesel

Tabla A.3.: Distribución simplificada de flotas

Escenarios sintéticos

La topología de las redes de tráfico urbano suele ser irregular, atendiendo a su génesis y su evolución en el tiempo, y sobre todo, por los condicionantes geográficos de su entorno. Esto hace que los modelos de optimización del enrutamiento de tráfico se vean fuertemente condicionados o sesgados por dicha topología, dificultando la atribución de los resultados a los mecanismos o a las propias tipologías.

Por este motivo, el uso de escenarios sintéticos con redes de referencia nos permite la creación de modelos uniformes que desacoplan los efectos atribuibles a los métodos de enrutamiento de los efectos atribuibles a las irregularidades de las tipologías reales. Posteriormente, los métodos ya validados son aplicados a redes reales para la validación de los resultados obtenidos.

En general, los modelos sintéticos se emplean para demostrar el detalle de funcionamiento de las propuestas de enrutamiento, realizar los análisis de sensibilidad de parámetros específicos. Algunos de los escenarios han sido retomados de las fuentes bibliográficas, y modificados o ampliados durante el transcurso de la investigación, con el fin de comparar resultados entre los diversos algoritmos empleados. No todos los escenarios experimentados se muestran en los artículos que conforman la tesis, centrando los resultados en aquellos más relevantes, para mayor claridad de la exposición de los mismos. Se recogen aquí como parte de los trabajos de investigación desarrollados, dado que han sido objeto de estudio.

Escenario sintético Ortuzar-Willumsen

El escenario Ortuzar-Willumsen (Figura A.2) está descrito en [94] y posteriormente usado por [14] para ilustrar su algoritmo genético para asignación estática de tráfico.

La red Ortuzar-Willumsen formada por una malla cuasi-rectangular de 13 nodos, conectados por 48 enlaces de un sólo carril por sentido. Los enlaces tienen un peso (coste) reasignado en el rango $[2, 15]$ según se observa en la figura A.2. Los nodos se denominan $[A, B, \dots, M]$ en función de su posición. Aunque los trabajos originales no lo detallan, se asume que los enlaces son bidireccionales con un sólo carril por sentido, dado que son empleados para búsquedas de enrutamientos óptimos. La hipótesis de direccionalidad nos permite lograr mejores caminos alternativos ampliando el espacio de búsqueda.




Figura A.2.: Red de tráfico Ortúzar-Willumsen

Este escenario se ha empleado como base de los algoritmos de optimización de pesos de TWM descritos en los artículos que forman los capítulos 4 y 5, por su rapidez de cálculo a la hora de evaluar los algoritmos evolutivos de optimización.

Configuración del tráfico




Figura A.3.: Flujos de tráfico en Ortúzar-Willumsen

Origen / Destino	L	M
A	600	400
B	300	400

Tabla A.4.: Ortúzar-Willumsen: O/D Matriz

Para lograr un efecto de congestión que fuerce el uso de caminos alternativos, se configura una demanda direccional formada por 4 flujos de tráfico $\mathbb{T} = [f_1, f_2 \dots f_4]$ que conectan nodos-centroides de los flujos: 2 orígenes de tráfico con 2 destinos, según se muestra en la Tabla A.4.

El tráfico total soportado en este escenario es de 1.700 vehículos, distribuido en los grupos indicados en la Figura A.3, aunque estos grupos no son empleados en los algoritmos de búsqueda de soluciones óptimas.

Este escenario sirve para el cálculo básico propuesto por Bazaan para evaluar las rutas óptimas de los vehículos, pero su utilidad se considera muy baja por varios motivos: la complejidad reside en el número de vehículos que se emplean, y no permite la realización de caminos KSP alternativos disjuntos (no solapantes) en la red, siendo todos los caminos prácticamente iguales. No es posible aliviar la congestión con un red como ésta.

Los experimentos realizados en esta red no han sido publicados por su baja relevancia y aplicabilidad como ya se ha comentado, pero han conducido a la concepción de los siguientes escenarios y experimentos de mayor complejidad.

Escenario sintético Paricio-LopezCarmona

El escenario Paricio-LópezCarmona (Figura A.4) es una evolución del escenario Ortúzar-Willumsen descrito en [94, 14] que añade nuevos nodos y enlaces que permiten desarrollar mejores KSP no coincidentes. Está diseñado para desarrollar los algoritmos de generación de TWM óptimos.

Está formado por una malla cuasi-rectangular de 21 nodos, conectados por 91 enlaces de un sólo carril por sentido. Los enlaces tienen un peso (coste) preasignado en el rango $[2, 15]$ según se muestra en la figura A.4. Los nodos se denominan $[A, B, \dots U]$ en función de su posición.




Figura A.4.: Red de tráfico Paricio-LópezCarmona

Este escenario se ha empleado como base de los algoritmos de optimización de pesos de TWM descritos en los artículos que forman los capítulos 4 y 5, por su rapidez de cálculo a la hora de evaluar los algoritmos evolutivos de optimización.

Origen / Destino	<i>L</i>	<i>M</i>
<i>A</i>	600	400
<i>B</i>	300	400

Tabla A.5.: Paricio-LópezCarmona: O/D Matriz

Configuración del tráfico




Figura A.5.: Flujos de tráfico en Paricio-LópezCarmona

Para lograr un efecto de congestión que fuerce el uso de caminos alternativos, se emplea la misma demanda direccional descrita en el escenario Ortúzar-Willumsen, formada por 4 flujos de tráfico $\mathbb{T} = [f_1, f_2 \dots f_4]$ que conectan nodos-centroides de los flujos: 2 orígenes de tráfico con 2 destinos, según se muestra en la Tabla A.5.

El tráfico total soportado en este escenario es de 1.700 vehículos, distribuido en los grupos indicados en la Figura A.1, aunque estos grupos no son empleados en los algoritmos de búsqueda de soluciones óptimas.

A pesar de mejorar el escenario Ortúzar-Willumsen, su uso se ha considerado también bastante restringido por su pequeño tamaño, y sus resultados han conducido a la selección de Grid-64 como escenario de referencia para los experimentos sintéticos de cálculo de mapas de pesos TWM óptimos, por

proporcionar una complejidad mayor más parecida a las redes de tráfico reales.

Escenario sintético Grid-64

El escenario Grid-64 (Figura A.6) es una malla rectangular de 8x8 nodos (64), conectados por 224 enlaces de un sólo carril por sentido. Los enlaces tienen un peso (coste) aleatorio uniformemente distribuido en el rango [4, 12] (en la figura, se ha representado el peso del enlace con grosores proporcionales). Se emplean distribuciones de pesos aleatorios en los enlaces para evitar el efecto de obtención de soluciones triviales por el algoritmo genético, debido al uso de una red idealmente uniforme. Los nodos se denominan $N_{i,j}$ en función de su posición.




Figura A.6.: Red de tráfico Grid-64

Este escenario se ha empleado como base de los algoritmos de optimización de pesos de TWM descritos en los artículos que forman los capítulos 4 y 5, por su rapidez de cálculo a la hora de evaluar los algoritmos evolutivos de optimización. Este escenario se usa como base de las simulaciones macroscópicas realizadas con MatLab.

Origen / Destino	N_{73}	N_{75}	N_{77}
N_{23}	1000	500	1000
N_{26}	500	1000	500

Tabla A.6.: Grid-64: matriz de demanda de tráfico origen/destino.

Configuración del tráfico

Para lograr un efecto de congestión que fuerce el uso de caminos alternativos, se configura una demanda direccional formada por 6 flujos de tráfico $\mathbb{T} = [f_1, f_2 \dots f_6]$ que conectan nodos-centroides de los flujos: 3 orígenes de tráfico con 2 destinos, según se muestra en la Tabla A.6.




Figura A.7.: Flujos de tráfico en Grid-64

El tráfico total soportado en este escenario es de 4.500 vehículos, distribuido en los grupos indicados en la Figura A.1.

Escenario sintético Grid-256

El escenario Grid-256 (Figura A.8) nos permite simular redes urbanas de topología regular, diseñadas según los patrones del racionalismo. Está formada por una malla rectangular de 16x16 nodos (256), conectados por 960 enlaces en dos posibles configuraciones: a) con un sólo carril por sentido, y b) con dos carriles por sentido para poder hacer simulaciones de capacidades ampliadas de carriles. La red es uniforme con enlaces de 50m limitados a 50km/h (13,9m/s). Los nodos se denominan $N_{i,j}$ en función de su posición, y los enlaces se denominan a partir de los nodos que conectan $N_{i,j} - N_{l,m}$.

El uso de enlaces de peso fijo nos permite analizar el comportamiento de la red ante mapas aleatorizados en diferentes configuraciones.




Figura A.8.: Red de tráfico Grid-256 mostrando los TAZs, en una situación de congestión.

Este escenario se ha empleado como base de los experimentos iniciales microscópicos (con SUMO [16]) para la definición del modelo de enrutamiento por

mapas de pesos descritos en los artículos [99, 98] (capítulo 3). Este escenario, junto a Radial-256, se emplea como modelo de simulación redes urbanas de cierto tamaño con fuertes mecanismos de congestión. En esta red se analizan los impactos subjetivos derivados del uso de TWM. No se han aplicado los algoritmos de optimización en este escenario por ser muy similar a Grid-64.

Configuración del tráfico




Figura A.9.: Flujos de tráfico en Grid-256

En la red se definen 5 áreas de tráfico (TAZ):

Origen / Destino	TAZ_N	TAZ_s	TAZ_E	TAZ_W	TAZ_C
TAZ_N		200			
TAZ_S	200				
TAZ_E				200	
TAZ_W			200		
TAZ_C					2000

Tabla A.7.: Grid-256: matriz de demanda de tráfico origen/destino.

- TAZ-N Norte. Agrupa los nodos origen/destino del extremo superior (norte) del Grid-256.
- TAZ-S Sur. Agrupa los nodos origen/destino del extremo inferior (sur) del Grid-256.
- TAZ-E Este. Agrupa los nodos origen/destino del extremo derecho del Grid-256.
- TAZ-W Oeste. Agrupa los nodos origen/destino del extremo izquierdo del Grid-256.
- TAZ-C Central. Contiene todos los nodos de la red de tráfico.

Para lograr un efecto de congestión que fuerce el uso de caminos alternativos, se configura la siguiente demanda de tráfico:

- 4 flujos de tráfico direccionales que cruzan la red de Norte a Sur y de Sur a Norte, así como de Este a Oeste y viceversa $\mathbb{T} = [f_{NS}, f_{SN}, f_{EW}, f_{WE}]$, conectando los TAZs entre sí, y que simula tráfico de tránsito entre los extremos de la red.
- Tráfico de fondo aleatorio que conecta nodos internos de la red sin tener en cuenta la configuración de TAZs.

Con esta configuración se prueban diversos volúmenes de vehículos, reflejándose en la Tabla A.7 la configuración publicada en los experimentos descritos en [99].

El tráfico total soportado en este escenario es de 2.800 vehículos, distribuido en los grupos indicados en la Figura A.1.

Escenario sintético Radial-241

El escenario RADIAL241, representado en la Figura A.10, nos permite simular las topologías de redes urbanas organizadas entorno a un núcleo central. En esta red sintética se configuran 16 ejes que parten de su centro hacia su periferia, y otros 16 anillos concéntricos que van uniendo los diferentes ejes. Así la red está formada por 241 nodos, y 992 enlaces. Para los diferentes experimentos, se emplean enlaces de 1 o 2 carriles por sentido. La red es uniforme con enlaces de 50m limitados a 50km/h (13,9m/s). Los nodos se denominan $N_{i,j}$ en función de su posición, y los enlaces se denominan a partir de los nodos que conectan $N_{i,j} - N_{l,m}$. Al igual que en Grid-256, el uso de enlaces de peso fijo nos permite analizar el comportamiento de la red ante mapas aleatorizados en diferentes configuraciones.




Figura A.10.: Flujos de tráfico en Radial-241

Este escenario se ha empleado como base de los experimentos iniciales microscópicos (con SUMO [16]) para la definición del modelo de enrutamiento por mapas de pesos descritos en los artículos [99, 98] (capítulo 3). Este escenario, junto a Grid-256, se ha empleado como modelo de simulación redes urbanas de cierto tamaño con fuertes mecanismos de congestión. Asimismo, en esta red se analizan los impactos subjetivos derivados del uso de TWM.

Configuración del tráfico

En la red se definen 5 áreas de tráfico (TAZ) tal y como se muestra en la Figura A.10.

TAZ-N Norte. Contiene un único nodo centroide origen/destino del extremo superior (norte) del Radial-241.

TAZ-S Sur. Contiene un único nodo centroide origen/destino del extremo inferior (sur) del Radial-241.

TAZ-E Este. Contiene un único nodo centroide origen/destino del extremo derecho del Radial-241.

TAZ-W Oeste. Contiene un único nodo centroide origen/destino del extremo izquierdo del Radial-241.

TAZ-C Central. Contiene todos los nodos de la red de tráfico, , entre los anillos 0 y 14.

Para lograr un efecto de congestión que fuerce el uso de caminos alternativos, se configura la siguiente demanda de tráfico:

- 4 flujos de tráfico direccionales que cruzan la red de Norte a Sur y de Sur a Norte, así como de Este a Oeste y viceversa $\mathbb{T} = [f_{NS}, f_{SN}, f_{EW}, f_{WE}]$, conectando los TAZs entre sí, y que simula tráfico de tránsito entre los extremos de la red.
- Tráfico de fondo aleatorio que conecta nodos internos de la red sin tener en cuenta la configuración de TAZs.

Origen / Destino	TAZ_N	TAZ_s	TAZ_E	TAZ_W	TAZ_C
TAZ_N		200			
TAZ_s	200				
TAZ_E				200	
TAZ_W			200		
TAZ_C					2000

Tabla A.8.: Radial-241: matriz de demanda de tráfico origen/destino.

Con esta configuración se prueban diversos volúmenes de vehículos, reflejándose en la Tabla A.8 la configuración publicada en los experimentos descritos en [99].

El tráfico total soportado en este escenario es de 2.800 vehículos, distribuido en los grupos indicados en la Figura A.1.

Escenarios reales

Existen diversos escenarios disponibles en la bibliografía de simulación de redes de tráfico, como los que se pueden encontrar en [123, 1, 81]. En nuestro caso, hemos elegido un conjunto de escenarios reales de complejidad creciente en términos de extensión de la red de tráfico para poder ir demostrando la viabilidad de los algoritmos empleados.

A excepción de la red TAPASCologne, el resto de escenarios han sido obtenidos desde el proyecto público de código abierto OpenStreetMaps [93] donde se pueden descargar mapas viarios con múltiples capas en varios formatos, aunque para la investigación se ha empleado el formato «.osm».

La mayor parte de las demandas de tráfico son sintéticas para la ejecución de los algoritmos, buscando reproducir las congestiones que se producen en la situación real de la red, donde el objetivo está centrado en regenerar los escenarios problemáticos antes que en emular a de forma precisa el comportamiento de la red. Así, se han ido probando diversas configuraciones de demanda de tráfico que nos permitieran calibrar los escenarios identificados.

En el caso concreto del escenario TAPAS-Cologne se ha usado la distribución de tráfico descrita en [123].

En el caso del escenario de la ciudad de Alcalá de Henares se han utilizado demandas de tráfico sintéticas, basadas en extracciones de datos obtenidos mediante mecanismos de crowd-sensing de una compañía privada (We-Plan, www.weplan.com [134]), cedidos con fines investigadores.

Red urbana de Madrid-Retiro

En la Figura A.11 se muestra un escenario de red de tráfico real que recoge un área perteneciente al barrio de Retiro en el centro de Madrid, España. El barrio ocupa una superficie de $5,38\text{km}^2$ y un censo de 125.978 habitantes¹. El barrio presenta una fuerte actividad ya que concentra una fuerte actividad de despachos profesionales, de comercio de proximidad y de usos turísticos, que genera fuertes movimientos vehiculares tanto de vehículos particulares como comerciales y de transporte público de uso individual (taxi, VTC). El barrio tiene fuertes restricciones al estacionamiento privado, con incentivo a la alta rotación del escaso número de plazas de estacionamiento en superficie, y está dotado de una fuerte infraestructura de transporte público. Los datos completos del barrio pueden ser accedidos en el portal de transparencia del Ayuntamiento de Madrid [46].

El mapa de la red viaria (*lat, long*) : (40,4260, -3,700) , (40,4205, -3,678) ha sido obtenido del proyecto de código abierto OpenStreetMaps [93] y posteriormente procesado mediante MatLab [86]. Contiene 191 nodos y 259 enlaces.

¹Fuente Google, datos correspondientes a 2005.




Figura A.11.: Red de tráfico Madrid-Retiro

Por su similitud estructural y de complejidad con la red sintética Grid-64, esta red urbana se ha empleado principalmente para los experimentos de cálculo de mapas de pesos TWM óptimos.

Configuración del tráfico

El tráfico total soportado en este escenario es de 8.000 vehículos, agrupado en 8 flujos de 1000 vehículos cada uno, según se muestra en la Tabla. La Figura A.1 muestra la distribución de tráfico en grupos.

Del nodo	Al nodo	Vehículos
1760085654	3964030753	1000
2005647264	1505184332	1000
2005647264	3964030753	1000
25901898	1505184332	1000
25901940	3964030753	1000
25903291	3964030753	1000
3587032531	1505184332	1000
4456617457	3964030753	1000

Tabla A.9.: Flujos de tráfico de Madrid-Retiro




Figura A.12.: Red de tráfico Madrid-Las Tablas

Red urbana de Madrid-Las Tablas

En la Figura A.13 se muestra un escenario de red de tráfico real que describe la parte central del nuevo distrito de Las Tablas en el norte de Madrid, España. Este distrito, con más de 24.300 hectáreas, ocupa casi la mitad del término municipal de Madrid. Además de esta particularidad, sus 30.000 habitantes lo convierten, por peso demográfico, en el tercer distrito de la ciudad. Contiene

además grandes centros empresariales y financieros, que provocan grandes movimientos de entrada y salida de tráfico en horario comercial. El distrito está delimitado por grandes vías rápidas al norte, sur y este, mientras que al oeste está bloqueado por las vías férreas. Los datos completos del barrio pueden ser accedidos en el portal de transparencia del Ayuntamiento de Madrid [46].

El mapa de la red viaria $(lat, long) : (40,520, -3,685), (40,495, -3,650)$ ha sido obtenido del proyecto de código abierto OpenStreetMaps [93] y posteriormente procesado mediante MatLab [86]. Contiene 971 nodos y 1583 enlaces.




Figura A.13.: Red de tráfico Madrid-Las Tablas

Esta red urbana ha sido principalmente usada para desarrollar experimentos de cálculo de

Por su similitud estructural y de complejidad con la red sintética Grid-64, esta red urbana se ha empleado principalmente para los experimentos de cálculo de mapas de pesos TWM óptimos.

Configuración del tráfico

El tráfico total soportado en este escenario es de 15.000 vehículos, agrupado en 30 flujos de 500 vehículos cada uno, según se muestra en la Figura A.14 y en la Tabla A.10. El escenario usa los grupos de tráfico definidos inicialmente en la Figura A.1




Figura A.14.: Red de tráfico Madrid-Las Tablas

Del nodo	Al nodo	Vehículos
1760085654	3964030753	1000
2005647264	1505184332	1000
2005647264	3964030753	1000
25901898	1505184332	1000
25901940	3964030753	1000
25903291	3964030753	1000
3587032531	1505184332	1000
4456617457	3964030753	1000

Tabla A.10.: Flujos de tráfico de Madrid-Retiro

Red urbana de Alcalá de Henares

Alcalá de Henares es una ciudad española perteneciente a la Comunidad de Madrid, ubicada a medio camino de Guadalajara (22km) y Madrid(31km). Es el tercer municipio más poblado en la Comunidad y el 31.º de España, con una población censada de 197,562 habitantes (INE [70], 2020), y una superficie 87.99 km². El municipio consta de una área urbana y una área metropolitana circundante que consolida una población de cerca de 800,000 habitantes y una superficie 1,421 km². La Administración Local se ha acogido a la Ley de Grandes Ciudades. El municipio acoge un censo de 9,800 empresas de todo tipo (INE [70], 2019): industrial, logística, servicios, etc.

La ciudad implementa una gran variedad de escenarios de tráfico ya que es atravesada por una autopista principal que conecta Madrid y Barcelona y que es utilizada diariamente por miles de vehículos privados y de distribución comercial ligera y pesada. Al sur, la ciudad está delimitada por el río Henares que delimita su expansión urbanística. La ciudad cuenta con severas restricciones de tráfico y zonas peatonales debido al centro histórico protegido de la ciudad y, al mismo tiempo, contiene numerosos equipamientos públicos de servicio al ciudadano, incluyendo parte del campus universitario. También combina zonas residenciales densas con otras extensas.

La ciudad está rodeada por un cinturón industrial con muchas empresas e industrias establecidas, predominando las de tipo logístico por su cercanía a Madrid. El cinturón también contiene amplias zonas comerciales y también

instalaciones públicas adicionales como hospitales y el resto del campus universitario. Alcalá está muy cerca del aeropuerto internacional de Madrid y de los centros de negocios, por lo que existe un intenso tráfico diario de entrada y salida que mezcla tráfico privado, público, comercial e industrial. También tiene un gran intercambio de tráfico con los pueblos cercanos que conforman su área metropolitana.

El mapa de la red viaria (*lat, long*) : (40,462099, -3,4088516) , (40,5187581, -3,3123779) ha sido obtenido del proyecto de código abierto OpenStreetMaps [93] y posteriormente procesado mediante MatLab [86]. La red está representada en la Figura A.15 y consta de 4150 nodos y 7830 enlaces, de uno o varios carriles.

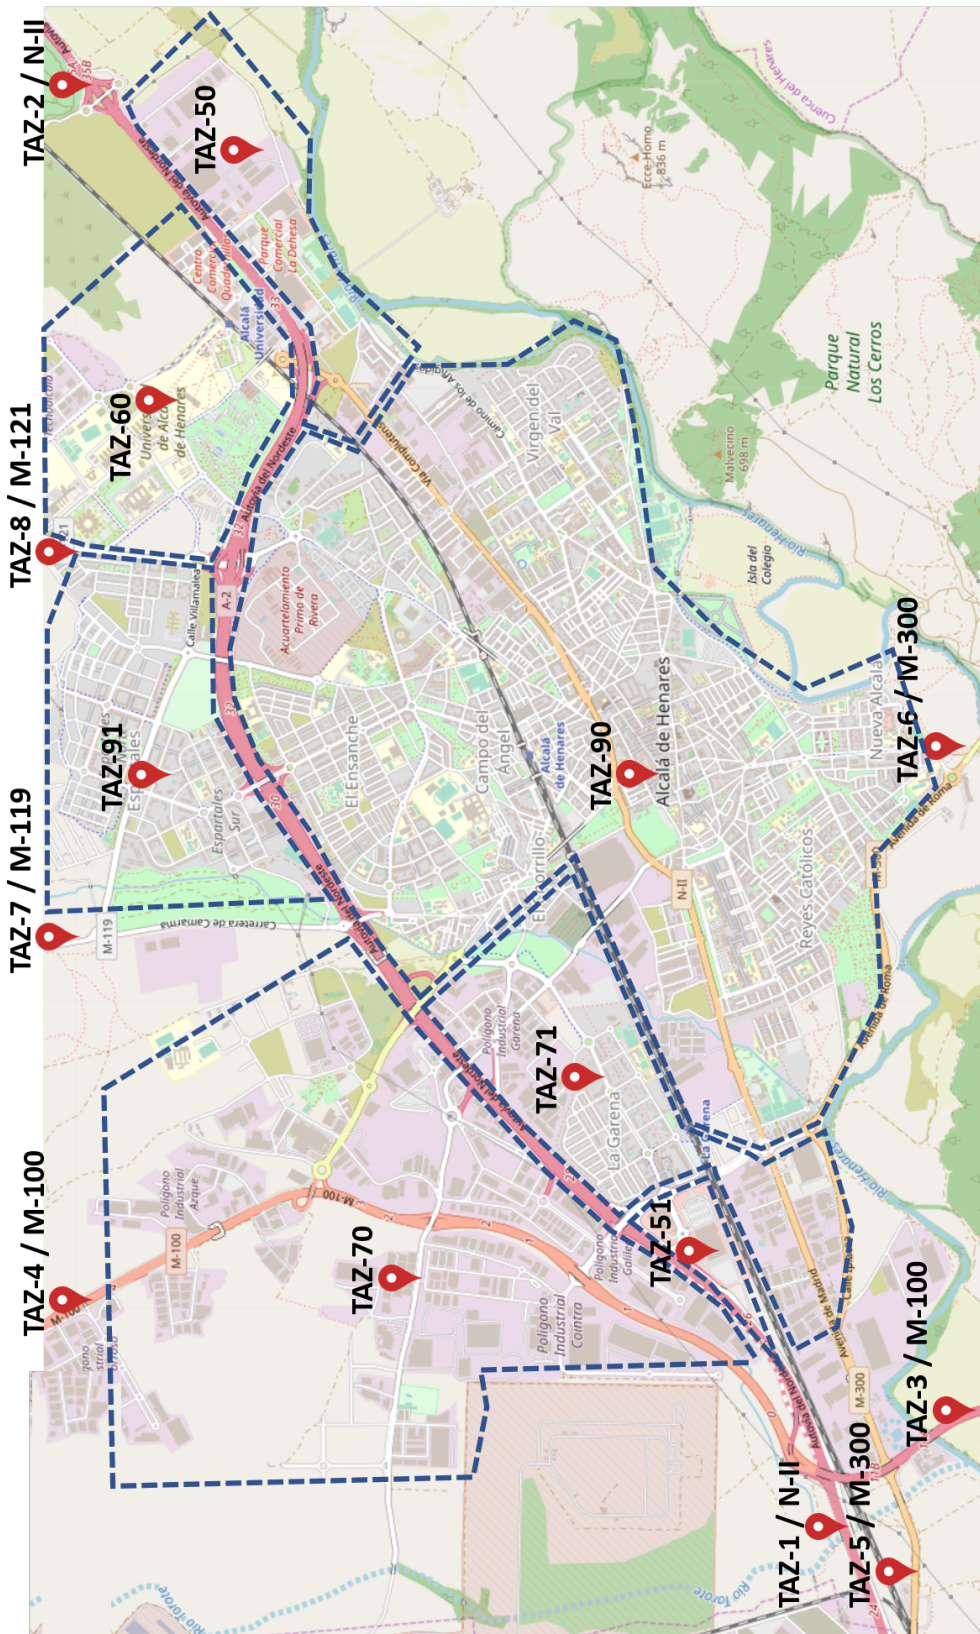


Figura A.15.: Red de tráfico de Alcalá de Henares

Como parte de la toma de datos de tráfico de Alcalá de Henares se realizó un experimento de *crowd-sensing* que se describe en la sección E. Se consideraron las TAZs descritas en la Tabla A.11 considerando la topología de la red urbana, la conectividad por carreteras, y los usos principales de sus áreas.

Se definen 3 tipologías de TAZ:

TAZ-Area urbana	Describen áreas de superficie que se agrupa por su uso principal, y que están delimitados por carreteras o por accidentes geográficos.
TAZ-Autovía	Describe áreas de entrada o salida de tráfico por grandes autovías o autopistas.
TAZ-Carretera	Describe áreas de entrada o salida de tráfico por carreteras de enlace entre poblaciones.

Los experimentos basados en el escenario Alcalá de Henares se han empleado principalmente con simulación microscópica para analizar el comportamiento de TWM con mapas aleatorizados, y la experiencia individual obtenida por los conductores.

Configuración del tráfico

Estos flujos se diseñan a partir de dos fuentes de datos que cubren las horas de tráfico intenso: a) medidas de sensores de red ubicados en las principales conexiones viales; y b) datos de *crowd-sensing* obtenidos a partir de apps móviles ad-hoc. La primera fuente de datos permite el cálculo de flujos sintéticos para la matriz OD, ya que contiene datos completos de tráfico pero carece de datos O/D de los viajes; la segunda fuente proporciona rutas reales con datos O/D y permite la validación de la matriz sintética. La Tabla A.12 muestra la matriz de tráfico de la TAZ para 2 horas, donde la simulación cubre una hora adicional para completar el tráfico.

Tipo	TAZ	Nombre	Descripción	Usos principales
Autopista	TAZ-1	E-5, N-2 Oeste	Autopista nacional, Madrid-Barcelona.	Tráfico de tránsito, desplazamiento laboral, logística y distribución
	TAZ-2	E-5, N-2 Este	Autopista nacional, Madrid-Barcelona.	Tráfico de tránsito, desplazamiento laboral, logística y distribución
	TAZ-3	M-100 Sur-Oeste	Autovía Regional (Mejorada)	Tráfico de tránsito, desplazamiento laboral, logística y distribución
	TAZ-4	M-100 Norte	Autovía Regional (Daganzo)	Tráfico de tránsito, desplazamiento laboral, logística y distribución
Carretera	TAZ-5	M-300 Oeste	Carretera Secundaria (Alcalá)	Tráfico de tránsito, desplazamiento laboral, logística y distribución
	TAZ-6	M-300 Sur	Carretera Secundaria (Loeches)	Tráfico de tránsito, desplazamiento laboral, logística y distribución
	TAZ-7	M-119 Norte	Carretera Secundaria (Camarma)	Tráfico de tránsito, desplazamiento laboral, logística y distribución
	TAZ-8	M-121 Norte	Carretera Secundaria (Meco)	Tráfico de tránsito, desplazamiento laboral, logística y distribución
Area	TAZ-50	La Dehesa/Cuadernillos	Área comercial Norte-Este	Comercial y distribución
	TAZ-51	La Garena	Área comercial Oeste	Comercial y distribución
	TAZ-60	Universidad	Campus Universitario, Hospital, Industria e Investigación	Servicios, Transporte público
	TAZ-70	Paracuellos, Daganzo	Industrial	Industria y logística
	TAZ-71	La Garena	Industrial	Industria y logística
	TAZ-90	Centro Ciudad	Residencial	Tráfico habitual y transporte público
	TAZ-91	Espartales	Residencial	Tráfico habitual y transporte público

Tabla A.11.: Descripción y uso de las TAZ

		TAZ Destino															
		90	91	1	2	3	4	5	6	7	8	50	51	60	70	71	
TAZ Origen	90	8000	200	800	800	400	400	1000	400	400	400	200	200	200	100	100	
	91	200	100	300	300	150	150	100	100	100	100	100	100	100	50	50	
	1	800	500		2000							100	100	200	200	200	
	2	800	500	2000								100	100	200	200	200	
	3	400	100	400	400		1000					100	100	100	50	50	
	4	400	100	400	200	1000						100	100	100	50	50	
	5	800	100							400			100	100	100	50	50
	6	800	100		400			1000					100	100	100	50	50
	7	400	100	300	100								100	100	100	50	50
	8	400	100	300	100								100	100	100	50	50
	50	200	100	100	100	100	100	100	100	100	100						
	51	200	100	100	100	100	100	100	100	100	100						
	60	200	50	200	200	100	100	100	100	100	100				50	50	
	70	100	50	200	200	50	50	50	50	50	50	50			50		
	71	100	50	200	200	50	50	50	50	50	50	50			50		

Tabla A.12.: Alcalá de Henares. Matriz de tráfico por TAZ origen/destino.

B

Recursos y herramientas de investigación

Para el desarrollo de la parte experimental que avala los resultados de la tesis, se han empleado diversos tipos de simuladores y escenarios de redes tráfico vehicular, con datos sintéticos basados en datos reales. Los datos reales que se han empleado en los escenarios urbanos reales son flujos sintéticos evolucionados desde fuentes de datos abiertas como de cesión de datos basados en herramientas de *crowd-sensing*. El uso de simuladores se hace imprescindible por la dificultad de desplegar sistemas reales de gestión de tráfico con propuestas experimentales, siendo además, una práctica estándar y habitual no sólo en la investigación en el área sino también en su aplicación real.

Simuladores y herramientas de gestión de tráfico

Para el desarrollo y pruebas de nuevas metodologías de enrutamiento de tráfico, es necesario el uso de simuladores por la imposibilidad de hacer despliegues reales, de medir los resultados en dichos escenarios real, de reproducir escenarios temporales extensos, y de generar los escenarios concretos.

Así emplearemos simuladores microscópicos y macroscópicos en función de cada caso de uso analizado. Igualmente, la simulación de entornos nos permite definir escenarios sintéticos que permitan focalizar y representar escenarios específicos. Se puede obtener una panorámica de los diferentes entornos de simulación en [112, 101, 72]

Simuladores microscópicos

Los simuladores microscópicos de tráfico implementan escenarios donde la trayectoria de cada vehículo es evaluada en cada instante de tiempo en relación a los demás vehículos y la red de transporte concreta. Así se itera en cada unidad de tiempo y se calculan todos y cada uno de los vehículos en base a cada comportamiento específico.

SUMO

SUMO [76] es una suite de simulación de tráfico gratuita y de código abierto. Está disponible desde 2001 y permite modelar sistemas de tráfico intermodales, incluyendo vehículos de carretera, transporte público y peatones. SUMO incluye una gran cantidad de herramientas de apoyo que automatizan las tareas básicas para la creación, la ejecución y la evaluación de escenarios de tráfico, como la importación de redes, el cálculo de rutas, la visualización y el cálculo de emisiones. El entorno del simulador SUMO es ampliable mediante módulos personalizados y proporciona varias API para controlar la simulación de forma remota. Está desarrollado y mantenido principalmente por el Instituto de Sistemas de Transporte del Centro Aeroespacial Alemán (<https://www.dlr.de/ts>), y se ofrece de forma gratuita bajo licencia «*Eclipse Public License V2*». La marca «Eclipse SUMO» es propiedad de la *Eclipse Foundation*.

SUMO ha sido empleado en numerosos proyectos de investigación y áreas de aplicación, como pueden ser:

- Evaluar la eficiencia de los sistemas de semáforos, incluyendo la evaluación de los algoritmos modernos hasta la evaluación de los planes de temporización semanales.
- Selección de rutas por parte de los vehículos, incluyendo la evaluación de rutas eco-sensibles basadas en la emisión de contaminantes, y así como el impacto del enrutamiento autónomo.
- Generación de previsiones de tráfico a las autoridades municipales.

- Emulación de escenarios de comunicaciones vehiculares, y la supervisión del tráfico mediante sondas GSM.
- Emulación de escenarios V2X tanto para proporcionar rastros realistas de vehículos como para evaluar aplicaciones con detectores de bucle en línea con un simulador de red.
- Simulación de los efectos del tráfico de vehículos autónomos y masivo.
- Simulación y validación de la función de conducción autónoma en cooperación con otros simuladores.
- Simulación del tráfico de aparcamientos.
- Simulación del tráfico ferroviario para la planificación inteligente de vehículos.
- Análisis de la seguridad del tráfico y evaluación de riesgos.
- Cálculo de emisiones (ruido y contaminantes).

El entorno de simulación SUMO contiene las aplicaciones y componentes descritos en la tabla B.1. La presente tesis ha generado numerosos elementos adicionales que complementan la función de SUMO y que se relacionan en el apéndice D.

El **módulo TraCI (*Traffic Control Interface*)** permite interactuar en tiempo real con una simulación de tráfico, para recuperar los valores de los objetos simulados y manipular su comportamiento "en línea". TraCI utiliza una arquitectura cliente/servidor basada en TCP para proporcionar acceso a sumo: actúa como un servidor que se inicia con opciones adicionales en la línea de comandos, siendo obligatorio indicar el puerto en el que el simulador atenderá las conexiones entrantes.

TraCI puede ejecutarse tanto en los dos modos de ejecución de SUMO, con interfaz gráfica o silencioso, y admite múltiples clientes simultáneos. Así muchas ampliaciones a SUMO usan esta interfaz para usar SUMO como motor de enrutamiento microscópico y desacoplar las funcionalidades. TraCI se

Herramienta	Descripción
sumo	Simulador de tráfico microscópico
sumo-traci	(Incluido en sumo) Componente de integración de sumo
sumo-gui	Interfaz gráfica de simulación de tráfico.
netconvert	Herramienta de importación de redes.
netedit	Editor visual de redes.
netgenerate	Generador de redes sintéticas.
od2trips	Convertor de matrices O/D en trayectos.
duarouter	Generador de rutas mediante DTA.
jtrrouter	Generador de rutas por ratios de giro en intersecciones.
dfrouter	Generador de rutas sobre datos de sensores.
marouter	Asignador de tráfico basado en funciones de capacidad.
polyconvert	Importador de zonas geométricas (TAZ).
activitygen	Generador de modelos de actividad de la población.
emissionsMap	Generador de mapas de emisiones.
emissionsDrivingCycle	Calculadora de emisiones basándose en un ciclo de conducción.
osmWebWizard	Generador de escenarios de red sobre OpenStreetMaps

Tabla B.1.: Componentes del entorno de simulación SUMO.

ejecuta en la simulación paso-a-paso en el tiempo (una vez por cada iteración temporal).

Simuladores macroscópicos

A la hora de realizar simulaciones relacionadas con la asignación estática de tráfico se han empleado dos aproximaciones, una basada en la prospección de implementaciones de código abierto existentes en el mercado, con el objetivo de modificarlas para implementar la asignación de TWM y poder comparar resultados. Y la otra basada en implementaciones directas y completas en herramientas de propósito general. Se ha optado finalmente por la segunda opción dado que la complejidad de modificar y re-implementar TWM en plataformas propietarias se estimaba similar a la implementación en MatLab que, además, ofrece numerosas herramientas de analítica posterior.

Programas *opensource* de cálculo de algoritmos de asignación estática

Aunque se ha hecho una implementación completa de los modelos de asignación estática UE y SUE, se han empleado otros modelos *opensource* disponibles para contrastar las soluciones obtenidas en los escenarios de referencia. Se relacionan aquí a modo de referencia.

- Entorno de Planificación de Tráfico MASLAB:

Es una colección de herramientas orientadas a la gestión del modelo de planificación del tráfico. Entre las herramientas empleadas está MSA, que es una herramienta Python para el cálculo de la asignación estática de tráfico mediante el método de medias sucesivas MSA.

Disponible en <https://github.com/maslab-ufrgs>

- Entorno de Asignación de Tráfico PRAMESHK:

Es una colección de herramientas orientadas a la gestión del modelo de planificación del tráfico. Entre las herramientas empleadas es MSA: Traffic-Assignment (TA) es una colección de herramientas Python para la asignación de tráfico estático. TA puede resolver el problema de asignación de tráfico estático mediante el cálculo del equilibrio de usuarios (UE) y del equilibrio estocástico de usuarios (SUE) para una red urbana. Empleado para la resolución diversos algoritmos tales como el método de promedios sucesivos (MSA) como con el algoritmo de Frank-Wolfe (F-W).

Disponible en <https://github.com/prameshk/Traffic-Assignment>

- Entorno de Asignación de Tráfico seSue

Es una herramienta de cálculo de asignación de tráfico basada en SUE, implementada sobre EXCEL. Dado el carácter ofimático de la plataforma de base, esta implementación es exclusivamente válida para modelos pequeños y ejercicios prácticos de cálculo.

Disponible en <https://github.com/bstabler/TransportationNetworks>

Entorno de propósito general MatLab

MatLab y SimuLink [86] es un entorno de cálculo científico de propósito general basado fundamentalmente en cálculo matricial. Dispone de un variado catálogo de módulos para múltiples casuísticas y campos de aplicación, y uno de sus características más destacables para el trabajo científico es la capacidad de funcionar sobre cuadernos de trabajo que permiten una experimentación continua en base a la investigación en tiempo real.

Aunque MatLab no dispone de algoritmos de asignación de tráfico con implementaciones nativas, si permite su desarrollo de forma efectiva habilitando el posterior trabajo de análisis de experimentos de forma interactiva en los cuadernos de trabajo. MatLab ofrece numerosas características que la hacen ideal para ser empleada en la simulación macroscópica:

1. El mencionado entorno de trabajo por cuadernos de experimentos que ofrece un marco de trabajo ágil y productivo.
2. Potentes rutinas de procesamiento de grafos dirigidos, ideales para la representación de las redes de tráfico.
3. Un potente motor de ingesta de datos en prácticamente cualquier formato transformándolos en representaciones numéricas de fácil procesamiento matricial. Este motor es capaz igualmente de exportar los datos a múltiples formatos de salida.
4. Librerías de algoritmos de optimización. En la tesis se ha optado por usar el módulo de algoritmos evolutivos MatLab-GA (Genetic Algorithms) [84] para el cálculo de las distribuciones de mapas TWM óptimos.
5. Librerías de lógica difusa. En la tesis se ha escogido el módulo de razonamiento por reglas difusas MatLab-Fuzzy Logic Toolbox [61] para implementar el modelo de utilidad subjetiva de los conductores.
6. Un completo sistema generación de gráficos y de análisis.

En cambio, la desventaja más palpable es la necesidad de licenciamiento comercial para su uso.

Por ello, se ha optado por implementar los simuladores macroscópicos bajo MatLab. Estos simuladores se describen en la sección D.

C

Modelo de comportamiento *fuzzy* de los conductores en la adopción de TWM

Las reglas se agrupan en los siguientes conjuntos según el comportamiento de los conductores:

1. **Comportamiento de los no usuarios de TWM (reglas 1-5):** cuando el conductor NO es usuario de TWM, dependiendo de lo valiosa que sea la experiencia del último viaje en comparación con las condiciones de conducción en flujo libre, y de la aceptación social de TWM, las utilidades $[U_{TWM}, \bar{U}]$ variarán. La utilidad de la TWM condiciona la política de los nuevos adoptantes.
2. **Comportamiento de los usuarios de TWM teniendo en cuenta la experiencia a corto plazo (reglas 6-15):** cuando el conductor SI es usuario de TWM (usuario registrado o lo ha utilizado alguna vez), la experiencia del último viaje condiciona si ha merecido la pena el uso de TWM o no, considerando si el tiempo de viaje ha mejorado o no. La aceptación social de la TWM es menos importante aquí. Este conjunto de reglas controla si el conductor sigue utilizando TWM o rechaza su uso en función de las experiencias de tráfico cuando la adherencia aumenta y las condiciones de congestión evolucionan.
3. **Comportamiento de los usuarios de TWM teniendo en cuenta la experiencia a medio y largo plazo (reglas 16-19):** cuando el conductor SI es usuario de TWM, la experiencia a medio y largo plazo utilizando TWM es valiosa para representar la confianza del conductor en el método de encaminamiento. Independientemente de lo que haya ocurrido en el

último viaje del conductor, éste aprende de otras experiencias anteriores. Estas reglas limitan también las oscilaciones en el proceso de decisión.

El origen de las reglas es un modelo ad-hoc adaptado al caso de uso de TWM en base a los comportamientos de promoción/detracción esperados. Este modelo debería ser generado desde un trabajo de campo previo basado en encuestas a la población de conductores y desde un trabajo comparativo de comportamientos en el tiempo. El objetivo de la investigación es el propio modelo de gestión BOID+S, que es general y permite añadir fácilmente nuevas reglas referidas a las variables difusas existentes o a nuevas adiciones.

En la tabla C.2 se muestran la lógica de reglas de decisión para las estrategias TWM y no-TWM, junto a su ponderación de peso indicado en la tabla C.1:

Category	Very High	High	Normal	Low
Weight	1	0.75	0.50	0.25

Tabla C.1.: Weight categories for the fuzzy rules.

Group	Id	Description	Weight	XFF-TTS	XMTT-K	XRU-K	XLTU-K	XSOC	XLT-TT	UTWM	U
Never used TWM	1	TWM non-users. Good routing experience. No need to change.	Very high	Optimum		NoUser	No			very low	high
	2	TWM non-users. Could improve routing performance. May change.	Normal	Acceptable		NoUser	No			low	mid
	3	TWM non-users. Bad routing performance. TWM unknown. Hardly change.	Normal	Bad		NoUser	No	low		very low	mid
	4	TWM non-users. Bad routing performance. TWM mid-popular. Could change.	Normal	Bad		NoUser	No	mid		low	mid
	5	TWM non-users. Bad routing performance. TWM very popular. Try to change.	Normal	Bad		NoUser	No	high		high	mid
TWM users	6	TWM user. Recently improved relative experience with TWM. Keep using.	High			ActiveUser	Yes		improved	high	low
	7	TWM user. Recently worsened relative experience using TWM. Reject using.	Normal			ActiveUser	Yes		worsened	very low	high
	8	TWM user. Didn't use recently TWM, and had good experience. Reject using.	Normal			ActiveUser	No		improved	very low	high
	9	TWM user. Didn't use recently TWM, and had poor experience. Return to TWM.	Normal			ActiveUser	No		worsened	high	low
	10	TWM user. Recently good absolute results with TWM. Keep using.	Normal	Optimum		ActiveUser	Yes			high	low
	11	TWM user. Recently good absolute results without TWM. Reject using.	Very High	Optimum		ActiveUser	No			low	mid
	12	TWM user. Recently mid absolute results with TWM. Indifferent.	Normal	Acceptable		ActiveUser	Yes			low	low
	13	TWM user. Recently mid absolute results without TWM. Detractor.	Normal	Acceptable		ActiveUser	No			low	mid
	14	TWM user. Recently poor absolute results with TWM. Strong detractor.	Normal	Bad		ActiveUser	Yes			low	high
	15	TWM user. Recently poor absolute results without TWM. Promoter.	Very High	Bad		ActiveUser	No			high	low
	16	TWM user. Latest TWM experiences are good. Promoter.	High		Improved	ActiveUser	Yes			high	low
	17	TWM user. Latest TWM experiences are good, even if last day didn't use it. Promoter.	High		Improved	ActiveUser	No			high	low
	18	TWM user. Latest TWM experiences are bad. Detractor.	High		worsened	ActiveUser	Yes			very low	high
	19	TWM user. Latest TWM experiences are bad, even if last day didn't use it. Detractor.	High		worsened	ActiveUser	No			very low	high

Tabla C.2.: Reglas de adopción de TWM.

D

Relación de productos y desarrollos generados durante la tesis

Como ya se ha mencionado en los objetivos y en el resumen extenso de la tesis, al ser TWM una técnica novedosa requiere numerosos desarrollos específicos entre los que se encuentran:

- Los simuladores específicos de TWM o complementos de extensión para TWM en los simuladores existentes.
- Los componentes de generación, distribución y gestión de los mapas TWM.
- Los componentes de optimización de mapas.
- Los componentes de simulación de experiencia de usuario.

Entorno MuTraff.

MuTraff (Arquitectura de Control de Tráfico Multi-mapa) esta ideada como una colección de herramientas compatibles entre sí (componentes y librerías reutilizables) donde las salidas de cada componentes pueden usarse como entradas de otros. Así MuTraff podrá utilizarse como sistema independiente o combinarse con arquitecturas de tráfico ya existentes.

Uno de los principales objetivos de MuTraff es proporcionar un conjunto de componentes que se integren sin problemas con los sistemas actuales mediante interfaces estándar, siendo también compatible con el software estándar de los agentes de tráfico. Algunos de los bloques de referencia pueden ser proporcionados por marcos, dispositivos y herramientas de gestión del tráfico ya existentes, pero otros son elementos nuevos añadidos para cubrir los algoritmos y la funcionalidad de TWM.

Está previsto evolucionar MuTraff hacia un proveedor de servicios de enrutamiento basado en TWM que ofrece servicios de mapas de red de tráfico personalizados, y también servicios eficientes de enrutamiento origen-destino. Para el operador de servicios de tráfico, MuTraff deberá ofrecer una herramienta de análisis y optimización del tráfico con un motor de big data para la ingesta de datos de tráfico.

Parte de los bloques de referencia ya están disponibles y otros están en construcción o en *backlog*.

mutraff_simulator

mutraff_simulator es una herramienta de simulación microscópica para los escenarios basados en TWM que permite integrarse de forma nativa con el simulador SUMO [76], a través de su componente de integración SUMO-TraCI [125]. En la figura D.1 se muestra su arquitectura:

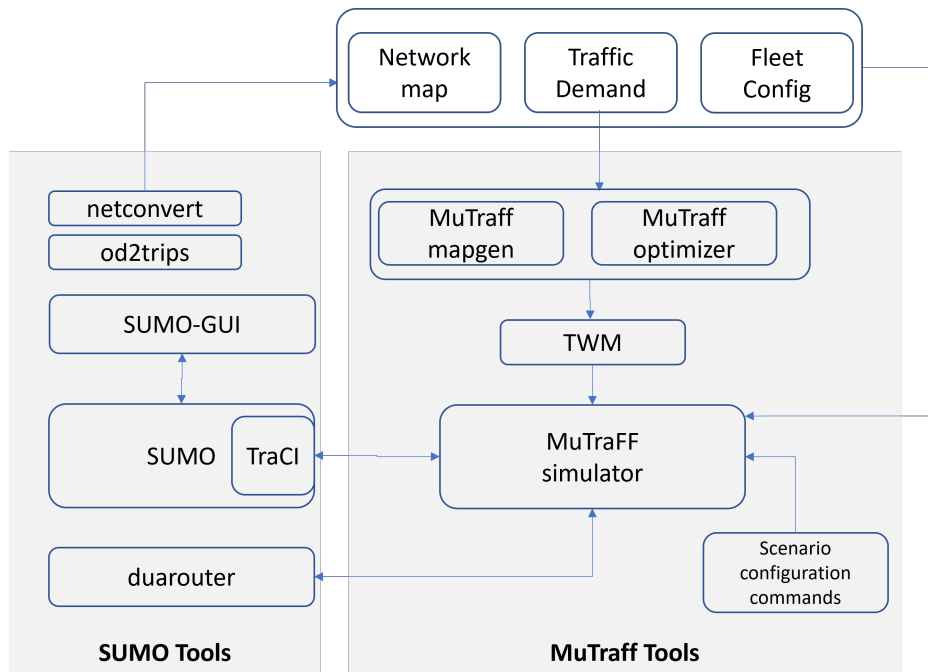


Figura D.1.: Diagrama general de funcionamiento de *mutraff_simulator*

El simulador recibe como entradas a) el escenario de tráfico (red de tráfico, demanda de viajes de los vehículos y distribución de flotas de vehículos); b) una colección de mapas TWM producidos por las herramientas de generación de mapas TWM; y c) una configuración del escenario TWM, sus políticas de uso y la planificación temporal de mapas y eventos (asignación temporal, incidentes de red, etc).

El simulador realiza la asignación dinámica de tráfico con el escenario de tráfico mediante las herramientas ofrecidas por SUMO (*duaroute*), y carga mediante el interfaz de integración SUMO-TraCI [125] el escenario de tráfico en el motor de simulación microscópica de SUMO. *mutraff_simulator* itera en el tiempo de simulación ingresando las nuevas demandas que aparecen en el tiempo. En la figura D.2 se muestra el diagrama funcional de la simulación con *mutraff_simulator*:

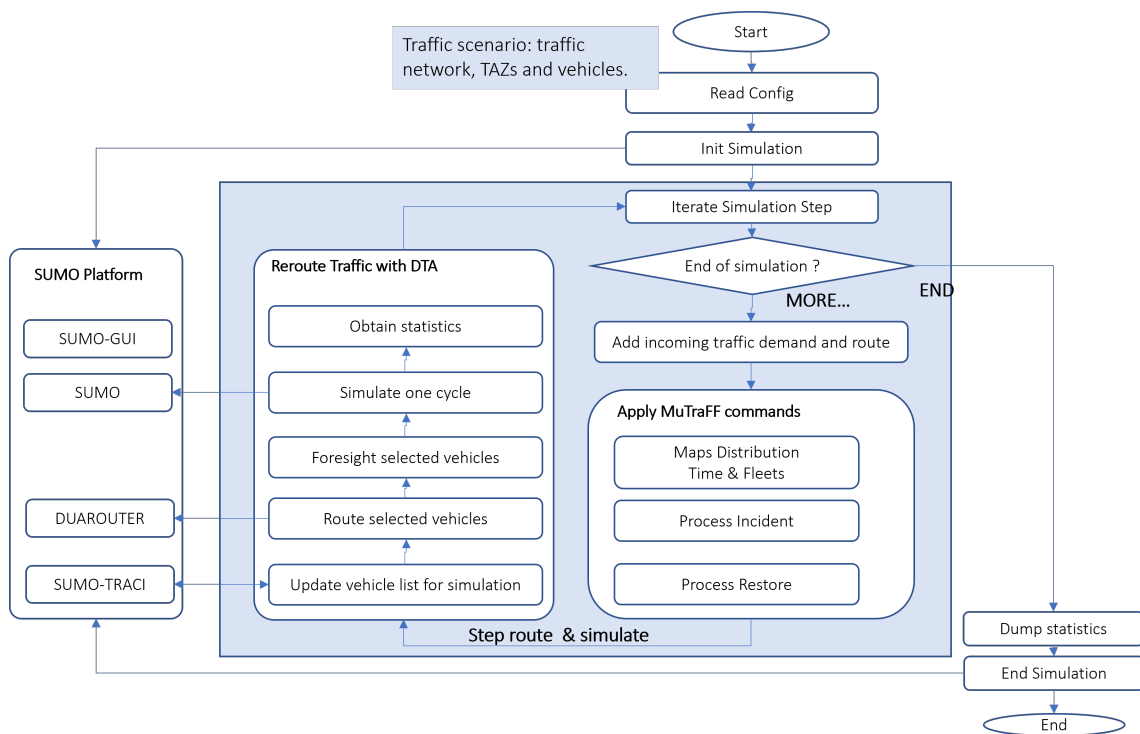


Figura D.2.: Diagrama general de funcionamiento de *mutraff_simulator*

El simulador va introduciendo la demanda de tráfico según las sucesivas iteraciones de tiempo (dinámico) y para cada vehículo introducido le asigna el correspondiente mapa para realizar su asignación dinámica de tráfico mediante la herramienta *duarouter* de SUMO.

El bloque de asignación de comandos MuTraff permite establecer diversos criterios de distribución de mapas:

- Por flotas o grupos de vehículos.
- Por instantes de tiempo.
- Por eventos planificados en la red.

El bloque de enrutamiento interactúa con el componente de integración SUMO-TraCI tomando los vehículos y reenrutándolos con las nuevas rutas obtenidas. Este componente permite igualmente mecanismos de prevención «visual» de la congestión, permitiendo a los vehículos consultar el estado de ocupación del enlace/enlaces inmediatamente posteriores para modificar su ruta.

mutraff_simulator esta desarrollado en python y es fácilmente extensible.

Generadores de mapas TWM

mutraff_mapgen

mutraff_mapgen es una herramienta de generación de mapas de pesos TWM que implementa las siguientes políticas y mecanismos:

- Generación de mapas TWM generales, mediante aplicación de funciones de generación de pesos a los pesos de toda la red. Estas funciones de generación están formadas por expresiones funcionales evaluables en python. Esta capacidad es empleada para generar mapas aleatorizados mediante expresiones que incluyen distribuciones aleatorias. Las más usadas son «uniform» y «norm».
- Generación de mapas TWM en ciertos puntos de la red, mediante aplicaciones de las funciones de modificación a los nodos indicados con un cierto radio de extensión. Así se pueden generar mapas para la gestión de incidentes.
- Generación de mapas TWM a ciertas listas de enlaces y/o TAZ para generar zonas de exclusión o de incentivo.
- Generación de mapas con validez temporal restringida, desde/hasta ciertos instantes de tiempo.

La herramienta permite la combinación de grupos de TWM para generar combinaciones aditivas, sustractivas, de reemplazo, etc,

mutraff_mapgen esta desarrollado en python y es fácilmente extensible.

mutraff_optimizer

mutraff_optimizer es una herramienta de generación de mapas de pesos TWM optimizados para UE-SO dados un escenario de red y demanda de tráfico. Sus mapas TWM son reutilizables por *mutraff_mapgen* para la combinación de políticas de enrutamiento.

mutraff_optimizer esta desarrollado en MatLab y es fácilmente extensible.

MuTraff Tools

mutraff_odgen

mutraff_odgen es una herramienta de generación de matrices O/D a partir de listados de viajes (*trips*) de los usuarios de una red. Es una herramienta útil para la transición entre entornos de simulación microscópica hacia los entornos macroscópicos de asignación estática y cálculo de TWM óptimos.

mutraff_odgen esta desarrollado en python y es fácilmente extensible.

mutraff_osm_mapconverter

mutraff_osm_mapconverter es una herramienta de conversión y adaptación de mapas desde múltiples fuentes como OpenStreetMap [93] hacia formatos compatibles en SUMO y MuTraff. En la mayoría de servidores de mapas se añaden ciertas características y planos de datos que no son relevantes para los motores de simulación.

mutraff_osm_mapconverter esta desarrollado en python y es fácilmente extensible.

mutraff_routeweigher

mutraff_routeweigher es una herramienta de cálculo de costes agregados de las rutas que se le proporcionan para una cierta distribución TWM. Su objetivo es analizar la calidad de las opciones de enrutamiento proporcionadas por un TWM.

mutraff_routeweigher esta desarrollado en python y es fácilmente extensible.

mutraff_tazcalc

mutraff_tazcalc es una herramienta de diseño y definición gráfica de *Traffic Area Zones* (TAZ) sobre cualquier mapa geo-posicionado. Toma como entrada un mapa web de OpenStreetMaps y permite dibujar polígonos directamente desde la web para diseñar los TAZ. La herramienta calcula los nodos incluidos en los polígonos y los exporta en formato XML compatible con el entorno MuTraff y SUMO.

mutraff_tazcalc esta desarrollado en javascript y es fácilmente extensible.

mutraff_simprofiler

mutraff_simprofiler es una herramienta interactiva de diseño de experimentos para *mutraff_simulator* . Dada la complejidad de parametrización de los escenarios por el volumen de parámetros y opciones a considerar, es una herramienta muy útil para la creación de experimentos específicos.

mutraff_simprofiler esta desarrollado en python y es fácilmente extensible.

Herramientas MatLab

Como ya se ha comentado MatLab ofrece múltiples posibilidades para la experimentación y simulación macroscópica de escenarios de tráfico. Comentaremos algunos de los módulos creados en función de su relevancia para la tesis.

Módulos de asignación estática de tráfico

mutraff_tap_aon es un módulo MatLab que realiza la asignación estática de tráfico en una red (TAP) mediante el criterio All-Or-Nothing AON, dados un cierto mapa de red y una demanda de tráfico.

mutraff_tap_cum es un módulo MatLab que realiza la asignación estática de tráfico en una red (TAP) mediante el método de incrementos acumulativos (CUM), dados un cierto mapa de red y una demanda de tráfico.

mutraff_tap_mse es un módulo MatLab que realiza la asignación estática de tráfico en una red (TAP) mediante el método de medias sucesivas (MSE), dados un cierto mapa de red y una demanda de tráfico.

mutraff_tap_wei_lp es un módulo MatLab que realiza la asignación estática de tráfico en una red (TAP) mediante el método de aproximación por programación lineal diseñado por Wei et al. [133], dados un cierto mapa de red y una demanda de tráfico.

mutraff_tap_TWM es un módulo MatLab que realiza la asignación estática de tráfico en una red (TAP) mediante mapas TWM, dados un cierto mapa de red, una demanda de tráfico y un TWM.

Cuadernos de experimentos

Los cuadernos experimentales *LiveScript* de MatLab desarrollados han permitido generar numerosos escenarios de validación de los métodos sobre las configuraciones de red de tráfico definidas.

mutraff_exp_TAP cuaderno de experimentos que implementa el simulador macroscópico de asignación estática de tráfico para cualquier escenario del catálogo.

mutraff_exp_GA_TWM cuaderno de experimentos para el análisis de la generación de mapas óptimos tráfico TWM mediante algoritmos genéticos, para cualquier configuración de red de tráfico.

mutraff_exp_SWARM_TWM cuaderno de experimentos para el análisis de la generación de mapas óptimos tráfico TWM mediante algoritmos basados en *particle swarm*, para cualquier configuración de red de tráfico.

mutraff_exp_FUZZY_TWM cuaderno de experimentos para la simulación dinámica de la experiencia de usuario y evolución de la adopción de TWM en la red .

E

Medición del tráfico en la red urbana de Alcalá de Henares mediante técnicas de crowd-sensing

La técnica de toma de datos de tráfico mediante *crowd-sensing* consiste en la instalación de un software de medición específico en un terminal móvil de usuario que toma datos de forma constante respecto al movimiento del mismo (posición, velocidad instantánea, etc) y los publica en una nube de datos (*big-data*) para su posterior explotación. En muchas ocasiones la aplicación de toma de datos toma la forma de un root-kit que es una librería, normalmente comercial, que se recibe integrada en la aplicación que realmente se instala y que toma datos del usuario. El acceso de la aplicación a dichos datos debe ser consentido por el usuario aunque, en muchas ocasiones, éste desconoce su uso estadístico posterior. En ese sentido, muchas aplicaciones que se ofrecen gratuitamente contienen root-kits de recogida de datos para posteriormente comercializarlos una vez despersonalizados. Este mecanismo se ilustra en la Figura E.1:

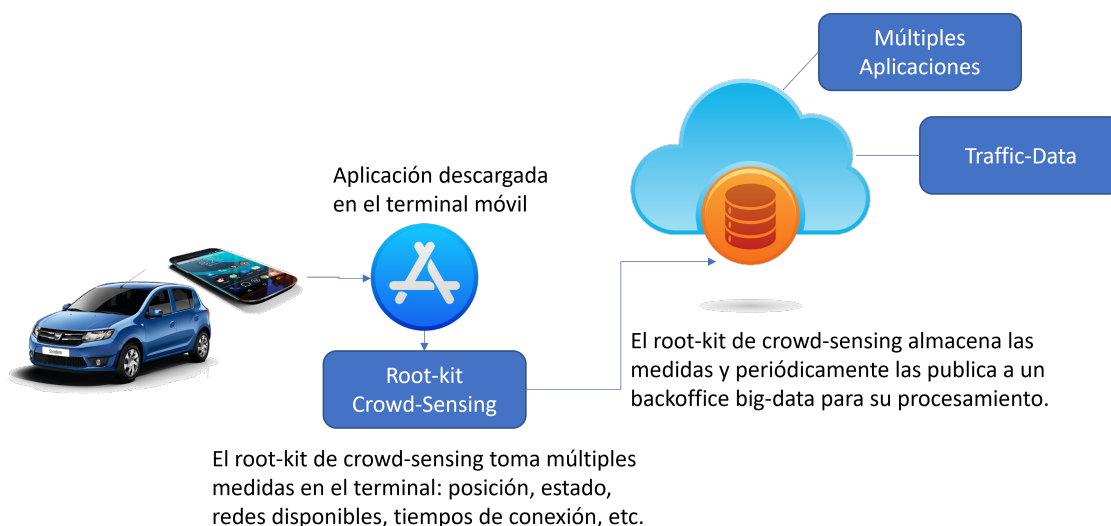


Figura E.1.: Mecanismo de toma de datos por crowd-sensing

Los mecanismos de *crowd-sensing* en el área de tráfico principalmente nos permiten tomar dos tipo de informaciones:

- Medidas de intensidad de flujo de tráfico, contabilizando el volumen de vehículos y su velocidad, que atraviesan la vía asociada a cierta coordenada geo-posicionada, en un cierto intervalo de tiempo
- Medidas de rutas de flujo, observando los trayectos seguidos por vehículos individuales en sus rutas O/D y sus tiempos de ruta.

La toma de datos en los experimentos ha sido posible mediante una cesión de datos anonimizados realizada por la empresa WePlan [134]. La estructura de los datos está representada en la Tabla E.1. Dado que no todos los vehículos llevan instalado y operativo el *root-kit* de *crowd-sensing* las medidas que tomemos deberán ser consideradas como muestras estadísticas.

En la Figura E.2 se representa el área muestreada para la toma de datos *crowd-sensing* para los experimentos de Alcalá de Henares.

Parámetro	Descripción	Tipología	Ejemplo de Valor
id	Identificador de la medida	integer	00001
timestamp_local	Marca de tiempo de la medida	timestamp	2019-10-05 12:00:00.000
agent_id	Identificador neutro del agente	string	0A023450BE4E5F
gps_latitude	Latitud GPS de la medida	float	40.50457897
gps_longitude	Longitud GPS de la medida	float	-3.34876469
gps_speed	Velocidad del agente en la medida	float	36.2

Tabla E.1.: Medidas tomadas del crowd-sensing



Figura E.2.: Selección de datos *crowd-sensing* para los experimentos de Alcalá de Henares

La Figura E.3 muestra la posición de los vehículos y mide su velocidad, asignando los códigos de colores azul para los vehículos rápidos y rojo para los lentos.

