



UNIVERSIDAD NACIONAL DEL SUR

TESIS DE DOCTOR EN INGENIERÍA

**Desarrollo de modelos y algoritmos para optimizar
redes logísticas de residuos sólidos urbanos**

Diego Gabriel Rossit

BAHÍA BLANCA

ARGENTINA

2018

Prefacio

Esta Tesis es presentada como parte de los requisitos para optar al grado Académico de Doctor en Ingeniería, de la Universidad Nacional del Sur, y no ha sido presentada previamente para la obtención de otro título en esta Universidad u otras. La misma contiene los resultados obtenidos en investigaciones llevadas a cabo en el Departamento de Ingeniería, durante el período comprendido entre el 1 de julio de 2014 y el 20 de marzo de 2018, bajo la dirección de los Doctores Fernando Abel Tohmé y Mariano Frutos.

Diego Gabriel Rossit
diegorossit@uns.edu.ar
DEPARTAMENTO DE INGENIERÍA
UNIVERSIDAD NACIONAL DEL SUR
Bahía Blanca, 20 de marzo de 2018.



UNIVERSIDAD NACIONAL DEL SUR
Secretaría General de Posgrado y Educación Continua

La presente tesis ha sido aprobada el ...19../...09.../..2018.,
mereciendo la calificación de10/10....(...SOBRESALIENTE..)

Agradecimientos

A Dios y la Patria.

A mi familia por el apoyo incondicional.

A mis amigos que se sienten parte de este logro.

A mis Directores, los Doctores Fernando Tohmé y Mariano Frutos, por su constante y permanente guía académica y acompañamiento humano.

A los Profesores Daniele Vigo y Silvano Martello de la Università di Bologna, Sergio Nesmachnow de la Universidad de la República de Uruguay y Diego Broz de la Universidad Nacional de Misiones por contribuir en mi formación.

A mis compañeros de trabajo los ingenieros Daniel Rossit, Antonella Cavallin, Nancy López, Adrián Toncovich, Adrián Castaño y Luciano Sívori.

Al Instituto de Investigaciones Económicas y Sociales del Sur y al Departamento de Ingeniería de la Universidad Nacional del Sur por brindarme el espacio para desarrollar este trabajo.

Al Programa Erasmus Mundus de la Unión Europea y a la Asociación de Universidades Grupo Montevideo por brindarme la oportunidad de realizar estancias de formación en el exterior.

Al Consejo Nacional de Investigaciones Científicas y Técnicas y, a través suyo, a la Sociedad Argentina por su apoyo primordial para hacer posible la realización de esta Tesis.

¡Muchas Gracias!

Resumen

La vida es muy peligrosa. No por las personas que hacen el mal, sino por las que se sientan a ver lo que pasa.

Albert Einstein (1879-1955)

La creciente urbanización e industrialización de la sociedad, sumado a una disponibilidad finita de recursos naturales, vuelve primordial hallar soluciones sustentables y eficientes que permitan la valorización de los residuos y su reincorporación nuevamente en forma de recursos al sistema productivo o, en su defecto, su correcta disposición final. Estas soluciones no sólo deben mitigar los importantes impactos ambientales asociados a un manejo inadecuado de residuos sino también, a través de una implementación simple y poco costosa, deben contribuir a la prosperidad de las comunidades, sobretodo aquellas que presentan acuciantes problemas de desarrollo. La Investigación Operativa, disciplina que consiste en el uso de modelos matemáticos y computacionales con objeto de racionalizar el proceso de toma de decisiones, puede realizar un aporte fundamental en el logro de sistemas eficientes que permitan satisfacer las necesidades actuales de la sociedad sin comprometer las generaciones futuras. Es por eso que en esta Tesis se analizan modelos para el diseño de los primeros eslabones de la cadena de logística inversa de Residuos Sólidos Urbanos (RSU) diferenciados en un ambiente urbano. En la primer parte, se aborda el problema de optimizar la localización de puntos de acumulación de residuos en un entorno urbano, a través de un sistema de contenedores comunitarios, considerando los objetivos de minimizar el costo del sistema así como maximizar la calidad del servicio brindado. Los modelos se aplican sobre escenarios de dos ciudades distintas. La primera es la ciudad de Bahía Blanca (Argentina), donde se comparan dos métodos para optimizar problemas multiobjetivo discretos. El segundo caso se corresponde a la ciudad de Montevideo (Uruguay), donde debido a la mayor complejidad de los escenarios se propone una reforma a uno de los métodos utilizados en el caso anterior a los efectos de poder abordar el problema. En ambos caso se logran obtener un conjunto de soluciones mutiobjetivo del problema. La segunda parte de este trabajo se enfoca sobre los problemas de ruteo de vehículos para optimizar los recorridos de los transportes que deben recolectar los residuos acumulados. Luego de un primer análisis, se encuentra un tema que aún no ha sido completamente estudiado en la literatura, y que ha sido aplicado en problemas de transporte de RSU, como lo es el concepto de “atracción visual” en

problemas de ruteo. Se desarrolla una extensa revisión del concepto de atracción visual, analizándose su origen, su relación con los objetivos tradicionales y su importancia en las aplicaciones prácticas de la planificación de rutas. Además, se aplican y comparan las diversas métricas utilizadas para medir atracción visual disponibles en la literatura a los encontrando similitudes entre algunas de las métricas y, a partir de ello, se realizan recomendaciones para que otros autores puedan elegir la métrica que mejor se ajuste a sus intereses. Finalmente, se presenta una heurística para optimizar la atracción visual en una variante del problema de ruteo, la cual logra mejorar la atracción visual con respecto a otras soluciones propuestas en la literatura para un conjunto de instancias.

Abstract

The world is a dangerous place to live; not because of the people who are evil, but because of the people who don't do anything about it.

Albert Einstein (1879-1955)

An increasing urbanized and industrialized society, in addition to a shortage of natural resources, has put pressure on the necessity of implementing efficient and sustainable policies that allow the recovery of the resources that are present in our waste, or, at least, allow a suitable final disposition. These policies should not only mitigate the severe environmental impacts associated to garbage mishandling but also, through an inexpensive and straightforward implementation, help to enhance the prosperity of the communities, especially those that are struggling to find a path of sustainable development. Operations Research, a discipline that consists in the development of support tools for the decision-making process through mathematical and computational models, can enormously contribute to obtain efficient systems that satisfy the current society needs without reducing the chances of future generations to have an equally high standard of living. For these reasons, in this Thesis different models to optimize the initial stages in the reverse logistic chain of Municipal Solid Waste (MSW) are analyzed. On the first stage, the problem of optimizing the location of garbage accumulation points in an urban area, while considering the aims of reducing investment costs and enhancing the quality of service, is addressed. The models are applied to scenarios that belong to two different cities. The first one is the Argentinian city of Bahía Blanca, where two different multiobjective resolution methods for discrete problems are compared. The second case corresponds to the Uruguayan city of Montevideo, where due to the higher complexity of the analyzed scenarios a slight reform has to be made to the resolution method used in the first city. In both cases it was possible to obtain a set of multiobjective solutions of the proposed scenarios. The second part of this Thesis focuses on the routing problems in waste management. After an initial revision, it was found that some works consider visual attractiveness in their optimization process, a topic that has not been completely studied yet. A throughout bibliographic review is performed in order to shed some light on the concept of visual attractiveness and its importance for real-world applications. Furthermore, the different metrics that are used in the literature are compared with the aim of finding similarities and making suggestions about the suitability of each metric in

different contexts. Finally, a heuristic to that is able to optimize visual attractiveness in a variant of routing problems is proposed.

Índice

Agradecimientos	III
Resumen	IV
Abstract	VI
I Conceptos básicos	1
1. Introducción	2
1.1. Motivación y alcance de la Tesis	2
1.1.1. Objetivos de la Tesis	3
1.2. Logística Inversa	4
1.3. Residuos Sólidos Urbanos: desafíos en la gestión	4
1.3.1. La Investigación de Operaciones y la toma de decisiones en la gestión de RSU	6
1.3.2. Panorama actual y herramientas para la toma de decisiones en la gestión de RSU en Argentina	7
1.4. Estructura de la tesis	8
II Modelos para la localización de contenedores de residuos	10
2. El problema de localización de contenedores	11
2.1. Revisión bibliográfica	12
2.1.1. Complejidad computacional del problema de localización de GAPs	17
2.2. Métodos multiobjetivo para programación entera	17
2.2.1. Método de las ponderaciones	18
2.2.2. Método de las ε -restricciones	18
2.2.3. Método de las ε -restricciones aumentado	19
2.3. Casos de aplicación: Bahía Blanca y Montevideo	22

3. Caso de aplicación: Bahía Blanca	23
3.1. Formulación del problema	24
3.2. Evaluación experimental	26
3.2.1. Resultados	28
3.2.2. Análisis de resultados	32
3.3. Discusión de los resultados	37
4. Caso de aplicación: Montevideo	38
4.1. Formulación matemática del problema	41
4.1.1. Enfoque de resolución	45
4.2. Evaluación experimental	47
4.2.1. Resultados	48
4.2.2. Análisis de resultados	49
4.3. Discusión de resultados	59
III Atracción visual en problemas de ruteo de vehículos	60
5. Atracción visual en problemas de ruteo de vehículos	61
5.1. Origen y beneficios de la atracción visual en aplicaciones prácticas	62
5.1.1. Percepción humana en el Problema del Agente Viajero	65
5.1.2. Atracción visual y costo de los problemas de ruteo: ¿siempre una relación negativa?	66
5.2. Revisión de la literatura	68
5.2.1. Atracción visual en problemas de ruteo	68
5.2.2. Atracción visual en problemas de Delimitación de Distritos	72
5.2.3. Características de los algoritmos utilizados	73
5.2.4. Discusión	73
6. Análisis de las métricas para medir la atracción visual	75
6.1. Compacidad en rutas	75
6.2. Solapamiento de rutas y cruces	78
6.3. Complejidad de las rutas	79
6.4. Métricas de atracción visual: descripción y experimentación	82
6.4.1. Descripción de métricas	82
6.4.2. Evaluación experimental	85
6.4.3. Recomendaciones	105
7. Heurística para optimizar la atracción visual en un CVRP	106
7.1. Descripción de la heurística	106
7.1.1. Aceptación de una nueva solución	106
7.1.2. Solución inicial	107

7.1.3. Operadores de búsqueda local	107
7.1.4. Reconstrucción	108
7.2. Experimentación computacional	110
7.2.1. Resultados	112
7.3. Discusión de resultados	112
IV Conclusiones	114
8. Conclusión: un intento por resolver problemas reales	115
8.1. Localización de contenedores	115
8.2. Ruteo de vehículos	116
8.3. Líneas de trabajo a futuro	117
Bibliografía	118

Índice de figuras

2.1. Metodología de diseño de un sistema de recolección	16
2.2. Diagrama de flujo del método AUGMECON2	21
3.1. Región estudiada de la ciudad de Bahía Blanca	27
3.2. Frente de Pareto del primer escenario. Método de las ponderaciones	33
3.3. Frente de Pareto del primer escenario. Método AUGMECON2	34
3.4. Frente de Pareto del segundo escenario. Método de las ponderaciones	34
3.5. Frente de Pareto del segundo escenario. Método AUGMECON2	35
3.6. Frente de Pareto del tercer escenario. Método de las ponderaciones	35
3.7. Frente de Pareto del tercer escenario. Método AUGMECON2	36
4.1. Región estudiada de la ciudad de Montevideo	39
4.2. GAPs actuales y potenciales en el área de estudio	40
4.3. Diferencias entre el peor valor posible sobre la región factible y sobre la frontera eficiente	46
5.1. Diferentes soluciones en una instancia de CVRP	63
5.2. Diferentes soluciones en una instancia de VRPTW	64
6.1. Diferencias entre cascos convexos de rutas	79
6.2. Diferentes soluciones a un problema de TSP	80
6.3. Ejemplo de cálculo del <i>Cross Length Percentage</i>	86
6.4. Matriz de correlación de la Clase C	97
6.5. Matriz de correlación de la Clase R	98
6.6. Matriz de correlación de la Clase RC	99
6.7. Matriz de correlación de las instancias de Uchoa	100
6.8. Ejemplos de soluciones con distintos valores de $COMP^a$	101
6.9. Ejemplos de soluciones con distintos valores de $COMP^b$	102
6.10. Ejemplos de soluciones con distintos valores de $COMP^c$	102
6.11. Ejemplos de soluciones con distintos valores de $PROX^a$	102
6.12. Ejemplos de soluciones con distintos valores de $PROX^b$	103
6.13. Ejemplos de soluciones con distintos valores de $PROX^c$	103

6.14. Ejemplos de soluciones con distintos valores de $Intra - C$	103
6.15. Ejemplos de soluciones con distintos valores de BE	104
7.1. Heurística para optimizar la atracción visual en un CVRP	109
7.2. Búsqueda local para optimizar la atracción visual en un CVRP	110
7.3. Ejemplo de solución para una instancia CVRP	112

Índice de Tablas

3.1. Modelo Bahía Blanca: conjuntos, parámetros y variables del modelo	25
3.2. Primer escenario: resultados para diez puntos grilla	29
3.3. Primer escenario: resultados para veinte puntos grilla	29
3.4. Segundo escenario: resultados para diez puntos grilla	30
3.5. Segundo escenario: resultados para veinte puntos grilla	30
3.6. Tercer escenario: resultados para diez puntos grilla	31
3.7. Tercer escenario: resultados para veinte puntos grilla	31
4.1. Modelo Montevideo: conjuntos, parámetros y variables del modelo	42
4.2. Valores extremos primer escenario: método secuencial	49
4.3. Valores extremos primer escenario: paralelismo determinista	50
4.4. Valores extremos primer escenario: paralelismo oportunista	50
4.5. Matriz de pagos del primer escenario	51
4.6. Valores extremos segundo escenario: método secuencial	51
4.7. Valores extremos segundo escenario: paralelismo determinista	51
4.8. Valores extremos segundo escenario: paralelismo oportunista	52
4.9. Matriz de pagos del segundo escenario	52
4.10. Soluciones multiobjetivo primer escenario: método secuencial	54
4.11. Soluciones multiobjetivo primer escenario: paralelismo determinista	54
4.12. Soluciones multiobjetivo primer escenario: paralelismo oportunista	55
4.13. Soluciones multiobjetivo segundo escenario: método secuencial	56
4.14. Soluciones multiobjetivo segundo escenario: paralelismo oportunista	56
4.15. Soluciones multiobjetivo segundo escenario: paralelismo oportunista	57
4.16. Soluciones no dominadas del primer escenario.	58
4.17. Soluciones no dominadas del segundo escenario.	58
6.1. Definiciones del centro de una ruta	77
6.2. Bibliografía principal sobre atracción visual en problemas VRP	81
6.3. Análisis de tiempos del peor caso de las métricas de atracción visual. . . .	83
6.4. Métricas de atracción visual para la C	88
6.5. Métricas de atracción visual para la Clase R	89

6.6. Métricas de atracción visual para la Clase RC	90
6.7. Métricas de atracción visual para las instancias de Uchoa (a)	92
6.8. Métricas de atracción visual para las instancias de Uchoa (b)	93
6.9. Métricas de atracción visual para las instancias de Uchoa corregidas	94
7.1. Resultados de heurística de CVRP	111

Parte I

Conceptos básicos

Capítulo 1

Introducción

1.1. Motivación y alcance de la Tesis

Esta Tesis fue desarrollada en el marco de las actividades para obtener el título de Doctor en Ingeniería en la Universidad Nacional del Sur, comenzando dichos estudios en abril del 2014 y finalizando en febrero 2018. Durante este lapso de tiempo la temática inicial sobre logística inversa fue focalizándose en la gestión de los Residuos Sólidos Urbanos. Dentro de esta actividad se evidenciaron las grandes dificultades que acarrear muchas ciudades argentinas en generar mecanismos válidos para volver más eficiente la gestión de RSU, sobre todo teniendo en cuenta que la falta de clasificación en origen de los residuos es, en numerosas ocasiones, un obstáculo infranqueable para la sustentabilidad del sistema. La separación posterior (en destino) de los residuos es mucho más costosa e ineficiente debido a la alta contaminación cruzada entre distintos tipos de desechos (Tai et al., 2011; Zhuang et al., 2008).

Si bien existen diversas localidades que llevan adelante un sistema de recolección diferenciada, son una minoría. La mayor parte de estas aglomeraciones urbanas son ciudades de primer orden nacional, por ejemplo, son capitales de regiones administrativas o de ricas cuencas económicas, que poseen recursos financieros y humanos adecuados para diseñar estrategias de gestión eficientes y sustentables. Asimismo, estas ciudades particulares constituyen, en general, puertas de ingreso al país o son importantes centros turísticos, por lo tanto existe un incentivo adicional para proyectar una imagen de pulcritud y/o eficiencia en la gestión de sus residuos. Entre ellas podemos mencionar la Ciudad Autónoma de Buenos Aires, Rosario y Salta. No obstante, existen otras ciudades con menor dotación de recursos que han logrado contrarrestar esta carencia con una importante determinación política y compromiso ciudadano, como es el caso de diversas localidades de la Provincia de Entre Ríos.

La intención inicial de esta tesis fue colaborar con ciudades que podrían pertenecer a este segundo conjunto a través del desarrollo de herramientas de apoyo al proceso de tomas de decisiones en la gestión de los desechos urbanos. De los diversos eslabones de la cadena logística se trabajó con los tramos iniciales: los procesos de acumulación de residuos y la recolección.

El sistema de contenedores comunitarios, donde los usuarios trasladan sus residuos desde sus hogares hacia los contenedores cercanos, es preferible al sistema puerta a puerta no sólo porque implica una disminución de los costos (Bonomo et al., 2012; Valeo et al., 1998) sino también porque mejora las condiciones de trabajo de los trabajadores recolectores (Vives et al., 2012). La ciudad de Bahía Blanca, la cual si bien posee ciertas características destacables (por ejemplo, un puerto con un importante calado natural, un polo industrial de dimensión considerable y una universidad por demás prestigiosa), no constituye una ciudad de primer orden a escala nacional. En esta ciudad, donde la recolección se efectúa actualmente bajo un sistema puerta a puerta se implementó un modelo para encontrar ubicaciones óptimas para los contenedores de residuos. Se evidenciaron una serie de obstáculos al momento de implementar el modelo en esta ciudad, sobre todo en cuanto a la recolección de información poblacional y geográfica. Por el contrario, al momento de realizar una estadía de estudio en la ciudad de Montevideo, ciudad que ya cuenta con un servicio de contenedores comunitarios, se utilizó la base de datos más consolidada que posee dicha ciudad para aplicar un modelo ampliado con la consideración de nuevos objetivos y datos de entrada.

La segunda parte de la tesis se centró sobre los problemas de ruteo de vehículos, los cuales están presentes en la fase de recolección de los residuos que es una parte esencial del sistema de gestión de RSU, sobre todo en nuestro país donde los costos logísticos son elevados (Broz et al., 2018). Revisando los diversos trabajos que se desarrollaron en este campo se encontró que algunos de ellos trataban el tema de la atracción visual. Al intentar profundizar sobre este concepto se encontraron una gran variedad de trabajos y métricas desarrollados por diversos autores. Por lo tanto, se procedió a intentar generar un aporte mediante un trabajo de revisión amplio que evaluara la naturaleza de este concepto, su importancia y su origen. Además, se evaluaron las distintas métricas utilizadas a los efectos de generar recomendaciones sobre que métrica utilizar en algunas situaciones particulares. Finalmente, se desarrolló una heurística que permite optimizar este aspecto.

1.1.1. Objetivos de la Tesis

Por lo tanto, los objetivos que se plantean en esta Tesis son los siguientes:

- Abordar el problema de localización de puntos de acumulación de residuos sólidos urbanos mediante la propuesta de modelos matemáticos y algoritmos de resolución basados en dos casos de estudio, uno de la ciudad de Bahía Blanca y otro de la ciudad de Montevideo.
- Abordar los problemas de ruteo de vehículos que consideran la optimización del concepto de atracción visual mediante el estudio del origen y la importancia de este concepto en los problemas de ruteo, el análisis y la comparación de las diversas métricas que existen para medir la atracción visual en los planes de rutas y proponer una heurística para optimizar la atracción visual en los problemas de ruteo.

1.2. Logística Inversa

Durante muchos años, y antes de que la Revolución Industrial marcara para siempre el desarrollo de la humanidad, la industria primitiva no se constituía como un factor importante de deterioro ambiental. Los nuevos mecanismos y formas de producción, junto con la explotación intensiva y sistemática de los recursos naturales, se fueron generalizando, sin prever los efectos de la misma sobre el medio ambiente. Aunque a finales de los años 50 y principios de los 60 empezó a manifestarse una conciencia medioambiental, no es hasta la década de los 70 cuando los procesos de deterioro ambiental y agotamiento de los recursos naturales se hacen evidentes, así como sus costos asociados. Surgen términos similares al de logística inversa tales como “Canales inversos” (Guiltinan y Nwokoye, 1975). De esta forma, se comienza a buscar, por un lado, formas alternativas de crecimiento y desarrollo económico que eviten continuar con los procesos de deterioro ambiental, y por otro lado, mecanismos que permitan la recuperación y saneamiento del medioambiente. A partir de los años 80, la sociedad intenta modificar progresivamente actitudes y normas de conducta que le permitan obtener mejoras en su entorno ambiental o, al menos, reducir el impacto negativo que ejerce sobre el medioambiente (Cabeza, 2012). De esta forma, términos tales como contaminación, impacto ambiental, efecto invernadero, residuos, reciclaje o ahorro energético, se han hecho habituales en la actualidad. El mundo industrial y empresarial no ha sido ajeno a esta situación y ha comenzado a considerar los aspectos ambientales y ecológicos como variables de decisión a la hora de formular su estrategia empresarial. Si bien esta actuación es fomentada principalmente por imperativos legales más que por requerimientos de mercado, cada vez son más las empresas que incorporan en su gestión consideraciones medioambientales. Del mismo modo, las administraciones públicas han comenzado a intentar dar respuesta a las inquietudes ciudadanas al respecto, adoptando medidas tendientes a reducir el impacto negativo de la actividad humana sobre su entorno natural. Entre estas acciones destacan las destinadas a disminuir la generación de residuos, incentivando las actividades de recuperación, reciclaje y reutilización de los productos (Fleischmann et al., 1997). Esto dio origen al concepto de logística inversa que puede definirse como la gestión, planificación, implementación y control de flujos inversos de materia prima, materiales en proceso o productos terminados desde un punto de procesamiento, distribución o uso hacia un punto de recuperación o disposición final (De Brito y Dekker, 2004).

1.3. Residuos Sólidos Urbanos: desafíos en la gestión

La definición de logística inversa implica, primero, el transporte físico de los productos usados desde el consumidor final hacia el punto de recupero o disposición para luego, en el siguiente etapa, proceder a transformar estos desechos en productos que puedan reincorporarse al sistema productivo o, en su defecto, realizar una disposición final adecuada (Fleischmann et al., 1997). De ambas etapas el foco de esta tesis se centra en la primera donde, naturalmente, el concepto de logística inversa involucra la gestión de los Residuos Sólidos Urbanos (RSU). Una definición precisa de RSU puede hallarse en la

Ley 13.592 de la Provincia de Buenos Aires, Argentina, (2010). En la misma se define a los residuos sólidos urbanos (RSU) como aquellos elementos, objetos o sustancias generados y desechados, producto de actividades realizadas en los núcleos urbanos y rurales, comprendiendo aquellos cuyo origen sea doméstico, comercial, institucional, asistencial e industrial no especial asimilable a los residuos domiciliarios. Con un espíritu similar, la Ley 25.916 de la Nación Argentina (2004) denomina residuo domiciliario a aquellos elementos, objetos o sustancias que como consecuencia de los procesos de consumo y desarrollo de actividades humanas, son desechados y/o abandonados.

En las sociedades actuales la gestión de RSU, se ha convertido en un tema acuciante para las autoridades. No sólo porque involucra una gran parte de los recursos presupuestarios de los gobiernos locales, que son los que generalmente se encargan de la gestión de los RSU (Hoornweg y Bhada-Tata, 2012; Pradhan et al., 2012), sino también porque su mal manejo está asociado a grandes problemáticas ambientales y sociales. A pesar de que varios de estos costos ambientales son de difícil solución, por ejemplo la emisión gases de efecto invernadero en los rellenos sanitarios (Kennedy et al., 2011), otros pueden limitarse mediante una gestión adecuada, como la contaminación visual asociada a la disposición inadecuada o la problemática de los recolectores informales (Wilson et al., 2006). Estas problemáticas se acentúan en los países en vías en desarrollo debido a restricciones presupuestarias y tecnológicas (Kinobe et al., 2012). Además, la gestión de RSU posee una complejidad intrínseca mayor que la gestión de otras corrientes de desechos que poseen una naturaleza más homogénea (Guerrero et al., 2013; Troschinetz y Mihelcic, 2009; Sáez y Urdaneta, 2014), como los residuos industriales o comerciales. El panorama se completa si además consideramos que la tasa de generación de residuos por habitante en el mundo continúa creciendo a una tasa ascendente que es, incluso, mayor a la tasa de urbanización (Hoornweg y Bhada-Tata, 2012; Hoornweg et al., 2015). Estimaciones científicas recientes establecen que la tasa per cápita de generación de RSU mantendrá su tendencia creciente por lo menos hasta el año 2075, siendo este el escenario más favorable donde se incluyen importantes campañas de concientización que reduzcan el excesivo materialismo de la población (Hoornweg et al., 2015). El mismo informe sitúa el pico de generación en el año 2100 para un escenario menos favorable. Esto se debe a que al natural desarrollo urbanístico y aumento de la densidad poblacional se suma el incremento en el consumo de productos desechables, descartables o de rápida obsolescencia (Cavallin et al., 2016). Por ejemplo, de acuerdo a informes oficiales del Gobierno Argentino (2015), en el 2012 se generó en promedio 1 kilogramo de RSU por habitante por día contra un valor de 0,86 en la anterior medición (año 2009). Por su parte Troschinetz y Mihelcic (2009) calcularon en 0,77 kg el promedio de generación de RSU por habitante diario en países en vías de desarrollo. Este panorama conlleva que nuestro planeta aún debe hacer frente a una cantidad mucho mayor de residuos que los que administra hoy en día en el futuro cercano (Hoornweg et al., 2013). Por lo tanto, se hace necesario incorporar tecnología a los procesos a los efectos de favorecer la reducción de residuos, la reutilización los y el reciclado de los mismos o, en su defecto, la disposición final adecuada que pueda disminuir el impacto sobre el medio actual y que permita volver a disponer de estos desechos en el caso que, en el futuro, se desarrollen las tecnologías adecuadas para reintroducirlos

al sistema productivo.

1.3.1. La Investigación de Operaciones y la toma de decisiones en la gestión de RSU

A pesar de que frecuentemente se ubican los inicios de la Investigación de Operaciones (IO) en tiempos de la Segunda Guerra Mundial, momento en el cual surgieron algunos de los primeros modelos de sistemas junto a los métodos para su resolución (Anderson et al., 2015; Hillier y Hillier, 2013), conceptos similares ya habían sido propuestos con anterioridad cuando profesionales curiosos de las áreas de matemática, estadística y física se enfrentaban a problemas complejos de temas que les eran poco familiares (Gass y Assad, 2005). La *International Federation of Operational Research Societies* (IFORS)¹ define a la Investigación Operativa como una disciplina que se encarga de la aplicación de métodos analíticos avanzados para contribuir a la toma de mejores decisiones en una organización. La IO intenta encontrar soluciones óptimas o “suficientemente buenas” a problemas de naturaleza compleja valiéndose de herramientas tales como la simulación, la optimización matemática, la teoría de colas, las cadenas de Markov, análisis estadísticos, redes neuronales, inteligencia artificial, entre otros. La IO también considera cuestiones de eficiencia en el proceso de toma de decisiones; es decir, no sólo le interesa resolver eficazmente los problemas sino también los recursos que se utilizan en el proceso, como por ejemplo la capacidad de cómputo y el tiempo de cálculo. De esta forma, se relaciona estrechamente con las ciencias computacionales y la ingeniería constructiva a través de, por ejemplo, la Computación de Alto Rendimiento o las modernas Tecnologías de la Información y Comunicación (TICs o ICTs, por su denominación en inglés *Information and Communications Technologies*).

Por lo tanto, en la sociedad actual donde las decisiones afectan a un número creciente de personas y donde es cada vez más complejo predecir las interrelaciones entre diversos factores, el valioso conocimiento empírico puede apoyarse en la IO para mejorar la calidad y coherencia de sus decisiones (Rossit et al., 2015a; Cavallin et al., 2017b). Este es el caso de la gestión de RSU donde las complejidades descritas en la Sección 1.3 dificultan el proceso de toma de decisiones. La literatura sobre el desarrollo de herramientas de IO para la gestión de los sistemas logísticos de los RSU es abundante. Ghiani et al. (2014a) y Bing et al. (2016) realizan extensos análisis de la bibliografía existente en esta temática. Si bien ambos tienen un enfoque generalista, abarcando varias áreas donde la IO puede contribuir a la gestión de los desechos urbanos, el primero se encuentra enfocado a decisiones estratégicas y tácticas mientras que el segundo a problemas principalmente logísticos. Asimismo, pueden encontrarse otras revisiones bibliográficas valiosas circunscritas a un campo particular de la aplicación de la IO en la gestión de RSU: Hannan et al. (2015) realizan una revisión de la literatura en cuanto a la aplicación de las ICT en la gestión de RSU; Purkayastha et al. (2015) presentan un análisis de modelos enfocados en la localización de contenedores receptores de residuos; Goulart Coelho et al. (2017); Soltani et al. (2015) evalúan la aplicación de modelos multicriterio en la gestión de RSU;

¹<http://www.ifors.org/>

y Han y Ponce Cueto (2015); Beliën et al. (2012); Golden et al. (2002) se enfocan en la revisión de modelos de enrutamiento de vehículos aplicados a los RSU.

1.3.2. Panorama actual y herramientas para la toma de decisiones en la gestión de RSU en Argentina

Argentina como el resto de América Latina ha tenido tradicionalmente un sistema de gestión de RSU deficitario (Acurio et al., 1998; Schejtman y Cellucci, 2014; González, 2010). Desde la promulgación de la Ley 25.916 2004, se dio comienzo a una serie de iniciativas provinciales y municipales para cumplir con los objetivos propuestos que apuntaban a una reducción y valorización de los desechos. Un año más tarde se presentó la “Estrategia Nacional para la Gestión Integral de Residuos Sólidos Urbanos” 2005 para trazar un plan de acción para cumplimentar esta ley. Cada ciudad comenzó por realizar las mejoras necesarias según el estado en el que se encontraba su respectivo sistema de GIRSU (erradicación de basurales a cielo abierto, construcción de rellenos sanitarios, disposición de contenedores para recolectar materiales reciclables, desarrollo de sistemas de recolección diferenciada de RSU, instalación de plantas de acopio y/o tratamiento de RSU, entre otras). En ciudades argentinas importantes, como la Ciudad Autónoma de Buenos Aires (2005) y Rosario, se realizaron adaptaciones de la normativa nacional a sus realidades locales. De esta forma, los cambios y avances en algunos municipios fueron notables, mientras que en otros se mantiene la falta de un tratamiento integral de los RSU. Datos de un informe sobre el estado de la gestión de residuos en el país Ministerio de Medio Ambiente y Desarrollo Sustentable, Argentina (2016) revelan que el porcentaje de cobertura de recolección de RSU por provincia ha mejorado en los últimos años, superando el 80 % promedio, mientras que el porcentaje de disposición adecuada en relleno sanitarios, a nivel país, alcanza el 61 % de habitantes, identificando a provincias como Neuquén, San Juan, Tucumán, Misiones y Gran Buenos Aires con porcentajes superiores al 80 %, mientras que en otros casos se registran números inferiores al 20 %. En la provincia de Buenos Aires, alrededor de un 85 % de los municipios poseen una disposición final adecuada de RSU. En cuanto a iniciativas de tratamiento de RSU, el mismo informe realiza un relevamiento de las plantas de separación municipales por provincia, indicando en el país un promedio de 37 % de alcance de la población y en la Provincia de Buenos Aires un 76 %. Según un relevamiento reciente (Cavallin y Rossit, 2017) son diversas las ciudades que cuentan con procesos de clasificación de residuos en Argentina. La mayoría de ellas ubicadas en la región central del país (Mendoza, Córdoba, Santa Fé, Entre Ríos y Buenos Aires) aunque existen algunas excepciones como la noroesteña ciudad de Salta (Tufró et al., 2012). Sin embargo, varias de estas ciudades aún continúan realizando un servicio puerta a puerta donde la recolección diferenciada es realizada mediante el establecimiento de un calendario particular para cada corriente de residuo lo que complejiza la logística del transporte. Algunas excepciones que trabajan con contenedores comunitarios son, por ejemplo, la ciudad de Buenos Aires (Bonomo et al., 2012) y algunos sectores de Concordia y Rosario (Gandara y Guerrero, 2013).

En Argentina, el diseño de sistemas de gestión de RSU se basa mayormente en cono-

cimientos empíricos de los tomadores de decisiones lo cual es común para países en vía de desarrollo (Hua et al., 2016). Sin desmerecer el invaluable aporte que puede realizarse desde la práctica y la experiencia, la bibliografía es amplia en el aporte tanto en términos de reducción de costos como de impacto ambiental, que pueden brindar la utilización de técnicas de apoyo a la toma de decisiones (véase Sección 1.3.1). En este sentido, pueden encontrarse varios aportes en distintas ciudades argentinas. Por ejemplo, en la ciudad de Río Cuarto se han aplicado diversos algoritmos para diseñar las rutas de recolección de residuos infecciosos, incluyendo combinaciones de técnicas exactas y heurísticas (Simón et al., 2012) y algoritmos puramente heurísticos, tanto genéticos (Méndez et al., 2004) como meméticos (Méndez et al., 2010, 2009). Naturalmente debido a su condición de principal urbe argentina, otra ciudad que ha recibido especial atención en este campo es la Ciudad de Buenos Aires. Bonomo et al. (2009) y Larrumbe (2009) implementan modelos de programación lineal para optimizar las rutas de recolección de contenedores de residuos en la zona sur de la Ciudad de Buenos Aires. Bonomo et al. (2012) también trabajan optimizando las rutas en esta zona teniendo como objetivos no sólo minimizar las distancias de recorrido sino también minimizar el desgaste de los vehículos. En Concordia, Bertero (2015) presenta una aplicación para diseñar las rutas de recolección de la ciudad haciendo un esfuerzo por minimizar la cantidad de giros para volver las rutas más aceptables por los tomadores de decisiones. Bianchetti (2015) presenta un algoritmo para resolver la zonificación de la ciudad de San Miguel de Tucumán a los efectos de optimizar el uso de recursos, reasignando camiones hacia la zona céntrica de la ciudad. En Braier et al. (2015, 2017) se elabora un modelo de programación entera para la recolección de residuos reciclables en la ciudad de Morón, Provincia de Buenos Aires. En el sudoeste de la Provincia de Buenos Aires encontramos los trabajos presentados por Rossit et al. (2014, 2015c), que elaboran un ensayo que simula la instalación de contenedores de residuos plásticos en un sector urbano de la ciudad de Bahía Blanca. En Rossit et al. (2015b) se presenta un enfoque integral que determina la localización de los contenedores como el diseño de la ruta que efectúa la recolección de su contenido. En Cavallin et al. (2015a,b) se presentan modelos de ruteo de vehículos con balanceo de distancias entre las distintas rutas para diseñar los recorridos de los recolectores informales de residuos reciclables en Bahía Blanca. También se han desarrollado evaluaciones de eficiencia mediante técnicas análisis envolvente de datos (DEA por sus siglas en inglés) (Cavallin et al., 2016) y de este técnica DEA combinada con redes neuronales (Cavallin et al., 2017a).

1.4. Estructura de la tesis

Esta Tesis se encuentra estructurada de la siguiente forma. Luego del presente capítulo introductorio se desarrollan dos Partes (II y III) que hacen al desarrollo de la Tesis y una Parte final (IV) que presenta las principales conclusiones. La Parte II se enfoca en los problemas de localización de contenedores. En esta Parte se presenta el Capítulo 2 que introduce el tipo de problema de localización de puntos de acumulación de residuos, el Capítulo 3 que describe el caso de aplicación en la ciudad de Bahía Blanca y el Capítulo 4 que desarrolla el caso de aplicación en la ciudad de Montevideo. La Parte III presenta

modelos de ruteo de vehículos, particularmente la aplicación de conceptos de atracción visual. En ella se encuentra el Capítulo 5 que realiza una revisión de la bibliografía existente en la temática, un análisis de la relación del concepto de atracción visual con los objetivos tradicionales y su importancia en las aplicaciones prácticas. En el Capítulo 6 se efectúa una comparación entre las distintas métricas en la literatura para medir la atracción visual de un plan de rutas. En el Capítulo 7 se propone un algoritmo heurístico para crear rutas visualmente atractivas. Finalmente, en el Capítulo 8 de la Parte IV, se presentan las principales conclusiones de esta Tesis y las líneas de trabajo a futuro. Esta Tesis fue escrita utilizando la plantilla $\text{T}_{\text{E}}\text{X}_{\text{S}}$ desarrollada para $\text{L}^{\text{A}}\text{T}_{\text{E}}\text{X}$ por Gómez Martín y Gómez Martín (2009).

Parte II

Modelos para la localización de contenedores de residuos

Capítulo 2

El problema de localización de contenedores: puerta de entrada al sistema de RSU

Como en cualquier cadena logística, en los sistemas de gestión de RSU los actores involucrados o *stakeholders* deben tomar diversas decisiones a nivel estratégico, táctico u operativo. Bing et al. (2016) y Ghiani et al. (2014a) consideran que un sistema de RSU puede ser dividido en dos subsistemas principales: un sistema de manejo regional y un sistema de recolección. El primero es generalmente administrado por autoridades regionales e involucra decisiones estratégicas que tienen un impacto en el largo plazo dentro de la cadena logística. En este tipo de decisiones pueden incluirse la selección de las tecnologías de tratamiento de RSU, la localización de lugares de acumulación y tratamientos de residuos y las estrategias de expansión de las capacidades de estos lugares. Por otro lado, el sistema de recolección involucra decisiones de nivel táctico como la asignación de las corrientes de residuos a las plantas de tratamiento y rellenos sanitarios, los patrones de frecuencia de recolección y la administración de las rutas de los vehículos recolectores.

De acuerdo a Tchobanoglous et al. (2002) un sistema de gestión de RSU está conformado por diversos elementos funcionales: generación de residuos; manejo, separación, acumulación y procesamiento de residuos en origen; recolección; transferencia y transporte; separación, procesamiento y transformación de residuos sólidos; y disposición final. Varios de estos elementos pueden ser afectados por las decisiones y estrategias que son implementadas en los eslabones iniciales de esta cadena logística. En otras palabras, el número de puntos de recolección (en adelante denominados puntos de acumulación de residuos ó GAP por su denominación en inglés *Garbage Accumulation Points*), su distribución en el terreno, el tipo y el tamaño de los recipientes utilizados y la frecuencia con la cual se recolecta su contenido son factores condicionantes de la eficiencia global del sistema. No solamente influyen directamente en los costos de la logística del transporte necesaria para su recolección (Vijay et al., 2005), sino también porque tienen un impacto

en niveles más estratégicos de la cadena logística, como por ejemplo la capacidad de las instalaciones de almacenaje intermedias o de procesamiento. Asimismo, la distribución de los GAP afecta la accesibilidad al sistema. Por ejemplo, Parrot et al. (2009) encontró en la ciudad camerunesa de Yaoundé que cuando distancia promedio entre los generadores de residuos y los contenedores donde deben depositarse los mismos aumenta, disminuye la proporción de población que los utiliza. Esto provoca un indeseable incremento de residuos acumulados en lugares inadecuados tales como cursos de agua o áreas verdes. Además de los obvios efectos sobre el medio ambiental, este comportamiento también afecta a la población de formas más indirectas mediante, por ejemplo, la diseminación de enfermedades o un aumento en las cargas públicas por los gastos asociados para remover los residuos mal dispuestos y reincorporarlos al sistema formal de RSU. También se han encontrado evidencias que una correcta disposición de contenedores en el entramado urbano puede incentivar la predisposición a reciclar de una comunidad (González-Torre et al., 2003; Martin et al., 2006; Belton et al., 1994). Finalmente, Gallardo et al. (2010), basándose en modelos de regresión desarrollados a partir de datos recolectados en diversas ciudades de España, encontraron que la disminución de la distancia promedio entre generador y los lugares de disposición de residuos incide positivamente en el porcentaje de basura diferenciada que se recolecta.

2.1. Revisión bibliográfica

El problema de localización GAP ha sido regularmente considerado como un problema estratégico en los sistemas de RSU (Ghiani et al., 2014a). Es conocido que el problema de localización de GAPs no es un problema trivial debido principalmente a la naturaleza semi-indeseable, del inglés *semi-obnoxious*, de este tipo de instalaciones. Tralhão et al. (2010) declara que los contenedores de residuos imponen costos ambientales en aquellos individuos que viven demasiado cerca y costos de transporte en aquellos que viven demasiado lejos. Los costos ambientales suelen incluir contaminación visual, malos olores y ruidos molestos y embotellamiento de tráfico debido a la operación de vehículos recolectores (Flahaut et al., 2002). Estos están relacionados con el fenómeno conocido como NYMBY (“Not in my Back Yard”) que ha sido estudiado en la literatura para otros problemas de localización de instalaciones, tales como lugares de tratamientos de adictos a las drogas, de reclusión de enfermos mentales, cárceles, barrios de vivienda económicos o refugios para personas en situación de calle (Schively, 2007). El fenómeno NYMBY fue descrito sintéticamente por Lindell y Earle (1983) de la siguiente forma: la cantidad de ciudadanos que desean tener una instalación indeseable cerca es mucho menor que la cantidad de ciudadanos que consideran que estas instalaciones deben ser construidas en algún lugar. Sin embargo, no sólo la complejidad de resolver el problema de localización de GAPs se basa en esta relación de compromiso entre costos ambientales y de transporte. Ghiani et al. (2012) establecieron que, a pesar del deseo de tener un GAP lo más cerca posible de sus hogares, los ciudadanos también desean pagar la menor cantidad de dinero, ya sea directamente o en concepto de cargas públicas, para que se le brinde el servicio de recolección de RSU.

Recientemente, Purkayastha et al. (2015) realizaron una revisión de los trabajos sobre la localización de contenedores, concluyendo que la bibliografía disponible resulta escasa frente a los importantes beneficios que podrían obtenerse de la aplicación de herramientas de apoyo a la toma de decisiones adecuadas en el problema de localización de GAPs. Bautista y Pereira (2006) presentaron el problema de localización de GAPs usando dos enfoques diferentes: un problema de hallar el menor conjunto de cobertura (en inglés *minimal set covering problem*) y un problema de maximización de satisfacción de cláusulas (en inglés *maximum satisfiability problem*). Propusieron técnicas metaheurísticas para resolver ambos modelos y los aplicaron en instancias reales de la ciudad de Barcelona, España. El objetivo fue localizar la menor cantidad de GAPs tal que cada hogar posea un GAP a una distancia comprendida dentro de cierto valor umbral. El mismo problema fue resuelto en Ghiani et al. (2012) a través de una heurística constructiva que fue validada para instancias pequeñas con CPLEX. En Ghiani et al. (2014b) esta heurística fue reutilizada con algunas modificaciones para limitar los costos posteriores del ruteo de vehículos necesario para la recolección. Por ejemplo, no permitieron que en un mismo GAP se instalen contenedores incompatibles, es decir, que requieran diferentes tipos de vehículos para ser recolectados. En ambos trabajos los experimentos computacionales fueron realizados sobre casos reales de la ciudad italiana de Nardò. Di Felice (2014a) propuso una heurística de dos etapas. En la etapa inicial resolvió el problema de localización de GAPs y en la segunda etapa resolvió la asignación de contenedores. Una característica distintiva de este trabajo es que los GAPs podían ser ubicados en cualquier lugar de la red urbana de calles y no únicamente en posiciones predefinidas como comúnmente se supone en la bibliografía (véase, por ejemplo, Tralhão et al., 2010; Ghiani et al., 2012). En Di Felice (2014b), el autor presentó los resultados de la aplicación del algoritmo anterior en la ciudad italiana de L'Aquila. Exploró la sensibilidad de la cantidad de contenedores necesarios cuando la distancia máxima permisible entre los hogares y el GAP asignado variaba.

En la literatura podemos encontrar diversos autores que consideraron múltiples criterios de optimización en este problema. Tralhão et al. (2010) resolvió el problema de localización de GAPs en un sector de la ciudad de Coimbra, Portugal, considerando la minimización de cuatro objetivos: el costo total del sistema, la distancia promedio entre los hogares y el GAP asignado y la cantidad de ciudadanos dentro del radio de “push” y “pull” de un GAP. Estos dos últimos objetivos se relacionan con la naturaleza semi-indeseable de los GAPs descrita en la Sección 2 y tienen una naturaleza contradictoria: mientras que objetivo “push” intenta que los ciudadanos estén lo más lejos posible de un GAP, el objetivo de “pull” intenta acercarlos al GAP. Los autores utilizaron distintas técnicas para obtener soluciones no-dominadas: método de programación por compromiso, programación por compromiso pero con una restricción especial para limitar el costo (lo que lo vuelve similar al método de las ε -restricciones) o programación por metas para minimizar la distancia a la solución “ideal”, esto es, la solución infactible que posee el valor de los óptimos individuales de cada objetivo. Coutinho-Rodrigues et al. (2012) resolvió un problema similar, pero sólo considerando dos objetivos: el costo total de inversión y una novedosa función de “insatisfacción” que nuevamente intenta captar la naturaleza

semi-indeseable de los GAPS. Los autores aplican el método de las ε -restricciones para construir el frente de Pareto.

Otros investigadores han utilizado Sistemas de Información Geográfica (SIG) para establecer las localizaciones de GAPS en un área urbana (véase, por ejemplo, Vijay et al., 2008; Gautam y Kumar, 2005; Valeo et al., 1998). Kao y Lin (2002) presentaron tres modelos exactos distintos para localizar GAPS en la ciudad de Hsinchu, Taiwán. Aremu y Sule (2012) aplicaron tecnología GIS para resolver un problema de p -median para ubicar recipientes de residuos en la ciudad de Ilorin, Nigeria. Los autores analizaron la sensibilidad de la solución según la cobertura del servicio, la satisfacción del público, los costos asociados a la provisión del servicio y las emanaciones contaminantes de los vehículos de recolección. Boskovic y Jovicic (2015) resolvieron la localización de contenedores en la ciudad de Kragujevac, Serbia, usando el módulo de ArcGIS Network Analyst. Primero los autores decidieron como redistribuir los puntos de recolección y luego decidieron cuantos contenedores de residuos instalar. Otras aplicaciones similares pueden encontrarse para la ciudad de Atenas, Grecia (Chalkias y Lasaridi, 2009; Karadimas et al., 2005). Zamorano et al. (2009) evaluó la eficiencia de la distribución de contenedores en la ciudad de Churriana de la Vega, España, determinando que un reordenamiento de la ubicación de los mismos podría tener un impacto positivo en el sistema. Gallardo et al. (2015) hicieron una contribución importante proponiendo una metodología organizada para diseñar un sistema de recolección (Figura 2.1). que aplicaron en la ciudad de Castellón, España y resolvieron el problema de localización de GAPS mediante ArcGIS. Esta metodología consiste en la siguientes etapas:

- selección del número de fracciones en los cuales clasificar la basura;
- selección del “nivel de almacenaje”, esto es, el sistema que será utilizado para la recolección de la basura, por ejemplo, un sistema puerta a puerta o con contenedores comunitarios;
- localización de los lugares de descarga de los residuos;
- y selección de la capacidad de acumulación de los GAPS y los contenedores a utilizar.
- elaboración de mapas de los puntos de acumulación para cada fracción.

A pesar de que en general el problema estratégico de localización de contenedores es considerado separadamente del problema táctico de diseño de los recorridos de recolección de residuos, pueden obtenerse ahorros importantes en los costos con un modelo integral (Ghiani et al., 2014a). Chang y Wei (2000, 1999) propusieron un algoritmo multiobjetivo genético difuso para resolver el problema de localización de sitios de descarga y los circuitos de recolección en Kaohsiung, Taiwán. Consideraron el porcentaje de población cubierto, la distancia promedio entre los ciudadanos y las estaciones de disposición de residuos y las posibles distancias de los recorridos de recolección como metas de planeamiento utilizando lógica difusa. Hemmelmayr et al. (2013) propusieron un enfoque

integrado donde el problema de la localización de reservorios es resuelto conjuntamente con la planificación de rutas de recolección en lo que denominaron el *Waste Bin Allocation and Routing Problem* (WBARP). El problema de localización de GAPs está embebido en un algoritmo metaheurístico del tipo *Variable Neighborhood Search* (VNS) que resuelve el problema de ruteo. Los autores utilizaron cuatro enfoques distintos de resolución. Todos con el mismo objetivo de minimizar el costo total del sistema que incluía el costo de instalar los contenedores y el costo de efectuar los recorridos de recolección. Los primeros dos enfoques fueron resoluciones jerárquicas donde la solución de uno de los problemas era tomada como dato de entrada por parte del segundo problema. Por ejemplo, primero se resolvió el problema de localización de GAPs y luego, con la configuración de GAPs obtenida, se resolvió el problema de ruteo. En el tercer enfoque ambos problemas se resuelven conjuntamente, esto es, para cada uno de los recorridos determinados por la VNS, se resuelve el problema de localización de GAPs para la frecuencia de recolección dada. Los tres enfoques mencionados utilizan CPLEX para determinar la localización de los GAPs de manera exacta. El cuarto enfoque utiliza una estimación heurística para resolver la localización de GAPs. El método integral propuesto, esto es, localización de contenedores y diseño del plan de recolección, es validado mediante la comparación con los resultados obtenidos por CPLEX en instancias pequeñas del problema. Existen otros trabajos donde estos dos problemas, la localización de instalaciones y el ruteo de vehículos, son resueltos secuencialmente. En Lin et al. (2011), el problema de localización de GAPs es resuelto con un modelo mixto-entero de programación matemática y luego los recorridos de recolección son abordados con un algoritmo de colonia de hormigas. En este trabajo, los autores consideraron que los GAPs tienen una ventana temporal, esto es, sólo están disponibles para los usuarios durante cierto intervalo de tiempo. Realizaron pruebas computacionales con instancias de la ciudad de Taichung, Taiwán. Ghiani et al. (2014b) y Rossit et al. (2015b) resolvieron el problema secuencialmente para sectores de las ciudades de Nardò, Italia y Bahía Blanca, Argentina. Primero se resolvió el problema de localización de GAPs y luego el problema de ruteo, demostrando el impacto positivo de una eficiente distribución de los contenedores en los costos de ruteo.

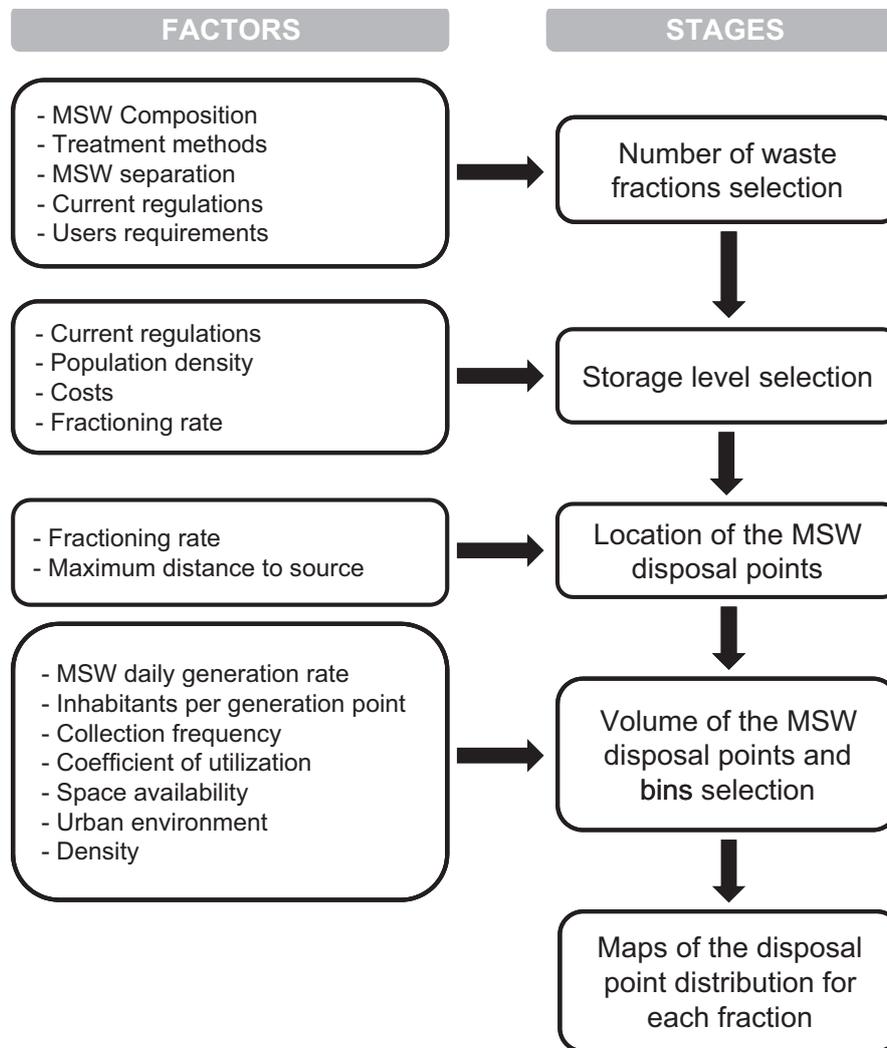


Figura 2.1: Metodología de diseño de un sistema de recolección. Fuente: Gallardo et al. (2015).

2.1.1. Complejidad computacional del problema de localización de GAPs

El problema GAP es un problema de localización de instalaciones o *facility location problem* (FLP). Este tipo de problemas son considerados problemas NP-hard en la literatura ya que su versión más básica, considerando capacidad infinitas en las instalaciones, esto es, el problema *uncapacitated FLP* (UFLP), es ya un problema NP-hard (Li et al., 2014). En Cornuejols et al. (1983) se demuestra la reducción de un UFLP a un problema de cobertura de vértices o *vertex cover problem*, el cual ha sido demostrado como NP-hard (Karp, 1972). El problema con restricciones de capacidad, conocido como *Capacitated Facility Location Problem*, también es NP-hard. Cornuéjols et al. (1991) demostró que un *3-dimensional matching problem*, el cual es NP-hard (Garey y Johnson, 1979), puede reducirse a este problema.

2.2. Métodos multiobjetivo para programación entera

El enfoque multiobjetivo en la gestión de RSU puede ofrecer un panorama más abarcativo a los tomadores de decisión, en adelante llamado simplemente “decisor”, que no está solamente guiado en el objetivo tradicional de la minimización de costos (Mavrotas et al., 2015). En los problemas multiobjetivo de programación matemática (MOMP por sus siglas en inglés), no existe una única solución factible que optimice todos los criterios simultáneamente. Por lo tanto, los agentes decisores deben elegir una solución preferida entre las diversas alternativas existentes (Méndez et al., 2014). Una solución no dominada, no inferior o Pareto óptima es aquella que no puede ser mejorada en un objetivo sin empeorar su desempeño en al menos otro de los criterios que se están optimizando. El conjunto de soluciones no dominadas constituyen la frontera de Pareto. Hwang y Masud (2012) clasifica los problema multiobjetivo en tres categorías, de acuerdo a la etapa en la cual se involucra al decisor:

- **métodos a priori:** el decisor expresa sus preferencias antes del proceso de cálculo;
- **métodos interactivos:** el decisor se involucra durante el periodo de optimización. Se alternan etapas de cálculo y deliberaciones con decisor, guiando progresivamente la búsqueda hacia la solución preferida por el decisor;
- **y métodos a posteriori:** el decisor se involucra cuando ya se generaron las soluciones (todas ellas o una muestra representativa) y selecciona la preferida.

Los métodos a posteriori o de generación requieren importantes recursos computacionales ya que el cálculo de soluciones eficientes es un proceso demandante en términos de tiempos de cómputo. Sin embargo, estos métodos son deseables cuando el decisor no está disponible en la etapa inicial del proceso. Además permiten presentar un panorama amplio sobre las alternativas disponibles al decisor, lo que aumenta su confianza en la elección definitiva (Mavrotas, 2009). Dos conocidos métodos multiobjetivo para resolver modelos exactos son el método de programación por compromiso o ponderaciones y el método de las ε -restricciones.

2.2.1. Método de las ponderaciones

El método de las ponderaciones utiliza los valores de la matriz de pagos para construir una función multiobjetivo. De hecho, resume la naturaleza multiobjetivo del problema en una única función a través de pesos relativos. Por ejemplo, se intenta optimizar $|I|$ funciones objetivo distintas, $f_i(x)$, $\forall i \in I$, sobre un conjunto de soluciones factible determinado por $x \in X$. El método de las ponderaciones plantea la optimización de una única función $F(f_i(x))$. Una forma sencilla de expresar F puede ser $F(f_i(x)) = \sum_{i \in I} (w_i f_i(x))$ donde w_i son los pesos relativos que se asignan a cada objetivo. Zeleny (1974) denominó este método como de los pesos aditivos. Si bien esta es la adición más sencilla de objetivos, Zeleny (1974) explicó las desventajas que posee ya que los objetivos pueden estar medidos en distintas unidades. Por ello, introduce la idea de optimizar la distancia relativa al valor ideal de cada objetivo. Existen diversas métricas para medir esta distancia (véase, por ejemplo, Zeleny, 1974).

2.2.2. Método de las ε -restricciones

Desde su desarrollo inicial por Zadeh (1963) en los 60', el método de las ponderaciones fue utilizado en una multiplicidad de aplicaciones debido a su simplicidad de uso. Sin embargo, posee algunas deficiencias importantes que han sido señaladas en la bibliografía (Caramia y Dell'Olmo, 2008; Marler y Arora, 2010; Mavrotas, 2009; Rossit et al., 2017b). Entre ellas puede nombrarse:

- en problemas lineales el método de las ponderaciones sólo puede encontrar soluciones de puntos extremos de la función objetivo. Esto puede ocasionar que para diversos vectores de ponderaciones el método halle la misma solución. Si este es el caso, varias ejecuciones obtendrán soluciones repetidas, desperdiciando tiempo y recursos computacionales.
- en problemas con variables enteras el método de las ponderaciones sólo servirá para encontrar soluciones respaldadas (del inglés *supported solutions*). Una solución no dominada $x \in X_e$, donde X_e es el conjunto de soluciones (Pareto) eficientes del área de soluciones factible X , es respaldada si no es dominada por ninguna combinación convexa (infactible) de soluciones en X_e (Antunes et al., 2016). En los problemas de programación lineal, donde la región factible (si es delimitada) es siempre un politopo convexo, todas las soluciones no dominadas son respaldadas. Sin embargo, esto no puede asegurarse cuando se utilizan variables enteras.
- la necesidad de escalar la función objetivo con el fin de evitar una suma sin sentido debido a las diferentes unidades de los distintos objetivos o un sesgo de la fórmula hacia aquellos objetivos que, en general, adopten valores con magnitudes más grandes.
- no provee una distribución uniforme de los óptimos de Pareto en el frente a pesar de utilizar una variación consistente de pesos. Por distribución uniforme se entiende distancias euclidianas consistentes entre dos soluciones consecutivas.

El método de las ε -restricciones, propuesto por Haimes et al. (1971), evita varias de las desventajas del método de las ponderaciones (Caramia y Dell'Olmo, 2008; Mavrotas, 2009). Entre ellas, la posibilidad de obtener soluciones no-dominadas en regiones factibles no convexas. Matemáticamente se desea resolver el siguiente problema:

$$\text{máx } f_{i'}(x)$$

Sujeto a:

$$\begin{aligned} f_i(x) &\leq \varepsilon_i, \quad \forall i \in I, i \neq i' \\ x &\in X \end{aligned}$$

donde i' es un objetivo determinado del conjunto I y ε_i son parámetros.

Sin embargo, en la literatura también se han identificado algunas desventajas de este método, como la posibilidad de obtener soluciones débilmente eficientes. Una nueva generación de modificaciones al método tradicional han surgido para suplir estas falencias, tales como, ε -restricciones aumentado (AUGMECON) method proposed by Mavrotas (2009), el método aumentado de las ε -restricciones simple (SAUGMECON) propuesto por Zhang y Reimann (2014) y el AUGMECON2 propuesto por Mavrotas y Florios (2013), que es el que se propone utilizar en esta tesis.

2.2.3. Método de las ε -restricciones aumentado

El método de las ε -restricciones aumentado (AUGMECON) resuelve algunas de las vulnerabilidades del del método tradicional, principalmente garantiza que la solución hallada sea un óptimo de Pareto, siempre y cuando la búsqueda logre converger, es decir, no se aborta por limitación de recursos computacionales. El problema a resolver en el método AUGMECON es el siguiente:

$$\text{máx } f_{i'}(x) + eps \sum_{\substack{i \in I \\ i \neq i'}} \left(a_i \frac{S_i}{r_i} \right)$$

Sujeto a:

$$\begin{aligned} f_i(x) - S_i &= \varepsilon_i, \quad \forall i \in I, i \neq i' \\ x &\in X \end{aligned}$$

donde ε_i son los parámetros para el Lado Derecho de la Restricción (LDR) para una iteración específica. r_i es el rango de la función objetivo $f_i(x)$, es decir, la distancia entre el mejor y el peor valor posible. S_i es la variable de holgura de la restricción asociada a $f_i(x)$. eps es una constante cualquiera que adopta valores entre 10^{-6} y 10^{-3} . En la versión original los coeficientes a_i adquieren todos el mismo valor (Mavrotas, 2009). Sin

embargo en la versión revisada del método, denominado AUGMECON2, estos valores siguen la siguiente fórmula $a_i = 10^{-(i-2)}$ (Mavrotas y Florios, 2013). Esto provoca que si existen óptimos alternativos esta modificación produce una optimización lexicográfica. Entonces, las funciones objetivo son optimizadas secuencialmente, esto es, primero $f_{i'}$, luego f_{i_1} y así siguiendo.

El rango de la función objetivo es dividido en q_k intervalos iguales utilizando $q_k - 1$ cortes que dan lugar a $q_k + 1$ puntos grilla que sirven para sistemáticamente variar el parámetro del LDR (ε_i). El número total de subproblemas es $\prod_{i \in I, i \neq i'} (q_i + 1)$. El paso de discretización de un objetivo $i \in I$ es: $paso_i = \frac{r_i}{q_i}$. El valor ε_i de la iteración t queda determinado de la siguiente forma: $\varepsilon_{i,t} = fmin_i + tpaso_i$, donde $fmin_i$ es el mínimo valor que adopta f_i en la matriz de pagos.

En cada iteración se verifica la variable de holgura correspondiente al objetivo más interno, esto es $f_{|I|}$, con ella se calcula el coeficiente de bypass $b_{|I|} = \frac{S_{|I|}}{paso_{|I|}}$. Cuando $b_{|I|} > 1$, indica el número de corridas que se pueden saltar ya que tendrán la misma solución final que la iteración actual.

El procedimiento del algoritmo AUGMECON2 se presenta de forma resumida en el diagrama de flujo de la Figura 2.2. El algoritmo comienza con los valores menos exigentes en los lados derechos de las restricciones asociadas a los objetivos y luego gradualmente, en las siguientes iteraciones, las va restringiendo. Por ejemplo, en un problema donde cierto criterio es minimizado comienza con el máximo valor para el lado derecho de la restricción asociada a dicho objetivo y gradualmente lo irá reduciendo. En este proceso, cuando una instancia se vuelve infactible, significa que no es necesario continuar con problemas aún más restringidos ya que también serán infactibles. Aunque no fueran infactibles, pero debido a la naturaleza compleja del problema y los recursos computacionales dados, el algoritmo implementado no pudiera hallar una solución, tampoco la hallará en instancias más restringidas. Por lo tanto, el algoritmo abandona el ciclo de más bajo nivel y procede con el siguiente punto de la grilla que corresponde al objetivo que se encuentra en el ciclo externo más próximo. También el coeficiente de bypass verifica que la siguiente ejecución no generará la misma solución y, por lo tanto, debiera ser saltada.

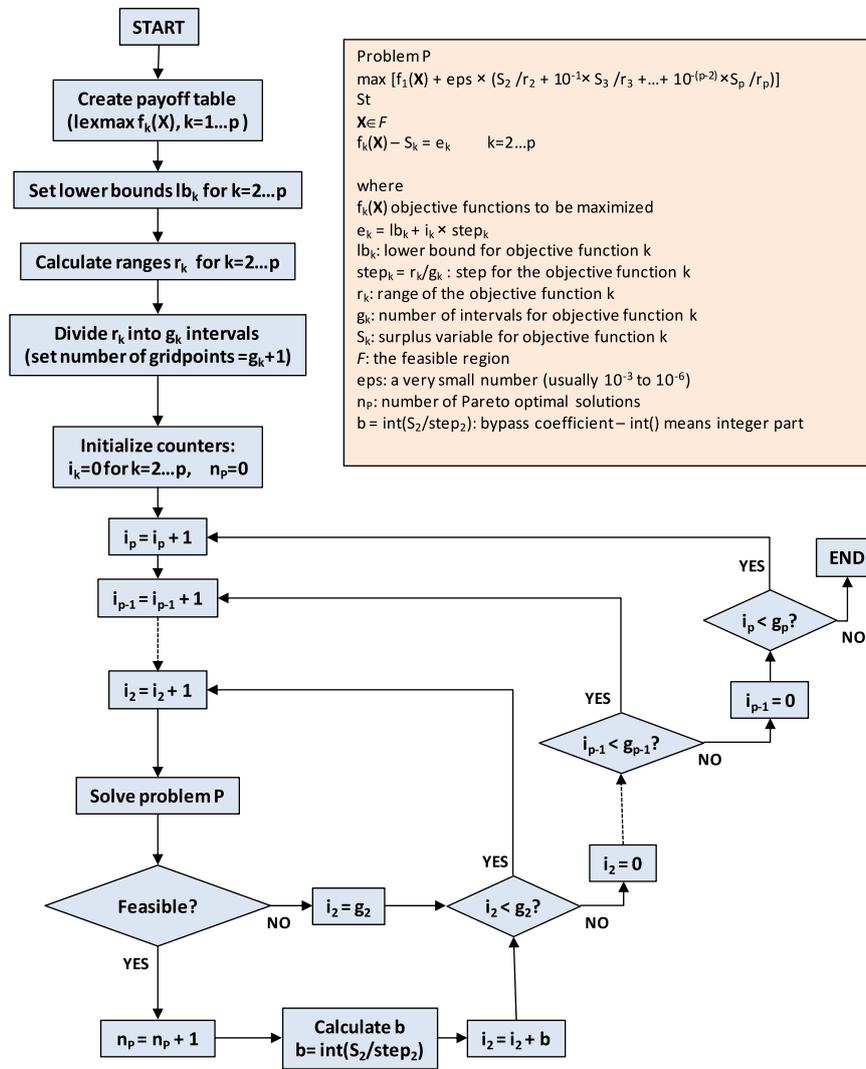


Figura 2.2: Diagrama de flujo del método de resolución AUGMECON2. Fuente: Mavrotas y Florios (2013).

2.3. Casos de aplicación: Bahía Blanca y Montevideo

En esta Parte se desarrollan dos trabajos basados en dos casos de estudio distintos siendo el estudio de casos una metodología que ha sido extensamente aplicada en la investigación científica Monge (2010). Un caso se encuentra basado en la ciudad de Bahía Blanca y el otro en la ciudad de Montevideo. En ambos estudios se aplica la metodología propuesta por Gallardo et al. (2015) y presentada anteriormente (Sección 2.1. El primero caso es la solución de un problema simulado en la ciudad de Bahía Blanca para localizar contenedores en el área centro de la ciudad. El segundo considera un modelo similar para la ciudad de Montevideo. Si bien ambos modelos intentan dar respuesta al problema de localización de GAPs el modelo aplicado en el segundo caso incorpora un objetivo adicional, que se basa en la frecuencia de recolección. Las autoridades de Montevideo, ciudad que ya contaba con un sistema de contenedores comunitarios y una base de datos más amplia que Bahía Blanca, estaban interesados en conocer el impacto de las frecuencias de recolección por lo que se incorporó ese objetivo.

Capítulo 3

Caso de aplicación: Bahía Blanca

La ciudad de Bahía Blanca se encuentra en el sur de la Provincia de Buenos Aires. Cuenta con aproximadamente 300.000 habitantes lo que la convierte en la ciudad más populosa del sur argentino. Además es un importante centro industrial y un nodo de interconexión de transporte multimodal, contando con el puerto natural de aguas profundas más grande del país. El sistema de gestión de RSU se basa casi exclusivamente en un sistema de recolección puerta a puerta, esto es, cada vecino deposita sus residuos en un cesto ubicado en la puerta de su vivienda desde donde será recolectado por el vehículo recolector. Además, no se practica la clasificación de residuos en origen. Como en muchas ciudades, el gobierno local es responsable de la gestión de RSU desde el punto de generación hasta su disposición final (Pradhan et al., 2012). En parte debido a los altos costos logísticos argentinos (Broz et al., 2016, 2018), incluyendo los altos salarios que cobran los transportistas en el país (Benes y Milmanda, 2012), el sistema consume un gran porcentaje del presupuesto municipal. Sin embargo, la gestión de RSU se encuentra lejos de ser considerada eficiente por los usuarios, algo que es común en los países en vías de desarrollo (Hoornweg y Bhada-Tata, 2012).

El material recolectado se deposita en un relleno sanitario ubicado en las afueras de la ciudad. El clima frío y seco de esta región, ya que Bahía Blanca se encuentra ubicada en las puertas del desierto patagónico, no favorece la descomposición natural de los residuos. Hace algunos años, el gobierno local, teniendo en cuenta que la capacidad de su relleno sanitario estaba cerca de colmarse, intentó implementar un sistema de separación de residuos en origen. Esta modalidad mantenía la recolección puerta a puerta determinando distintos días a la semana en los cuales se pasaría a recolectar distintos tipos de residuo. Sin embargo, la iniciativa fue abandonada al poco tiempo. Para implementar una clasificación de residuos en origen la utilización de contenedores comunitarios ha demostrado ser un sistema eficiente (Bonomo et al., 2012; Valeo et al., 1998).

Sólo una pequeña proporción de residuos son recolectados en seis “puntos limpios”, esto es, lugares donde se dispone de contenedores para distintos tipos de desechos. Lo recolectado en los puntos limpios es enviado a una planta de tratamiento para su recuperación y reciclado. Sin embargo, el impacto de estos seis lugares de separación de RSU en una ciudad de 300.000 habitantes es limitado. Además, la localización de estos lugares

no fue optimizada a los efectos de hacer su uso más simple para los ciudadanos. Estos puntos limpios, generalmente localizados en lugares concurridos, cumplen el objetivo de concientizar a la población. Recientemente se ha retomado el análisis de iniciativas para lograr una clasificación en origen en grandes generadores de residuos urbanos (Honorable Consejo Deliberante de Bahía Blanca, Argentina, 2015).

Dentro de las estrategias que apuntan hacia una gestión más sustentable de los RSU, la clasificación en origen ha sido utilizada con éxito para mejorar el desempeño del sistema de gestión de estos residuos en países en vía de desarrollo (Zhuang et al., 2008; Valeo et al., 1998).

3.1. Formulación del problema

Se propone un modelo de variables enteras (IP por su denominación en inglés *integer programming*) para obtener localizaciones óptimas, o en su defecto cuasi-óptimas, de los GAPs (Rossit et al., 2017b). En el contexto del problema un GAP se entiende por un área predefinida donde es posible proceder a la instalación de contenedores de residuos previa habilitación del mismo. En este modelo se persiguen dos objetivos:

1. minimizar la distancia promedio entre los generadores y los GAPs que le son asignados,
2. minimizar los costos de inversión, los cuales incluyen tanto a los costos asociados a la habilitación de los GAPs como a la compra de contenedores

. Los contenedores pueden ser de diversos tipos, con diferencias en las capacidades y el espacio que ocupan. También se considera que existe una distancia máxima permitida entre los generadores y el GAP asignado, denominada “distancia umbral”. Este concepto ha sido utilizado regularmente en la bibliografía (véase, por ejemplo, Coutinho-Rodrigues et al., 2012; Di Felice, 2014a,b; Ghiani et al., 2014b, 2012; Rossit et al., 2015c; Tralhão et al., 2010) y representa una medida de la calidad del servicio ya que está relacionado con la accesibilidad al sistema por parte de los usuarios. Los conjuntos, parámetros y variables relevantes se presentan en la Tabla 3.1.

Tabla 3.1: Conjuntos, parámetros y variables del modelo.

Conjuntos	
I	Conjunto de potenciales localizaciones de GAPs.
P	Conjunto de generadores de residuos.
J	Conjunto de tipos de contenedores.
H	Conjunto de fracciones de residuos.
Parámetros	
co	Costo de habilitar un GAP.
cin_j	Costo de instalación de un contenedor tipo $j \in J$.
d_{pi}	Distancia desde el generador $p \in P$ a la localización $i \in I$.
b_{ph}	Cantidad de basura del tipo $h \in H$ generada por el generador $p \in P$ en unidades de volumen.
cap_j	Capacidad del contenedor tipo $j \in J$ en unidades de volumen.
e_j	Espacio ocupado por un contenedor del tipo $j \in J$.
Es_i	Espacio disponible en un GAP $i \in I$.
d_m	Distancia umbral (máxima) entre un generador y el GAP asignado.
Variables	
t_{jhi}	Número de contenedores tipo $j \in J$ y tipo de basura $h \in H$ instalados en el GAP $i \in I$.
k_i	1 si el punto limpio $i \in I$ se habilita, 0 en otro caso.
x_{pi}	1 si el generador $p \in P$ es asignado al punto limpio $i \in I$, 0 en otro caso.

El modelo propuesto se detalla en las Ecuaciones 3.1a-3.1i

$$\min \sum_{\substack{p \in P \\ i \in I}} \frac{(d_{pi} x_{pi})}{|P|} \quad (3.1a)$$

$$\min \sum_{\substack{j \in J \\ h \in H \\ i \in I}} (t_{jhi} cin_j) + \sum_{i \in I} (k_i co) \quad (3.1b)$$

Sujeto a

$$\sum_{i \in I} (x_{pi}) = 1, \forall p \in P \quad (3.1c)$$

$$\sum_{\substack{j \in J \\ h \in H}} (t_{jhi} e_j) \leq Es_i k_i, \forall i \in I \quad (3.1d)$$

$$\sum_{p \in P} (b_{ph} x_{pi}) \leq \sum_{j \in J} (cap_j t_{jhi}), \forall h \in H, i \in I \quad (3.1e)$$

$$d_{pi} * x_{pi} \leq d_m, \forall p \in P, i \in I \quad (3.1f)$$

$$x_{pi} \in [0, 1], \forall p \in P, i \in I \quad (3.1g)$$

$$k_i \in [0, 1], \forall p \in P, i \in I \quad (3.1h)$$

$$t_{jhi} \in \mathbb{Z}_0^+, \forall h \in H, i \in I, j \in J \quad (3.1i)$$

El modelo posee dos funciones objetivos. La Ecuación 3.1a representa la distancia promedio que deben recorrer los generadores hacia el GAP asignado. La Ecuación 3.1b representa el objetivo de minimizar el costo de inversión total del sistema, tanto de la habilitación de los GAPs como de la instalación de los contenedores. La Ecuación 3.1c establece que un generador sólo puede ser asignado a un único GAP. La Ecuación 3.1d asegura que la cantidad de contenedores instalados en un GAP no supera el espacio disponible en el mismo. La Ecuación 3.1e establece que, para cada tipo de desecho, el residuo asignado a un GAP no supere la capacidad de los contenedores instalados en el mismo. Las Ecuaciones 3.1f y 3.1g refuerzan la naturaleza binaria de las variables. La Ecuación 3.1h establece la naturaleza entera de la variable.

Hay una clara contradicción entre ambos objetivos del modelo. Si se persigue una estrategia de habilitar un gran número GAPs y contenedores, se obtendrá una distancia promedio pequeña de transporte de residuos para los generadores (elevando la calidad del servicio) pero se incurrirá en un alto costo. Esto también incrementaría el costo logístico de la recolección de la basura acumulada por la gran cantidad de puntos a visitar (Di Felice, 2014b). Por otro lado, un plan con una pequeña cantidad de GAPs sería menos costoso pero a su vez impondría mayores distancias para los generadores disminuyendo la calidad del servicio y el acceso al sistema (Parrot et al., 2009). Asimismo una gran concentración de contenedores en un mismo GAP podría incrementar los perjuicios para los vecinos cercanos, por ejemplo a través de afectar la estética visual del área y, por lo tanto, disminuir el valor comercial de las propiedades (Di Felice, 2014b).

3.2. Evaluación experimental

Siguiendo la metodología determinada por Gallardo et al. (2015) lo primero que debe determinarse es la cantidad de fracciones de residuos que se utilizarán. La tasa de generación per cápita diaria de residuos en Bahía Blanca fue estimada en 0,715 kg. (Planta Piloto de Ingeniería Química, Universidad Nacional del Sur (UNS)-CONICET, 2013), siendo moderadamente menor a la tasa promedio estimada por Troschinetz y Mihelcic (2009) para países en vías de desarrollo (0,77 kg) y menor al promedio nacional (Secretaría de Ambiente y Desarrollo Sustentable, 2015). La composición de las distintas fracciones en la ciudad de Bahía Blanca es de aproximadamente 48 % de materia orgánica, 18 % plásticos, 11 % papel, 7 % vidrio y 16 % de otros materiales (Planta Piloto de Ingeniería Química, Universidad Nacional del Sur (UNS)-CONICET, 2013). Con el objeto de separar la mayor proporción de residuos, se consideraron tres fracciones de basura: materia orgánica, plásticos y otra corriente miscelánea que contienen el resto de los residuos.

El siguiente punto de la metodología es establecer el sistema de recolección, el cual será con contenedores comunitarios. Los dos puntos subsiguientes son determinar la localización de los GAPs y la configuración de cada uno de ellos, esto es, los contenedores que se ubicarán en el mismo. Estos serán determinados mediante el modelo presentado anteriormente (Sección 3). Se supuso que existen dos tipos de contenedores con capaci-

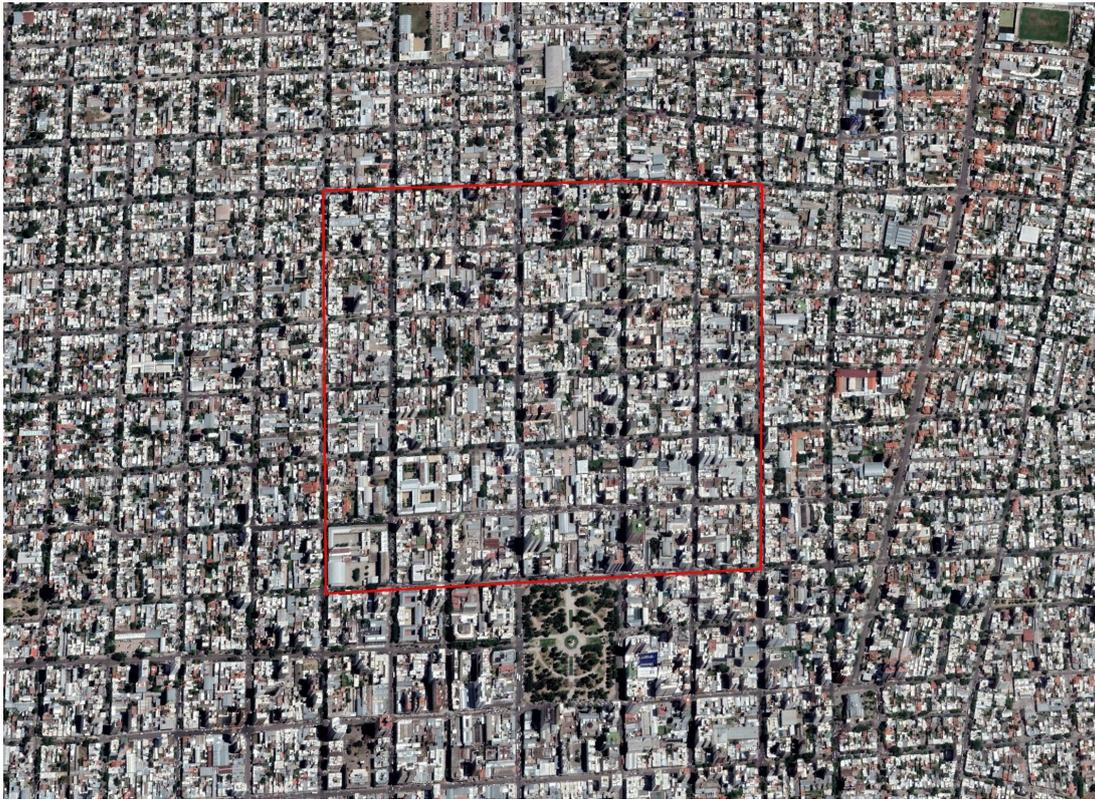


Figura 3.1: Región estudiada de Bahía Blanca. Remarcado en rojo se visualiza el primer escenario (el más grande). El segundo y tercer escenario (más pequeños) son áreas incluidas dentro de este. Fuente: Google Earth Pro (2017b)

dades de 1000 y 2000 litros. Estos ocupan un espacio de $1m^2$ y $2m^2$ y tienen un costo de instalación de 3000 y 5000 u.m (unidades monetarias), respectivamente. El espacio máximo disponible en un GAP es de $25m^2$. La densidad estimada para las tres corrientes de residuos es de: $300kg/m^2$ residuos orgánicos, $65kg/m^2$ para plásticos y $150kg/m^2$ para la corriente miscelánea (Henry y Heinke, 1999). La distancia máxima tolerada entre un generador y el punto limpio asignado es de 300 m. El costo de habilitación de un punto limpio es de 50000 u.m.. Se consideraron tres escenarios: el primero está compuesto por 320 generadores y 13 potenciales puntos limpios; el segundo escenario por 720 generadores y 18 potenciales puntos limpios; y el tercer escenario por 2304 generadores y 25 potenciales puntos limpios. Los generadores, de acuerdo a su tasa de generación, pueden considerarse como grandes, medianos o pequeños generadores según una distribución de probabilidad empírica estimada para el área de Bahía Blanca basada en el número promedio de habitantes por unidad habitacional de la ciudad de Bahía Blanca (Dirección Provincial de Estadística de la Provincia de Buenos Aires, Argentina, 2010).

Se utilizó para la resolución el software CPLEX 12.5.1 y el problema fue modelado

en GAMS 24.1.3. El computador utilizado tiene las siguientes características: procesador Intel Core I5-4210U, CPU @ 2.7 GHz, memoria RAM de 3.5 GB y sistema operativo Windows 10 de 64 bits. La matriz de pagos se calculó utilizando el método lexicográfico tomando un límite temporal de 3000 segundos para cada ejecución. Luego fue aplicado el método AUGMECON2 para resolver el modelo presentado en las Ecuaciones 3.1a-3.1h y obtener soluciones multiobjetivo. Se utilizaron corridas de 10 y 20 puntos para la grilla de cálculo. En el caso del AUGMECON2 los puntos grilla son aplicados sobre el objetivo de costos de inversión. Sin embargo, en el método de las ponderaciones la partición recae en la generación de pesos relativos uniformemente separados en una cantidad igual al número de puntos grilla del AUGMECON. En ambos modelos el límite temporal es de 2000 segundos para la obtención de soluciones multiobjetivo. Para cada escenario, se computan la cantidad de soluciones eficientes, el tiempo de cómputo y el desvío promedio del óptimo.

3.2.1. Resultados

Los resultados obtenidos en el primer escenario son mostrados en las Tablas 3.2 y 3.3; para el segundo escenario en las Tablas 3.4 y 3.5; y para el tercer escenario en las Tablas 3.6 y 3.7 para diez y veinte puntos en la grilla respectivamente.

Primer escenario

Tabla 3.2: Resultados para diez puntos grilla.

Método	Número de soluciones eficientes	Tiempo de ejecución (seg)	Promedio de desviación del óptimo
Ponderaciones	10	364,89	0,000000
AUGMECON2	10	1196,27	0,000000

Tabla 3.3: Resultados para veinte puntos grilla.

Método	Número de soluciones eficientes	Tiempo de ejecución (seg)	Promedio de desviación del óptimo
Ponderaciones	8	1431,75	0,000000
AUGMECON2	17	1488,30	0,000000

Segundo escenario

Tabla 3.4: Resultados para diez puntos grilla.

Método	Número de soluciones eficientes	Tiempo de ejecución (seg)	Promedio de desviación del óptimo
Ponderaciones	7	11239,87	0,002067
AUGMECON2	10	8285,61	0,001621

Tabla 3.5: Resultados para veinte puntos grilla.

Método	Número de soluciones eficientes	Tiempo de ejecución (seg)	Promedio de desviación del óptimo
Ponderaciones	12	26892,59	0,005458
AUGMECON2	18	24408,58	0,012701

Tercer escenario

Tabla 3.6: Resultados para diez puntos grilla.

Método	Número de soluciones eficientes	Tiempo de ejecución (seg)	Promedio de desviación del óptimo
Ponderaciones	9	17256,55	0,025371
AUGMECON2	10	16873,17	0,016303

Tabla 3.7: Resultados para veinte puntos grilla.

Método	Número de soluciones eficientes	Tiempo de ejecución (seg)	Promedio de desviación del óptimo
Ponderaciones	14	36022,58	0,014260
AUGMECON2	15	29893,08	0,020692

Para visualizar los resultados se presentan los frentes de Pareto de las pruebas con 20 puntos grilla. Las Figuras 3.2 y 3.3 corresponden el primer escenario con el método de las ponderaciones y el método AUGMECON2, respectivamente; Figuras 3.4 y 3.5 al segundo escenario; y Figuras 3.6 y 3.7 para el tercer escenario. De la misma forma que en el cálculo del *gap*¹ promedio, se descartaron las soluciones inferiores (y repetidas en el método de las ponderaciones).

3.2.2. Análisis de resultados

En los resultados para diez puntos grilla para el primer escenario (Tabla 3.2), ambos métodos encuentran diez soluciones no dominadas, todas ellas óptimas. Sin embargo, el método de las ponderaciones utiliza un tiempo menor. En los resultados con veinte puntos (Tabla 3.3), la situación cambia. El número de soluciones no inferiores es de 8 con el método tradicional contra 7 del AUGMECON2. A pesar de que el método de las ponderaciones todavía requiere menos tiempo de cómputo, la diferencia se reduce. Nuevamente, no se registra desviación del óptimo. Esto puede deberse a la simplicidad del escenario tratado (es el más pequeño de los tres), que permite al *solver* encontrar soluciones óptimas dentro del límite temporal de 2.000 segundos independientemente del método multiobjetivo aplicado. En el segundo escenario, el método de las ponderaciones encuentra menos soluciones eficientes en ambas corridas (Tablas 3.4 y 3.5). Esta diferencia es mayor para la corridas de veinte puntos. Además, el método de las ponderaciones requiere mayor tiempo de cómputo en ambos casos. Sin embargo, el método clásico obtiene una menor desviación del óptimo promedio para la corrida más larga. En la corrida más corta de 10 puntos esta situación se invierte. En el último escenario los resultados favorecen al método AUGMECON2, tanto en tiempo de cómputo como en número de soluciones eficientes (Tablas 3.6 y 3.7). En cuanto a la desviación promedio del óptimo, se repite la situación del segundo escenario, mostrando el método AUGMECON2 una mejor performance en la corrida de diez puntos y una peor en la de veinte puntos.

La otra cuestión a ser analizada es la comparación de la distribución de soluciones a lo largo del frente de Pareto. Las comparaciones de los tres escenarios implican los siguientes análisis, Figura 3.2 vs. Figura 3.3, Figura 3.4 vs. Figura 3.5 y Figura 3.6 vs. Figura 3.7. Puede verse que no sólo el método AUGMECON2 produce una curva más densa debido al mayor número de soluciones eficientes obtenidos, sino que también estas soluciones se distribuyen más equitativamente dentro del frente de Pareto. Esta característica se debe a la utilización de puntos equidistantes en la grilla. En contraste cuando se aplica el método de las ponderaciones con pesos relativos equitativamente distribuidos, los resultados son diferentes, obteniéndose una distribución heterogénea de los mismos. En algunos casos extremos, obtenemos para un intervalo amplio de pesos relativos las mismas soluciones. Esto se relaciona con el hecho de que en el método de las ponderaciones, una distribución uniforme de los pesos relativos, en general, no produce una distribución uniforme de los

¹La palabra *gap* entendida como desviación del valor óptimo no debe confundirse con la sigla **GAP** (*garbage accumulation point*) que se utiliza comunmente en la bibliografía, así como en este trabajo, para referirse a los lugares de la ciudad donde los generadores depositan sus residuos.

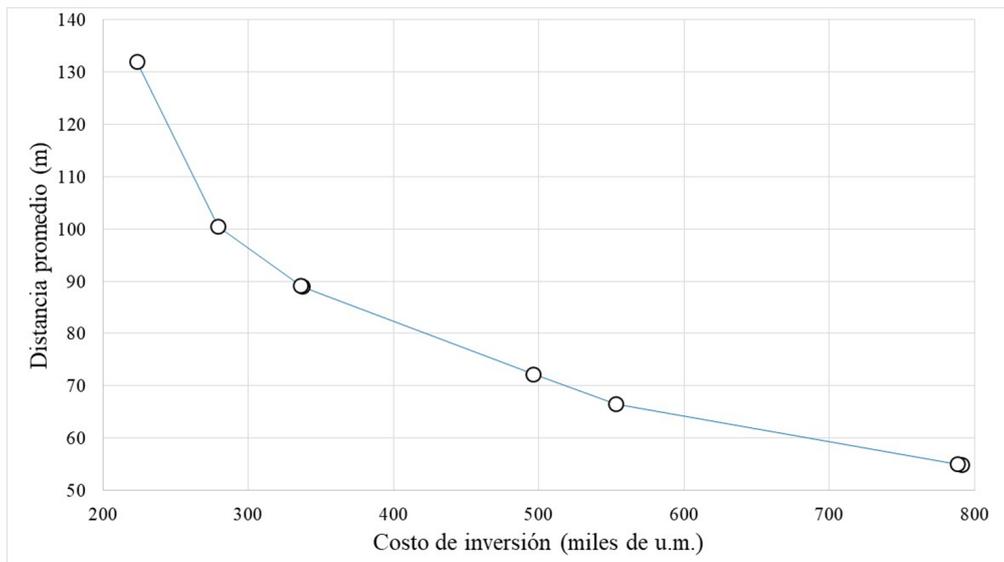


Figura 3.2: Frente de Pareto del primer escenario obtenido con el método de las ponderaciones.

puntos en el frente de Pareto (Caramia y Dell'Olmo, 2008). De hecho, en las Figuras 3.2, 3.5 y 3.6 las soluciones eficientes se encuentran concentradas en algunos sectores de la curva de Pareto, mientras que otras porciones significativas de la misma no poseen soluciones eficientes. En los tres escenarios hay una concentración alta especialmente en las zonas de altos costos de inversión.

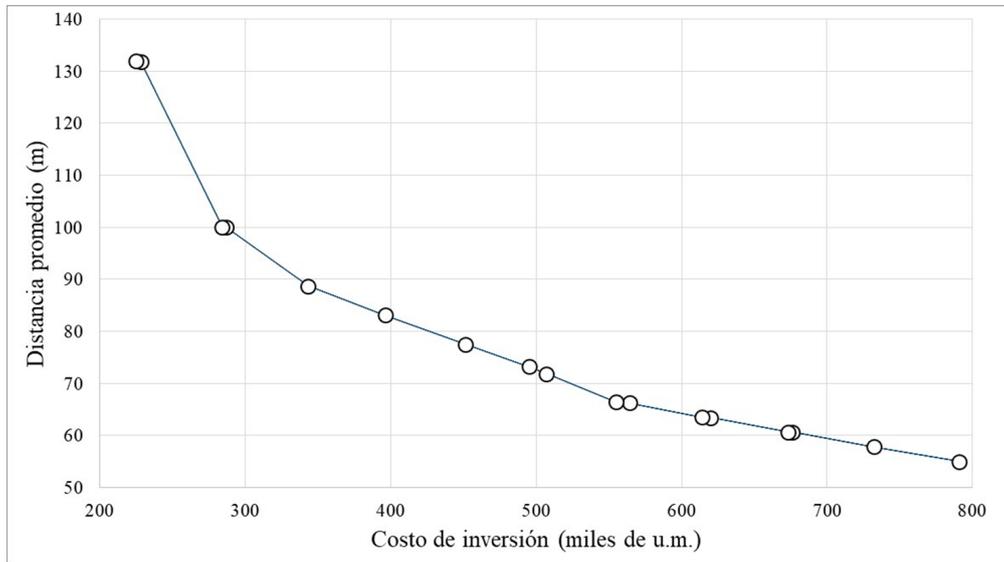


Figura 3.3: Frente de Pareto del primer escenario obtenido con el método AUGMECON2.

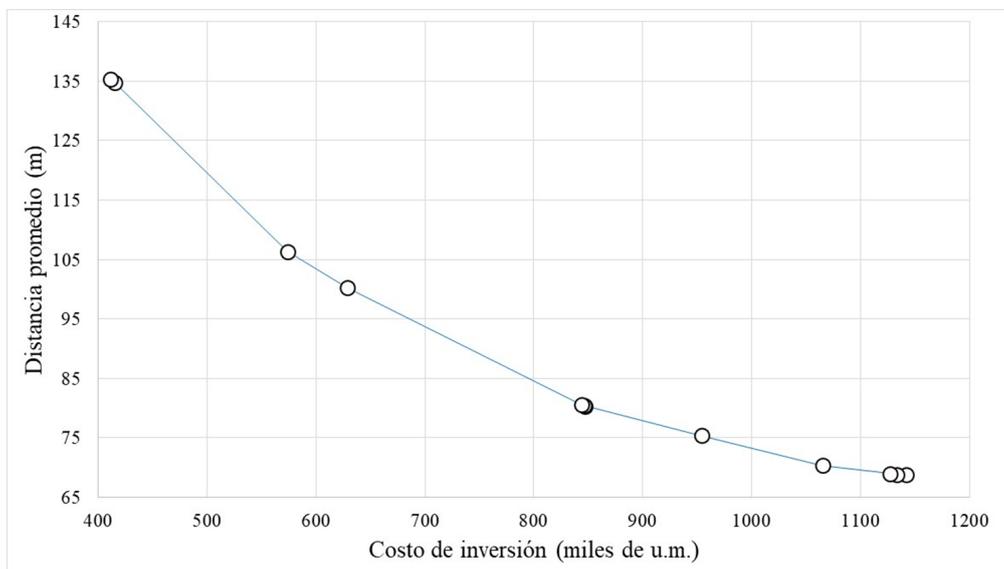


Figura 3.4: Frente de Pareto del segundo escenario obtenido con el método de las ponderaciones.

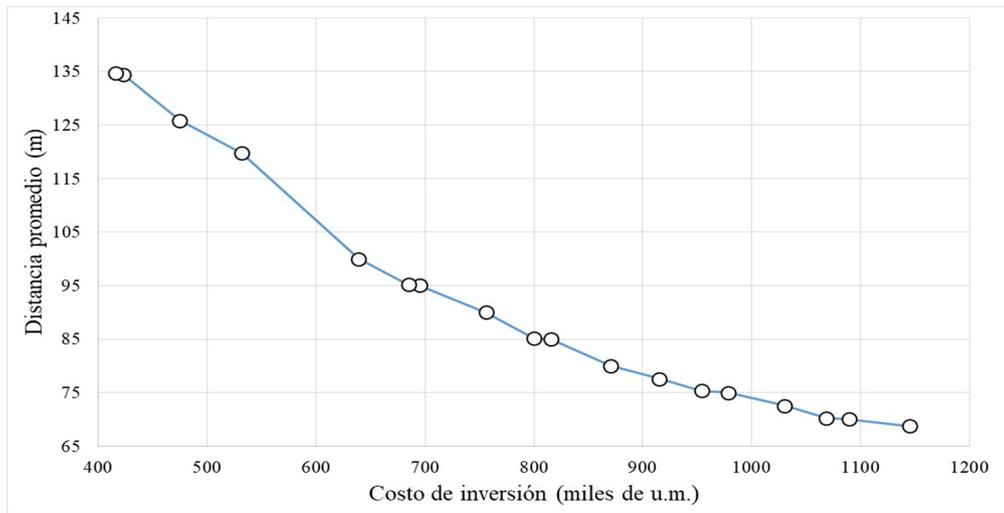


Figura 3.5: Frente de Pareto del segundo escenario obtenido con el método AUGMECON2.

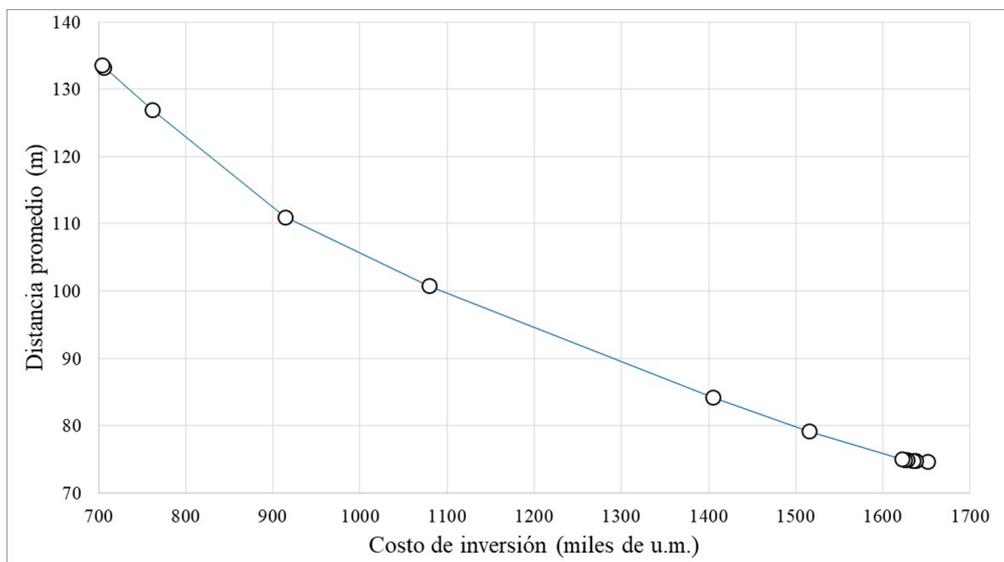


Figura 3.6: Frente de Pareto del tercer escenario obtenido con el método de las ponderaciones.

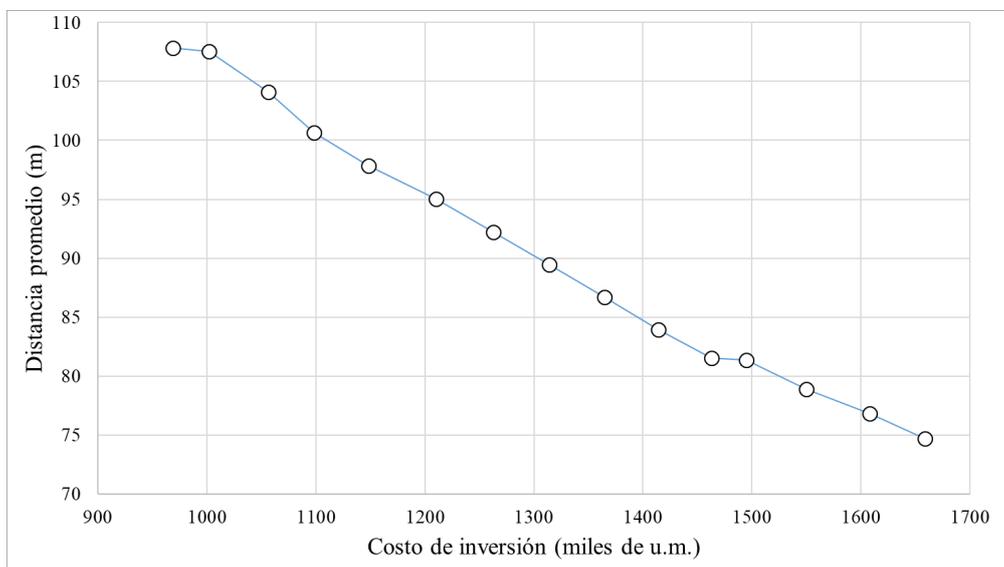


Figura 3.7: Frente de Pareto del tercer escenario obtenido con el método AUGMECON2.

3.3. Discusión de los resultados

En general, el método AUGMECON2 ha mostrado una mejor performance principalmente en los escenarios más complejos. Por su parte, el método de las ponderaciones evidenció su mejor desempeño en el escenario pequeño. Los puntos fuertes del método AUGMECON2 que se han observado en este trabajo, y que han sido reconocidos en la literatura, son: menores tiempos de cómputo, mayor número de soluciones eficientes y la posibilidad de un moderado control la distribución de los puntos eficientes en la curva de Pareto. Estas características beneficiosas pueden atribuirse a la capacidad de este método de explotar la información almacenada en las variables de holgura de las ε -restricciones y, por lo tanto, evitar corridas innecesarias del modelo que derivarían en soluciones repetidas. Contrariamente, el método de las ponderaciones, que carece de esta característica, calcula una solución para cada punto de la grilla sin importar si esto derivará en una solución repetida o, debido al tiempo computacional limitado, en una solución dominada. A pesar de estas características en favor del método AUGMECON2, se encontraron algunas excepciones. Por ejemplo, en las corridas de diez puntos para el menor escenario, el método de las ponderaciones obtuvo el mismo número de soluciones en un intervalo de tiempo más corto. Además, para los resultados en el *gap* los resultados no fueron categóricos. El método de las ponderaciones tuvo, en general, una mejor performance cuando se demandaba mayor número de soluciones. No obstante, debe notarse que la desviación promedio es calculada sólo con las soluciones no inferiores ni repetidas del método de las ponderaciones. AUGMECON2 es más eficiente y no genera soluciones repetidas o inferiores, lo que evita de hacer este filtrado previo. La distribución regular de las soluciones en el frente de Pareto es una cuestión clave ya que permite al agente decisor tener una visión más abarcadora del problema.

Capítulo 4

Caso de aplicación: Montevideo

Montevideo es la capital administrativa y aglomeración urbana más importante de la República Oriental del Uruguay, con una población estimada de 1,3 millones de habitantes en 2011 (Instituto Nacional de Estadística de Uruguay). Asimismo, es sede de diversos organismos regionales y es considerada una de las más prósperas ciudades latinoamericanas. En el año 2003, Montevideo inició una reforma de su sistema de gestión de residuos. El proceso incluía la migración desde un sistema puerta a puerta a un sistema de contenedores comunitarios, comenzando con la instalación de 3200 contenedores iniciales. Hoy en día ya cuenta con 12300 contenedores y la gran mayoría de la población de la ciudad utiliza el nuevo sistema que permite la clasificación de los residuos en dos fracciones: residuo secos (plástico, metal y papel) y residuos húmedos y vidrio, que incluye la materia orgánica. Una gran parte del éxito en la implementación de este nuevo sistema se debió a una campaña pública masiva con objeto de concientizar a la población sobre los beneficios de separar los residuos y cuidar el sistema de contenedores (Intendencia de Montevideo). Los esfuerzos de las autoridades por optimizar el uso de los recursos han encontrado eco en la comunidad científica donde se han realizado diversos estudios sobre optimización de aspectos logísticos de los RSU de la ciudad (véase, por ejemplo, Toutouh et al., 2018; Nesmachnow et al., 2018; Rossit et al., 2017a)



Figura 4.1: Región estudiada de la ciudad de Montevideo. Fuente: Google Earth Pro (2017a).

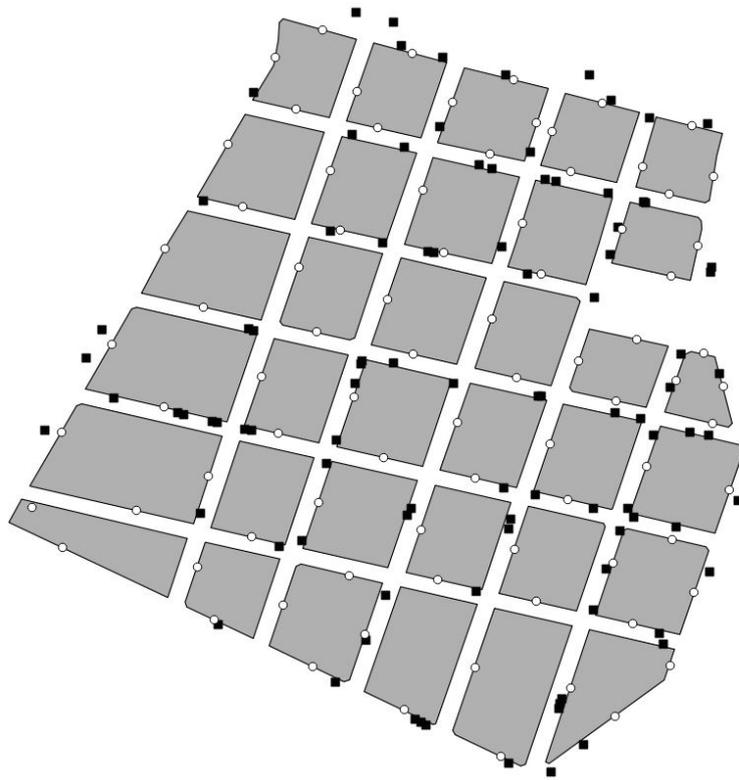


Figura 4.2: Puntos limpios instalados actualmente (cuadrados negros) y puntos limpios potenciales considerados por el modelo (círculos blancos).

En el caso de Montevideo se trabajó con un objetivo adicional que surgió en un intercambio de ideas con gente relacionada a la gestión y al tratamiento de este tipo de problemas. Este objetivo intenta minimizar la frecuencia de recolección de los contenedores. Es decir, que los contenedores deban vaciarse la menor cantidad de veces posibles en un horizonte temporal dado.

4.1. Formulación matemática del problema

El modelo exacto se presenta como un Problema Mixto Entero (MIP, por sus siglas en inglés *Mixed Integer Programming*) (Rossit et al., 2017a). Los conjuntos, parámetros y variables utilizadas se describen en la Tabla 4.1. Nuevamente, existe una cantidad dada de potenciales ubicaciones donde pueden localizarse los GAPS (conjunto I). El conjunto P representa los grupos de generadores. El conjunto Y representa todos los posibles perfiles de frecuencia de recolección para los GAPS y el parámetro a_y representa el periodo de tiempo en días entre dos visitas consecutivas del vehículo recolector para el perfil de frecuencia $y \in Y$. Por ejemplo, si se asume que los perfiles de visita considerados son diario (y_1) y cada dos días (y_2), entonces el conjunto Y se define como $Y = \{y_1, y_2\}$, a_{y_1} es igual a 1 y a_{y_2} es igual a 2. Finalmente, $Dmax$ representa la máxima distancia permisible entre un hogar y el punto limpio al cual es asignado.

Tabla 4.1: Conjuntos, parámetros y variables del modelo.

Conjuntos	
I	Conjunto de potenciales puntos limpios.
P	Conjunto de generadores.
J	Conjunto de tipos de contenedor.
H	Conjunto de fracciones de residuos.
Y	Conjunto de perfiles de frecuencia de recolección.
Parámetros	
cin_j	Costo de instalar un contenedor del tipo $j \in J$.
d_{pi}	Distancia desde el generador $p \in P$ al punto limpio $i \in I$.
b_{ph}	Cantidad de residuo de la fracción $h \in H$ generada por el generador $p \in P$ en unidades de volumen.
a_y	Número de días entre dos visitas consecutivas del vehículo de recolección para el perfil de frecuencia $y \in Y$.
cap_j	Capacidad del contenedor del tipo $j \in J$ en unidades de volumen.
e_j	Espacio ocupado por un contenedor del tipo $j \in J$.
Es_i	Espacio disponible en el punto limpio $i \in I$.
To_j	Máximo número de contenedores $j \in J$ que pueden instalarse.
$Dmax$	Distancia umbral entre un generador y el punto limpio asignado en metros.
Variables	
t_{jhi}	Número de contenedores de la clase $j \in J$ y fracción de residuos $h \in H$ instalados en el punto limpio $i \in I$.
x_{pi}	1 si el generador $p \in P$ es asignado al punto limpio $i \in I$, 0 en otro caso.
f_{hiy}	1 si el tipo de basura $h \in H$ en el punto limpio $i \in I$ es recolectado con frecuencia $y \in Y$, 0 en otro caso.

El modelo es descrito en las Ecuaciones 4.1-4.13.

$$\text{mín} \frac{\sum_{\substack{h \in H \\ i \in I \\ y \in Y}} \left(\frac{f_{hiy}}{a_y} \right)}{|I| |H|} \quad (4.1)$$

$$\text{mín} \sum_{\substack{p \in P \\ i \in I}} \frac{(d_{pi} x_{pi})}{|P|} \quad (4.2)$$

$$\text{mín} \sum_{\substack{j \in J \\ h \in H \\ i \in I}} (t_{jhi} cin_j) \quad (4.3)$$

Sujeto a

$$\sum_{i \in I} (x_{pi}) = 1, \quad \forall p \in P \quad (4.4)$$

$$\sum_{\substack{j \in J \\ h \in H}} (t_{jhi} e_j) \leq E s_i, \quad \forall i \in I \quad (4.5)$$

$$\sum_{\substack{p \in P \\ y \in Y}} (b_{ph} x_{p,i} f_{hiy} a_y) \leq \sum_{j \in J} (cap_j t_{jhi}), \quad \forall h \in H, i \in I \quad (4.6)$$

$$\sum_{y \in Y} f_{hiy} \leq 1, \quad \forall h \in H, i \in I \quad (4.7)$$

$$|P| \sum_{y \in Y} f_{hiy} \geq \sum_{i \in I} x_{pi}, \quad \forall h \in H, i \in I \quad (4.8)$$

$$\sum_{\substack{h \in H \\ i \in I}} t_{jhi} \leq T o_j, \quad \forall j \in J \quad (4.9)$$

$$d_{pi} x_{pi} \leq Dmax, \quad \forall p \in P, i \in I \quad (4.10)$$

$$x_{pi} \in [0, 1], \quad \forall p \in P, i \in I \quad (4.11)$$

$$f_{hiy} \in [0, 1], \quad \forall h \in H, i \in I, y \in Y \quad (4.12)$$

$$t_{jhi} \in \mathbb{Z}_0^+, \quad \forall h \in H, i \in I, y \in Y \quad (4.13)$$

El problema propone tres funciones objetivo. La Ecuación 4.1 expresa el número promedio de puntos limpios que son utilizados afectado por el número de días entre dos visitas consecutivas (a_y). La Ecuación 4.2 representa la distancia promedio entre los generadores y los puntos limpios a los cuales son asignados. La Ecuación 4.3 es el costo total de inversión. La Ecuación 4.4 refuerza que todo generador es asignado a un único punto limpio. La Ecuación 4.5 controla que no se exceda el máximo espacio disponible. La Ecuación 4.6 asegura que el volumen asignado a un punto limpio no es mayor que la capacidad de los contenedores instalados en el mismo. La Ecuación 4.7 establece que sólo un perfil de frecuencia de recolección es asignado a cada tipo de residuo en un punto limpio. La Ecuación 4.8 establece que si por lo menos un hogar es asignado a un punto limpio, ese punto limpio deba tener una frecuencia de recolección. La Ecuación 4.9 limita el número de contenedores de cada tipo que puede instalarse. La Ecuación 4.10 establece la máxima distancia tolerable entre un generador y el punto limpio asignado. Las Ecuaciones 4.11 y 4.12 indican la naturaleza binaria de las variables. Por último, la Ecuación 4.13 establece que la variable $t_{j,h,i}$ adopta valores enteros no negativos.

4.1.0.1. Salvando la no linealidad

La formulación matemática del problema (Ecuaciones 4.1-4.13) es no lineal debido a la presencia de la Ecuación 4.6. Es conocido en optimización que en ocasiones prácticas es preferible el uso de modelos lineales sobre los no lineales debido a que en los primeros pueden beneficiarse por un marco teórico más extenso y consolidado y una mayor facilidad para programar métodos de resolución Glover y Woolsey (1973, 1974). Sin embargo la bibliografía no es concluyente (véase, por ejemplo, Taha, 1972).

Para obtener un modelo lineal se utiliza la linealización propuesta por Glover (1975).

Dadas una variable discreta x_w y una variable discreta o continua y_w (que no depende de x_w), el producto entre ambas $x_w y_w$ puede ser reemplazado por una variable z_w tal que:

$$z_w \geq L_w x_w, \quad \forall w \in W \quad (4.14)$$

$$z_w \leq U_w x_w, \quad \forall w \in W \quad (4.15)$$

$$z_w \geq y_w - U_w(1 - x_w), \quad \forall w \in W \quad (4.16)$$

$$z_w \leq y_w L_w(1 - x_w), \quad \forall w \in W \quad (4.17)$$

donde L_w y U_w son las cotas inferior y superior, respectivamente, de la variable y_w . En Glover (1984), el autor sugiere realizar el siguiente reemplazo $s_w = z_w - y_w + U_w(1 - x_w)$, de forma que la Ecuación 4.16 se transforme en una restricción de no negatividad y así reducir el número de restricciones estructurales. Realizando el reemplazo las Ecuaciones 4.14-4.17 se reescriben como:

$$s_w \geq L_w x_w + U_w(1 - x_w) - y_w, \quad \forall w \in W \quad (4.18)$$

$$s_w \leq U_w - y_w, \quad \forall w \in W \quad (4.19)$$

$$s_w \geq 0, \quad \forall w \in W \quad (4.20)$$

$$s_w \leq U_w(1 - x_w) + L_w(1 - x_w), \quad \forall w \in W \quad (4.21)$$

Aplicado al caso de el modelo descrito (Ecuaciones 4.1-4.13), puede realizarse la sustitución $u_{phiy} = x_{pi} f_{hiy} - f_{hiy} + 1 - x_{pi}$. Se reescribe a la Ecuación 4.6 como:

$$\sum_{\substack{p \in P \\ y \in Y}} [b_{ph} a_y (u_{phiy} + f_{hiy} - 1 + x_{pi})] \leq \sum_{j \in J} (cap_j t_{jhi}), \quad \forall h \in H, i \in I \quad (4.22)$$

Y, conociendo que las cotas superior e inferior de cualquier variable binaria, como x_{pi} y f_{hiy} , son 1 y 0, respectivamente, se adicionan al modelo las siguientes Ecuaciones (análogas a las Ecuaciones 4.18-4.21):

$$u_{phiy} \geq 1 - x_{pi} - f_{hiy}, \quad \forall p \in P, h \in H, i \in I, y \in Y \quad (4.23)$$

$$u_{phiy} \leq 1 - f_{hiy}, \quad \forall p \in P, h \in H, i \in I, y \in Y \quad (4.24)$$

$$u_{phiy} \geq 0, \quad \forall p \in P, h \in H, i \in I, y \in Y \quad (4.25)$$

$$u_{phiy} \leq 1 - x_{pi}, \quad \forall p \in P, h \in H, i \in I, y \in Y \quad (4.26)$$

Con este reemplazo puede comprobarse que:

- si $x_{pi} = 1$ y $f_{hiy} = 1$, entonces $u_{phiy} = 0$ y $u_{phiy} + f_{hiy} - 1 + x_{pi} = 1$
- si $x_{pi} = 0$ y $f_{hiy} = 0$, entonces $u_{phiy} = 1$ y $u_{phiy} + f_{hiy} - 1 + x_{pi} = 0$

- si $x_{pi} = 1$ y $f_{hiy} = 0$, entonces $u_{phiy} = 0$ y $u_{phiy} + f_{hiy} - 1 + x_{pi} = 0$
- si $x_{pi} = 0$ y $f_{hiy} = 1$, entonces $u_{phiy} = 0$ y $u_{phiy} + f_{hiy} - 1 + x_{pi} = 0$

Por lo tanto, la formulación lineal del problema está compuesta por las Ecuaciones 4.1-4.5 y 4.7-4.26. Este modelo es resuelto con el método exacto AUGMECON2 con una ligera modificación al momento de hallar la matriz de pagos.

Si bien esta estrategia de linealización fue desarrollada en Glover (1975, 1984) deben destacarse como fuente de consulta los trabajos de Adams et al. (2004) y Adams y Forrester (2005) que ayudaron a comprender mejor esta teoría.

4.1.1. Enfoque de resolución

Para aplicar el método de AUGMECON2 descrito en Sección 2.2, deben conocerse los rangos en los cuales varía la función objetivo dentro de la frontera eficiente. Esto es, el mejor y el peor valor que alcanzan las funciones objetivo que son utilizadas como restricciones dentro del frente de Pareto (de aquí en adelante se denominará “rango eficiente”). Teóricamente, el método AUGMECON2 debe poder lidiar con rangos que son más grandes que el rango eficiente, siendo suficiente conocer una cota de este rango (Mavrotas y Florios, 2013). Esto es porque el uso de los coeficientes de bypass debiera evitar las ejecuciones innecesarias del modelo. Sin embargo, el uso del rango eficiente puede ahorrar tiempo de cómputo, lo cual es particularmente importante en problemas que son difíciles de resolver y, por lo tanto, para determinados subproblemas puede no hallarse una solución Pareto óptima (o siquiera factible) debido a limitaciones de recursos computacionales. Este es el caso del problema de localización de instalaciones que se encara en este trabajo, el cual hasta en su versión más simple (cuando no se consideran restricciones de capacidad) es catalogado como NP-hard (Cornuejols et al., 1983).

A diferencia del valor ideal que es fácilmente obtenible mediante optimización monobjetivo, estimar el peor valor posible del frente de Pareto no es una tarea trivial (Ehrgott y Tenfelde-Podehl, 2003). El requisito de que el peor valor pertenezca al conjunto eficiente de soluciones excluye algunos enfoques en donde esto no está garantizado totalmente basados en optimización monobjetivo. Por ejemplo, Ehrgott y Ryan (2002) estimaron la peor solución posible desde la matriz de pagos compuesta por los resultados de la optimización individual de todos los objetivos. Sin embargo, esta matriz puede tener soluciones subóptimas en el caso de existencia de óptimos alternativos para estos problemas (Reeves y Reid, 1988). Otro ejemplo, aunque para un método multiobjetivo distinto (SAUGMECON) se encuentra en Zhang y Reimann (2014) donde los autores calcularon los peores valores desde la optimización de los objetivos invertidos. De nuevo, dependiendo de la forma de la región factible, los rangos calculados de esta forma pueden no ser eficientes. A modo de ejemplo se presenta la Figura 4.3. Los rangos obtenidos mediante optimización inversa, esto es $[f_a^1, f_a^4]$ y $[f_b^3, f_b^2]$, son mayores a los rangos eficientes, esto es, $[f_a^2, f_a^4]$ and $[f_b^4, f_b^2]$.

En Mavrotas (2009), los autores proponen el método lexicográfico. Optimizan uno de los objetivos y luego, dentro de los posibles óptimos alternativos, optimizan el segundo

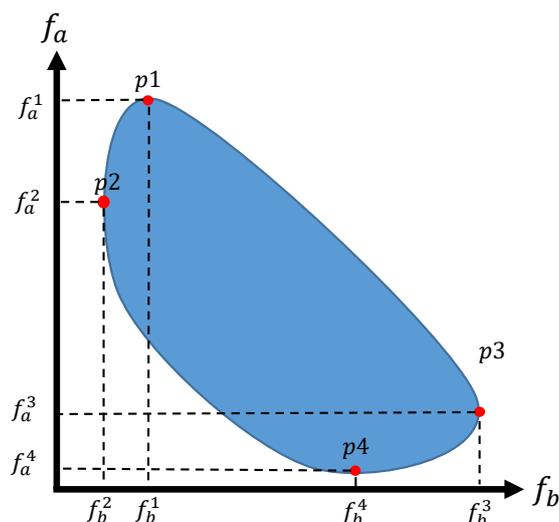


Figura 4.3: Diferencias entre peor valor posible sobre la región factible (f_a^1 y f_b^3), obtenido con optimización monoobjetivo inversa (un problema de maximización), y el peor valor posible sobre la frontera eficiente (f_a^2 and f_b^4).

objetivo y así sucesivamente hasta el último criterio de optimización. Esto garantiza una matriz de pagos conformada por soluciones no dominadas o no inferiores. Además, los autores distribuyen un versión de su método en el modelador GAMS para ser aplicada directamente por los usuarios. Sin embargo, cuando se intenta aplicar al problema de esta tesis, con el solver CPLEX que constituye el estado del arte, esta implementación no fue capaz de hallar la matriz de pagos luego de días de cómputo. Probablemente esto está relacionado con la naturaleza NP-hard del problema FLP (Cornuejols et al., 1983) y la dificultad de reiniciar la solución de un problema desde una solución inicial.

Por otro lado, Tralhão et al. (2010) obtuvo los mejores valores de los objetivos individuales con el método de las ponderaciones a través de la resolución de un problema con una función objetivo con pesos altamente sesgados. Cuando se intenta encontrar el óptimo de un determinado criterio, se le asigna a este criterio un muy alto peso relativo, y al resto de los criterios se les asignan valores pequeños pero mayores a cero de forma de lograr soluciones no dominadas. Si K es el conjunto de criterios a optimizar de un problema multiobjetivo determinado y w_k es el peso relativo asignado al k -ésimo objetivo definido por la función Obj_k . Entonces, Tralhão et al. (2010) aplicaron la Ecuación 4.27 para calcular el óptimo del objetivo $k' \in K$.

$$\min \left[w_{k'} Obj_{k'} + \sum_{\substack{k \in K \\ k \neq k'}} (w_k Obj_k) \right] \quad (4.27)$$

donde $w_{k'} \gg w_k \forall k \in K, k \neq k'$. Luego aplicaron la Ecuación 4.28 para normalizar

los pesos relativos y generar soluciones multiobjetivo.

$$\min \sum_{k \in K} \left(w_k \frac{\sum_{\substack{j \in K \\ j \neq k}} Obj_{j*}}{Obj_{k*}} Obj_k \right) \quad (4.28)$$

donde Obj_{k*} es el mejor valor del k -th objetivo. Por un lado, en la Ecuación 4.27 los pesos no se encuentran normalizados. Por otro lado, en la Ecuación 4.28 cada objetivo es afectado por el valor ideal del resto de los objetivos a través de la sumatoria $\sum_{\substack{j \in K \\ j \neq k}} Obj_{j*}$.

Ambas situaciones pueden afectar los propósitos de la normalización en el método de las ponderaciones: evitar sumas absurdas (cuando los objetivos están medidos en unidades diferentes) o el sesgo del resultado de la función hacia aquellos atributos que adopten valores con valor absoluto grande (Ballesteros y Romero, 2013).

La estrategia utilizada en este trabajo para estimar el mejor y el peor valor posible son las siguientes. Primeramente, cada objetivo es optimizado individualmente para construir una versión inicial de la matriz de pagos. Desde estos resultados se obtiene una primera aproximación a los valores ideales y antideales. Luego estos valores son refinados con el método de las ponderaciones utilizando un vector de pesos relativos desbalanceado como en Tralhão et al. (2010). Sin embargo, a diferencia de estos autores, los pesos están normalizados mediante la Ecuación 4.29 propuesta por Zeleny (1974) con sus valores ideales y antideales intrínsecos de la primera aproximación de la matriz de pagos.

$$\min \left[w_{k'} \frac{Obj_{k'} - Obj_{k'*}}{Obj_{*k'} - Obj_{k'*}} + \sum_{\substack{k \in K \\ k \neq k'}} \left(w_k \frac{Obj_k - Obj_{k*}}{Obj_k^* - Obj_{k*}} \right) \right] \quad (4.29)$$

donde Obj_k^* es el peor valor posible del k -ésimo objetivo.

4.2. Evaluación experimental

Di Felice (2014b) establece que en el problema de localización de GAPs, es crucial contar con información descriptiva de buena calidad sobre la distribución poblacional y la tasa de generación de residuos, algo que no es sencillo ya que ambas variables que son altamente dependientes de diversos factores locales (Lebersorger y Beigl, 2011). Montevideo cuenta con abundante información actualizada provista por los gobiernos locales y nacionales.

En el caso de estudio de Montevideo, se utilizan las fracciones de residuos y el sistema de recolección ya utilizado actualmente, primer y segundo punto de Gallardo et al. (2015). Esto son las fracciones secos y húmedos y los contenedores comunitarios. La localización de GAPs y el residuo asignado a cada GAP será determinado mediante el modelo presentado en la Sección 4.1. Se utilizarán tres tipos de contenedores. El coste, la capacidad y el espacio que ocupa cada tipo (esto es, cin_j , cap_j y e_j , respectivamente) son 1000, 2000, 3000 unidades monetarias, 1, 2 y 3 m³ y 1, 2, 3 m² para cada $j \in J$

respectivamente. La densidad de población fue tomada de la web de la Intendencia de Montevideo (Servicio de Geomática, Intendencia de Montevideo, Uruguay, 2017) mientras que la tasa de generación de residuos fue tomada de un informe llevado a cabo por el Ministerio de Vivienda, Ordenamiento Territorial y Medio Ambiente de Uruguay (2012). Las distancias entre los hogares y los posibles puntos limpios se calcularon utilizando OpenStreetMap¹ a través de una versión modificada ad-hoc de la librería de R desarrollada por Eugster y Schlesinger (2013) con el objeto de obtener distancias peatonales en vez de distancia en automóvil como brinda la librería original. Como en diversos trabajos similares (Coutinho-Rodrigues et al., 2012; Tralhão et al., 2010), los generadores son agrupados por cercanía para reducir la dimensión del problema y mantener la tratabilidad del mismo. En este caso, los generadores son agrupados por cuadra. La Figura 4.2 muestra la localización de los generadores que coinciden con las potenciales ubicaciones de los puntos limpios. También presenta las localizaciones actuales de los contenedores. El valor de los otros parámetros descritos en la Tabla 4.1 que fueron usados para las pruebas son $d_m = 300m$; $Es_i = 5m^2 \forall i \in I$; y a_y es igual a 1, 2 y 3 para cada $y \in Y$.

Se consideraron dos escenarios diferentes para el área de estudio:

- *Escenario 1* sin clasificación de residuos en origen.
- *Escenario 2* con la clasificación en origen en las dos fracciones de residuos que se utilizan actualmente en Montevideo: residuos secos y húmedos.

4.2.1. Resultados

El modelo fue resuelto utilizando CPLEX 12.7.1 a través de la vinculación *Concert Technology* en un entorno de C++. CPLEX posee la opción de trabajar con paralelismo utilizando dos maneras diferentes, determinística y oportunista (International Business Machines Corporation, 2016). El modo oportunista generalmente es más rápido que el determinista debido principalmente a que ahorra el tiempo que se dedica a mantener el determinismo de la solución. Esto es que dos ejecuciones del mismo algoritmo con los mismos datos de entrada en la misma máquina no garantizan seguir el mismo camino para obtener la solución y por lo tanto pueden tener distintos tiempos de cálculo (Achterberg y Wunderling, 2013). En resumen, los escenarios se resolvieron mediante tres enfoques diferentes: secuencial (utilizando un núcleo), paralelo determinista y paralelo oportunista. La computadora utilizada tenía un procesador Intel Core i7, una memoria RAM de 16 GB en un entorno de Windows 10. Para comprobar la no dominancia entre las soluciones se utilizó el algoritmo de Kung-Luccio-Preparata (1975). Todas las corridas del escenario 1 tenían como límite temporal 4200 segundos, mientras que en segundo escenario, de mayor complejidad, se estableció 8400 segundos.

Para estimar los rangos de los objetivos se utilizó el procedimiento explicado en la Sección 4.1.1. Los resultados del primer escenario con los tres métodos de CPLEX se presentan en las Tablas 4.2-4.4. Con esto se constituye la matriz de pagos (Tabla 4.5).

¹<https://www.openstreetmap.org>

Primer escenario

Tabla 4.2: Valores extremos obtenidos con el método secuencial de un núcleo del primer escenario.

	<i>Obj1</i>	<i>Obj2</i>	<i>Obj3</i>	Tiempo de cómputo (seg)	<i>gap</i>
Optimización monobjetivo					
mín <i>Obj1</i>	0,195122	250,317	410000	4200,01	0,6353
mín <i>Obj2</i>	0,414634	0	410000	0,30	0,0000
mín <i>Obj3</i>	0,721545	250,207	80000	4200,02	0,9750
Valores extremos iniciales					
Mínimo	0,195122	0,000	80000		
Máximo	0,721545	250,317	410000		
Método de las ponderaciones desbalanceado					
mín <i>Obj1</i>	0,197154	149,012	140000	4200,09	26,8840
mín <i>Obj2</i>	0,349593	0,000	261000	0,70	0,0000
mín <i>Obj3</i>	0,219512	107,073	80000	4200,09	1,1734
Valores extremos refinados					
Mínimo	0,195122	0,000	80000		
Máximo	0,349593	250,317	410000		

El mismo procedimiento se sigue para el segundo escenario en las Tablas 4.6-4.8 y 4.9, respectivamente. Un resultado interesante es que en el escenario 2, el modo secuencial, no es capaz siquiera de construir la matriz de pagos inicial (Tabla 4.6). Esto demuestra, naturalmente, la mayor potencialidad del paralelismo para resolver problemas complejos. En general, las soluciones obtenidas en la matriz de pagos a través del refinamiento usando el método de la ponderaciones dominan las de la matriz de pagos inicial excepto para el objetivo *Obj3* de la optimización monobjetivo que permanece como solución no dominada.

Luego de construir las matriz de pagos, se aplica el método AUGMECON2. El número de puntos grilla, esto es, el número de intervalos en los cuales se dividen los rangos de los objetivos se establece en 5. Por lo tanto, el límite superior de la cantidad de corridas que pueden realizarse es de $(g+1)^{p-1}$, donde g es el número de puntos grilla y p es el número de objetivos. En este caso es 36. Este es sólo una cota superior al número de corridas debido al mecanismo de aceleración con abandono temprano de corridas para las que no se encuentra solución factible.

4.2.2. Análisis de resultados

Las Tablas 4.10-4.12 y 4.13-4.15 muestran las soluciones multiobjetivo de los escenarios 1 y 2, respectivamente. Estas tablas indican de izquierda a derecha los valores de los tres objetivos, si la solución es dominada o no, el tiempo de cómputo, la desviación del

Tabla 4.3: Valores extremos obtenidos con el método de paralelismo determinista del primer escenario.

	<i>Obj1</i>	<i>Obj2</i>	<i>Obj3</i>	Tiempo de cómputo (seg)	<i>gap</i>
Optimización monobjetivo					
mín <i>Obj1</i>	0,195122	250,317	410000	4204,14	0,5066
mín <i>Obj2</i>	0,414634	0,000	410000	0,42	0,0000
mín <i>Obj3</i>	0,721545	250,207	80000	4201,86	0,9807
Valores extremos iniciales					
Mínimo	0,195122	0,000	80000		
Máximo	0,721545	250,317	410000		
Método de las ponderaciones desbalanceado					
mín <i>Obj1</i>	0,199187	163,220	150000	4208,28	19,2126
mín <i>Obj2</i>	0,349593	0,000	261000	1,27	0,0000
mín <i>Obj3</i>	0,219512	106,805	80000	4210,45	1,1678
Valores extremos refinados					
Mínimo	0,195122	0,000	80000		
Máximo	0,349593	250,317	410000		

Tabla 4.4: Valores extremos obtenidos con el método de paralelismo oportunista del primer escenario.

	<i>Obj1</i>	<i>Obj2</i>	<i>Obj3</i>	Tiempo de cómputo (seg)	<i>gap</i>
Optimización monobjetivo					
mín <i>Obj3</i>	0,701220	265,256	80000	4202,13	0,0187
mín <i>Obj2</i>	0,414634	0,000	410000	0,45	0,0000
mín <i>Obj1</i>	0,197154	233,329	410000	4208,89	0,5104
Valores extremos iniciales					
Mínimo	0,197154	0,000000	80000		
Máximo	0,701220	265,256	410000		
Método de las ponderaciones desbalanceado					
mín <i>Obj3</i>	0,219512	111,122	80000	4234,08	1,2636
mín <i>Obj2</i>	0,349593	0,000	261000	1,23	0,0000
mín <i>Obj1</i>	0,199187	151,963	145000	4211,75	28,1463
Valores extremos refinados					
Mínimo	0,197154	0,000	80000	-	-
Máximo	0,349593	233,329	410000	-	-

Tabla 4.5: Matriz de pagos del primer escenario.

	<i>Obj1</i>	<i>Obj2</i>	<i>Obj3</i>
Valor ideal	0,195122	0,000	80000
Velor antideal	0,349593	233,329	410000

Tabla 4.6: Valores extremos obtenidos con el método secuencial de un núcleo del segundo escenario.

	<i>Obj1</i>	<i>Obj2</i>	<i>Obj3</i>	Tiempo de cómputo (seg)	<i>gap</i>
Optimización monobjetivo					
mín <i>Obj1</i>	No se encontró solución factible			-	-
mín <i>Obj2</i>	1,477640	0,000	410000	1,12	0,0000
mín <i>Obj3</i>	1,569110	244,927	87000	8400,05	0,9781

Tabla 4.7: Valores extremos obtenidos con el método de paralelismo determinista del segundo escenario.

	<i>Obj1</i>	<i>Obj2</i>	<i>Obj3</i>	Tiempo de cómputo (seg)	<i>gap</i>
Optimización monobjetivo					
mín <i>Obj1</i>	0,449187	245,159	410000	8428,28	0,9028
mín <i>Obj2</i>	1,619920	0,000	410000	1,59	0,0000
mín <i>Obj3</i>	1,280490	239,268	87000	8401,95	0,0977
Valores extremos iniciales					
Mínimo	0,449187	0,000	87000	-	-
Máximo	1,619920	245,159	410000	-	-
Método de las ponderaciones desbalanceado					
mín <i>Obj1</i>	0,445122	176,268	208000	8428,42	44,5696
mín <i>Obj2</i>	0,847561	0	233000	2,80	0,0000
mín <i>Obj3</i>	0,487805	113,488	87000	8473,20	5,5749
Valores extremos refinados					
Mínimo	0,445122	0,000	87000	-	-
Máximo	0,847561	176,268	233000	-	-

Tabla 4.8: Valores extremos obtenidos con el método de paralelismo oportunista en el segundo escenario.

	<i>Obj1</i>	<i>Obj2</i>	<i>Obj3</i>	Tiempo de cómputo (seg)	<i>gap</i>
Optimización monobjetivo					
mín <i>Obj1</i>	0,447154	231,695	410000	8421,31	0,9037
mín <i>Obj2</i>	1,619920	0,000	410000	1,27	0,0000
mín <i>Obj3</i>	1,219510	253,439	87000	8403,16	0,9981
Valores extremos iniciales					
Mínimo	0,447154	0,000	87000	-	-
Máximo	1,619920	253,439	410000	-	-
Método de las ponderaciones desbalanceado					
mín <i>Obj1</i>	0,445122	184,634	200000	8410,00	36,8964
mín <i>Obj2</i>	0,847561	0,000	233000	2,03	0,0000
mín <i>Obj3</i>	0,487805	119,939	87000	8461,80	5,4604
Valores extremos refinados					
Mínimo	0,445122	0,000	87000	-	-
Máximo	0,847561	184,634	233000	-	-

Tabla 4.9: Matriz de pagos en el segundo escenario.

	<i>Obj1</i>	<i>Obj2</i>	<i>Obj3</i>
Valor ideal	0,445122	0,000	87000
Valor antideal	0,847561	176,268	233000

valor óptimo calculada por CPLEX (*gap*), el número de contenedores de cada tipo utilizado en la solución y la cantidad de puntos limpios (o combinación de puntos limpios-tipo de residuo en el caso de escenario dos) que son visitados con cada perfil de frecuencia. La dominancia es verificada dentro de cada tabla, es decir, localmente para cada enfoque. Por otro lado, las Tablas 4.16 y 4.17 muestran los óptimos globales no inferiores, es decir, considerando todas las soluciones encontradas, para los escenarios 1 y 2 respectivamente. En el primer escenario el método secuencial encuentra menos soluciones Pareto óptimas (4) que el paralelo determinista (8) y el oportunista (8). Algunas de las soluciones encontradas en la matriz de pagos permanecen como soluciones no dominadas. En el segundo escenario, el método paralelo determinista encontró 4 soluciones no dominadas, el método secuencial 3 y el oportunista 2. En general estos resultados demuestran que el segundo escenario es más complejo que el primero. Esto es razonable dado que el las variables y restricciones indexadas en h se duplican.

Tabla 4.10: Soluciones obtenidas con el método secuencial en el primer escenario.

Id.	Obj1	Obj2	Obj3	Tiempo de cómputo (seg)	gap	Dominancia	Número de contenedores			Número de puntos limpios		
							j = 1	j = 2	j = 3	y = 1	y = 2	y = 3
1	0,199187	134,988	122000	4200,02	0,6661	ND	79	11	7	10	8	7
2	0,199187	173,366	144000	4199,92	0,8350	D	93	18	5	6	16	7
3	0,199187	183,646	129000	4199,88	0,8845	D	70	19	7	9	10	7
4	0,203252	91,622	147000	4199,95	0,4034	ND	90	18	7	7	12	11
5	0,221545	46,061	209000	4200,11	0,0833	ND	105	25	18	1	15	29
6	0,337398	0,000	278000	0,08	0,0000	ND	110	33	34	0	2	80
7	0,337398	0,000	282000	0,09	0,0000	D(*)	101	38	35	0	2	80
8	0,449187	0,000	212000	0,08	0,0000	ND	117	22	17	0	57	25
9	0,764228	0,000	146000	0,11	0,0000	ND	106	14	4	48	20	14

(*) El *gap* medido por CPLEX es de $1,49647e^{-6}$.

Ejecuciones en las que no se halló solución factible ni se detectó infactibilidad: 7. Ejecuciones infactibles: 1.

Tabla 4.11: Soluciones obtenidas con el método de paralelismo determinista en el primer escenario.

Id.	Obj1	Obj2	Obj3	Tiempo de cómputo (seg)	gap	Dominancia	Número de contenedores			Número de puntos limpios		
							j = 1	j = 2	j = 3	y = 1	y = 2	y = 3
1	0,197154	195,671	130000	31581,10	0,8576	ND	92	7	8	9	26	0
2	0,199187	181,695	135000	29616,90	0,8318	D	115	4	4	8	27	0
3	0,199187	130,561	135000	19702,80	0,6730	ND	75	15	10	8	12	7
4	0,201220	91,317	149000	31794,90	0,3960	ND	85	17	10	7	11	12
5	0,201220	92,427	119000	19558,60	0,3691	ND	92	9	3	10	11	3
6	0,221545	46,585	199000	24120,50	0,0782	ND	134	22	7	1	15	26
7	0,337398	0,000	282000	0,25	0,0000	D(*)	101	38	35	0	2	80
8	0,337398	0,000	277000	0,38	0,0000	ND	108	32	35	0	2	80
9	0,449187	0,000	212000	0,31	0,0000	ND	117	22	17	0	57	25
10	0,764228	0,000	146000	0,28	0,0000	ND	103	14	5	48	20	14

(*) El *gap* medido por CPLEX es de $1,50006e^{-6}$.

Ejecuciones en las que no se halló solución factible ni se detectó infactibilidad: 6. Ejecuciones infactibles: 1.

Tabla 4.12: Soluciones obtenidas con el método de paralelismo oportunista en el primer escenario.

Id.	Obj1	Obj2	Obj3	Tiempo de cómputo (seg)	gap	Dominancia	Número de contenedores			Número de puntos limpios		
							$j = 1$	$j = 2$	$j = 3$	$y = 1$	$y = 2$	$y = 3$
1	0,197154	139,524	125000	29725,50	0,6530	ND	85	17	2	10	7	8
2	0,197154	175,585	125000	32878,20	0,8260	D	72	13	9	9	11	5
3	0,197154	190,171	119000	33200,00	0,8731	ND	93	13	0	11	5	8
4	0,20122	90,073	140000	24310,30	0,0719	ND	97	8	9	7	15	6
5	0,219512	46,646	213000	24310,30	0,0719	ND	128	26	11	1	14	30
6	0,221545	46,500	198000	17488,90	0,0706	ND	115	25	11	2	15	26
7	0,337398	0,000	278000	0,23	0,0000	ND	110	33	34	0	2	80
8	0,337398	0,000	282000	0,17	0,0000	D(*)	101	38	35	0	2	80
9	0,449187	0,000	212000	0,22	0,0000	ND	117	22	17	0	57	25
10	0,764228	0,000	146000	0,28	0,0000	ND	103	14	5	48	20	14

(*) El *gap* medido por CPLEX es de $1,50006e^{-6}$.

Ejecuciones en las que no se halló solución factible ni se detectó infactibilidad: 6. Ejecuciones infactibles: 1.

Tabla 4.13: Soluciones multiobjetivo obtenidas con el método secuencial en el segundo escenario.

Id.	Obj1	Obj2	Obj3	Tiempo de cómputo (seg)	gap	Dominancia	Número de contendores			Número de puntos limpios		
							j = 1	j = 2	j = 3	y = 1	y = 2	y = 3
1	0,678862	0,000	31600	0,17	0,0000	ND	59	72	33	0	6	158
2	0,485772	35,085	26200	8399,69	0,0822	ND	88	24	10	0	23	85
3	0,439024	69,720	20000	8399,78	0,4357	ND	62	29	6	8	24	48
4	0,447154	103,780	21000	8399,98	0,7010	D	47	33	14	5	32	47
5	0,445122	137,646	22000	8399,50	0,8097	D	67	23	9	4	27	57
6	0,443089	173,976	19500	8399,80	0,8762	ND	72	6	4	9	26	43

Tabla 4.14: Soluciones multiobjetivo obtenidas con el método de paralelismo determinista en el segundo escenario.

Id.	Obj1	Obj2	Obj3	Tiempo de cómputo (seg)	gap	Dominancia	Número de contendores			Número de puntos limpios		
							j = 1	j = 2	j = 3	y = 1	y = 2	y = 3
1	0,678862	0,000	31600	0,78	0,00000	ND	59	72	33	0	6	158
2	0,481707	34,878	26600	48163,90	0,07135	ND	94	17	9	0	21	87
3	0,441057	67,342	20500	33802,40	0,44840	ND	53	21	16	6	29	47
4	0,439024	103,720	18500	34630,20	0,69358	ND	61	10	8	11	24	39
5	0,445122	135,878	18500	39863,50	0,81707	D	59	15	8	14	15	45
6	0,447154	173,756	22000	58638,30	0,87273	D	70	20	9	6	20	62

(*) El *gap* medido por CPLEX es de $1,50006\epsilon^{-6}$.

Tabla 4.15: Soluciones multiobjetivo obtenidas con el método de paralelismo oportunista en el segundo escenario.

Id.	Obj1	Obj2	Obj3	Tiempo de cómputo (seg)	gap	Dominancia	Número de contenedores			Número de puntos limpios		
							j = 1	j = 2	j = 3	y = 1	y = 2	y = 3
1	0,678862	0,000	31600	0,81	0,0000	ND	59	72	33	0	6	158
2	0,479675	35,146	26100	35318,50	0,0737	ND	86	25	10	0	24	82
3	0,443089	68,037	20500	17418,60	0,4494	MD	68	17	4	6	30	46
4	0,449187	101,280	20000	27338,60	0,7063	ND	65	20	8	8	9	34
5	0,443089	130,659	19500	51754,60	0,8056	ND	64	16	7	11	18	49
6	0,457317	147,756	22500	62935,90	0,8753	ND	73	20	10	6	21	63

(*) El *gap* medido por CPLEX es de $1,50006e^{-6}$.

Tabla 4.16: Soluciones no dominadas del primer escenario.

Id.	Obj1	Obj2	Obj3	Origen
1	0,195122	250,317	410000	Det: payoff
2	0,197154	139,524	125000	Op: 1
3	0,197154	190,171	119000	Op: 3
4	0,199187	134,988	122000	Sec: 1
5	0,199187	130,561	135000	Det: 3
6	0,199187	151,963	14500	Op: payoff
7	0,201220	92,427	119000	Det: 5
8	0,201220	90,073	140000	Op: 4
9	0,219512	46,646	213000	Op: 5
10	0,219512	106,805	80000	Det: payoff
11	0,221545	46,061	209000	Sec: 5
12	0,221545	46,500	198000	Op: 6
13	0,337398	0,000	277000	Det: 8
14	0,349593	0,000	261000	Det: payoff
15	0,449187	0,000	212000	Sec: 8, Det: 9, Op: 9
16	0,764228	0,000	146000	Sec: 9, Det: 10, Op: 10

Tabla 4.17: Soluciones no dominadas del segundo escenario.

Id.	Obj1	Obj2	Obj3	Origen
1	0,439024	69,720	20000	Sec: 3
2	0,439024	103,720	18500	Det: 4
3	0,441057	67,342	20500	Det: 3
4	0,479675	35,146	26100	Op: 2
5	0,481707	34,878	26600	Det: 2
6	0,485772	35,085	26200	Sec: 2
7	0,678862	0,000	31600	Sec: 1
8	0,678862	0,000	31600	Det: 1
9	0,678862	0,000	31600	Op: 1

4.3. Discusión de resultados

En el caso de Montevideo se realizó una modificación al método AUGMECON2 en la formación de la matriz de pagos. El modelo planteado en este capítulo era más complejo de resolver que el planteado para el caso de Bahía Blanca (Sección 3.1) ya que se consideran tres objetivos. Esta modificación permitió hallar la matriz de pagos para resolver el problema y poder explorar la relación de compromiso entre los diversos objetivos. El tercer objetivo adicionado en este problema es algo relativamente novedoso que no es común en la bibliografía. El mismo puede considerarse de utilidad que permite limitar el impacto que tiene la localización de los GAPs con el ruteo posterior.

Parte III

Atracción visual en problemas de ruteo de vehículos

Capítulo 5

Atracción visual en problemas de ruteo de vehículos

El problema de ruteo de vehículos o *vehicle routing problem* (VRP) es un problema de optimización combinatoria que concierne el diseño de los recorridos óptimos de una flota de vehículos para servir a un conjunto de clientes (véase Toth y Vigo, 2014). Cuando se resuelve un problema VRP pueden perseguirse distintos objetivos y considerar distintas restricciones dependiendo del caso de aplicación. Esto ha llevado a que existan una gran cantidad de variantes de este problema. Por ejemplo, pueden citarse el problema de ruteo con restricciones de capacidad o *Capacitated VRP* (CVRP), el problema con restricciones de distancias o *Distance-Constrained VRP*, el problema con ventanas de tiempo o *VRP with Time Windows* (VRPTW), el VRP con *Backhauls*, el VRP con *Pickup y Delivery* (PDP) y el VRP periódico o *Periodic VRP* (PVRP). Para una descripción más extensa de estas variantes puede consultar la obra de Irnich et al. (2014). En general, los criterios convencionales o tradicionales que se intentan optimizar en los problemas de ruteo tratan sobre aspectos objetivos (y cuantitativos) como minimizar los costos de transporte, las distancias o los tiempos de viaje, el número de vehículos requeridos o las penalizaciones por violación de restricciones que se asumen como “débiles”, tales como las ventanas de tiempo.

Otro objetivo que puede considerarse es la llamada “atracción visual” de las rutas. La “atracción visual” está relacionada con la aceptación que tienen las soluciones producidas por los algoritmos VRP por parte de administrador o planificador de las rutas¹, por lo que es un objetivo que se menciona frecuentemente en trabajos de VRP que se encuentran orientados a resolver casos reales. Si bien no es fácil de elaborar una definición precisa de la atracción visual (véase Constantino et al., 2015), diversos autores relacionan este concepto subjetivo con algunas características que deben exhibir las rutas de un plan. Como regla general las rutas deben:

¹en el marco de esta Parte III se denomina administrador o planificador a las personas que se encuentran a cargo de la implementación del plan de rutas. En general, son los mandos operativos que se encuentran directamente a cargo de los conductores.

- **ser compactas** (véase Bräysy y Hasle, 2014; Matis, 2008; Poot et al., 2002; Rossit et al., 2016; Hollis y Green, 2012; Matis y Koháni, 2011; Tang y Miller-Hooks, 2006),
- **no deben solaparse** (véase Hollis y Green, 2012; Kim et al., 2006; Rossit et al., 2016) o **sin cruzamientos** entre ellas (véase Bräysy y Hasle, 2014; Lu y Dessouky, 2006; Matis, 2008; Poot et al., 2002; Rossit et al., 2016; Tang y Miller-Hooks, 2006)),
- **no deben ser complejas** (véase Gretton y Kilby, 2013; Constantino et al., 2015).

Uno puede tener una idea intuitiva del concepto de compacidad, relacionado al hecho de que se extienda por un área geográfica reducida y no “elongada”. También de manera intuitiva puede plantearse que dos rutas se encuentran solapadas cuando ocupan el mismo área geográfica. Por su parte, la complejidad de la ruta se asocia a características que se definen para cada ruta individualmente y no al plan de ruteo en su conjunto. Si bien estos primeros acercamientos a estos conceptos pueden resultar imprecisos, resultan adecuados para presentar el concepto de atracción visual en este capítulo. En el Capítulo siguiente (6) se abordarán en detalle.

Las diferencias entre perseguir objetivos tradicionales como la minimización de distancias o costos o la maximización de la atracción visual pueden ser notorias. Por ejemplo, en las Figuras 5.1 y 5.2 se presentan las soluciones obtenidas para optimizar dos instancias, una de un CVRP y otra de un VRPTW, respectivamente, bajo dos objetivos diferentes. Al examinar las figuras, se vuelve evidente que optimizar la atracción visual produce, por un lado, soluciones más compactas y con menor área solapada y, por otro lado, generalmente más extensas que aquellas obtenidas optimizando el costo del plan. Los algoritmos que se utilizaron para diseñar las rutas visualmente atractivas de las Figuras 5.1 y 5.2 incentivan la atracción visual usando diversos criterios: la obtención de rutas compactas y no solapadas para el caso de la Figura 5.1 y estos criterios más la minimización de los cruces entre caminos para el caso de la Figura 5.2.

El objetivo de este capítulo es realizar una revisión de la bibliografía existente en un campo que ha atraído un fuerte interés en los últimos años tanto de las compañías privadas como de la comunidad académica, generalmente motivado por la solución de problemas reales (véase, por ejemplo, Hollis y Green, 2012; Jang et al., 2006; Kant et al., 2008; Kim et al., 2006).

5.1. Origen y beneficios de la atracción visual en aplicaciones prácticas

A pesar de la relativa vaguedad con que se define la atracción visual, este concepto ha sido frecuentemente considerado como un elemento central en el diseño de rutas de vehículos. El primer uso del término fue realizado en Poot et al. (2002) para expresar los requerimientos de sus clientes. Los autores notaron que algunos clientes consideraban los resultados provistos por el software de planificación de rutas de la compañía en

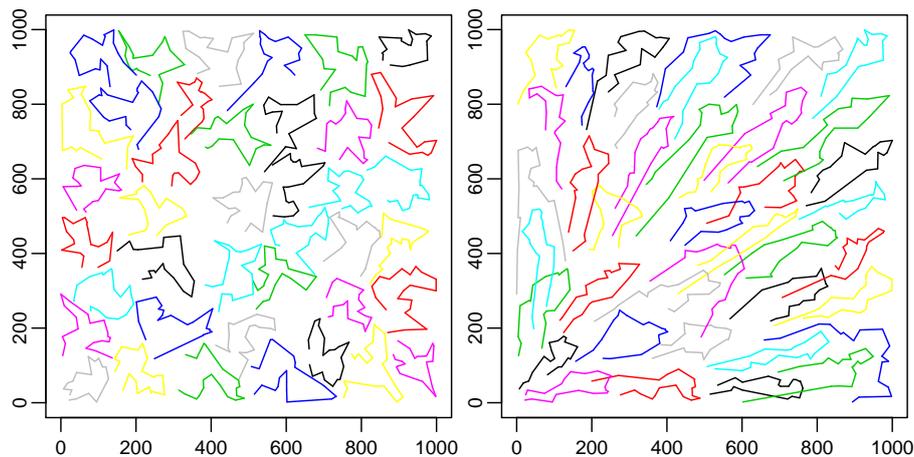


Figura 5.1: Diferentes enfoques de resolución para la instancia CVRP X-n801-k40 del benchmark de Uchoa et al. (2017). La imagen izquierda maximiza la atracción visual y la derecha minimiza el costo. Fuente: Rossit et al. (2016).

la que trabajaban (la neerlandesa ORTEC²) como “pobres”. Sin embargo, la causa de esta “pobreza” no se encontraba en el desempeño de la rutas en cuanto a las métricas tradicionales, como el costo, número total de vehículos o distancia total de viaje, sino a indicadores no estándares para la época que aún no habían sido estudiados adecuadamente. Los autores evidenciaron que las soluciones eran aceptadas intuitivamente por los administradores cuando eran planes visualmente atractivos que eran más lógicos y cercanos a la forma tradicional de trabajo, la cual generalmente estaba basada en una planificación manual de los recorridos. Esto generaba confianza en el plan por parte de los conductores y planificadores, derivando en una rápida aceptación del nuevo plan propuesto.

En los años que siguieron, regularmente se ha resaltado en la literatura la importancia de tener en cuenta los aspectos de la atracción visual, lo que permitió expandir los fundamentos de esta relevancia basándose principalmente en las aplicaciones prácticas. Matis (2008) establece que si un conjunto de rutas se solapan entre ellas provocarán las quejas del conductor que aducirá que la planificación fue realizada de forma deficiente. Los administradores tienden a rechazar las rutas que han sido optimizadas en distancias y se extienden por muchas áreas geográficas distintas y, además, presentan cruces entre ellas (Mourgaya y Vanderbeck, 2007). Las soluciones “agradables” requieren de un menor esfuerzo para su implementación, lo que reduce el tiempo necesario para instruir a los conductores sobre las rutas y, además, provocan un desempeño más estable debido a que los conductores suelen estar asignados a una misma área geográfica con condiciones de tráfico homogéneas (véase Battarra et al., 2014; Schneider et al., 2014). Asimismo, las rutas son objeto de continuas modificaciones a través del aprovechamiento de la

²<http://www.ortec.com/>

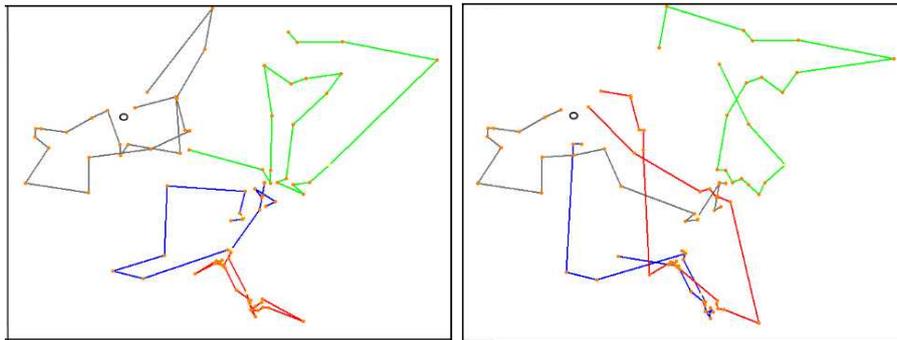


Figura 5.2: Diferentes enfoques de resolución en una instancia real de VRPTW que representa la distribución diaria de Schweppes Australia Pty. Ltd. en la ciudad de Melbourne. La imagen izquierda maximiza la atracción visual y la derecha minimiza el costo. Fuente: Hollis y Green (2012).

familiaridad que se genera entre los conductores y los clientes que son servidos en la ruta (véase Kant et al., 2008; Poot et al., 2002).

En Hollis y Green (2012), se analizaron otros beneficios prácticos de las rutas compactas. Si un cliente no puede ser atendido en el momento estipulado en la planificación, será más fácil visitar a este cliente nuevamente en un momento posterior si el vehículo permanece cerca durante el resto de su recorrido, es decir, en un mismo zona geográfica. De manera similar, ante una situación como una congestión de tránsito o un corte de una calle, será más fácil encontrar una ruta alternativa si los clientes se encuentran ubicados dentro de un área compacta.

Más recientemente, Battarra et al. (2014) describieron algunas aplicaciones donde la compacidad de las rutas es una cuestión de crucial importancia. Por ejemplo en el transporte de personas mayores a centros de recreación, donde los usuarios prefieren ser buscados juntamente con sus vecinos o el caso de los sectores urbanos aislados por muros o cercas por cuestiones de seguridad, como son los barrios residenciales cerrados (o *countries*) o los parques industriales. Cuando deben visitarse más de un cliente de una misma comunidad, sería provechoso que se encuentren consecutivos en la ruta del mismo vehículo. Esto se debe a que el ingreso al sector, que generalmente involucra la presentación de cierta documentación, es un proceso que requiere de un tiempo considerable. Otros casos prácticos, citados en Bräysy y Hasle (2014) (véase también Hasle et al., 2010, 2011), se presentan en la distribución de diarios. En esta actividad, no es deseable que la distribución en un mismo barrio la realicen diferentes distribuidores, debido a que clientes que son vecinos pueden recibir su diario con una diferencia horaria importante.

Bosch (2014) evidenció que los planificadores tienden a rechazar rutas que impliquen que cuando los vehículos deben viajar a atender clientes en zonas alejadas, se le adicionen visitas a otros clientes ubicados en las inmediaciones de los trayectos de ida y retorno de la región distante. Ven esto como un uso ineficiente de la capacidad del vehículo, ya que consideran que conducir a la región lejana es la parte más costosa de la ruta. Por

lo tanto, prefieren servir a todos los clientes alejados con un vehículo y a los clientes ubicados cerca de los trayectos (y probablemente cercanos al depósito) con un segundo vehículo. En el mismo trabajo se recaban dos requisitos frecuentes de los conductores de vehículos: cuando se visitan varias poblaciones cada poblado debe ser visitado por la menor cantidad posible de vehículos; y las distancias entre clientes de una misma ruta deben ser lo más cortas posibles.

Como conclusión, la atracción visual ha demostrado ser un factor muy importante en las aplicaciones prácticas. Invertir gran cantidad de recursos (humanos y computacionales) y tiempo en diseñar un plan de distribución (casi)óptimo en términos de costos que, a la vez, resulta muy poco atractivo y que, por lo tanto, será probablemente rechazado o modificado “sobre la marcha” de acuerdo a las consideraciones de los administradores y conductores (remarcando que estos cambios que estarán fuera del control de los diseñadores) puede resultar de muy poca utilidad. Considerar la atracción visual al momento de diseñar la planificación, y, por ende, la satisfacción y confianza del usuario de dicho plan, puede contribuir a reducir los costos de implementación del plan. Sin embargo, limitar estos costos no es la única razón para incluir la atracción visual en la etapa de diseño. Como se ha descrito en la literatura especializada citada en esta sección, existen otros beneficios asociados, además de aplicaciones particulares donde se requieren planes de rutas agradables. En la Sección 5.1.2 presentaremos algunas consideraciones sobre la relación entre los costos y la atracción visual, relación que a pesar de lo que podría preverse no es siempre constante.

5.1.1. Percepción humana en el Problema del Agente Viajero

La razón por la cual los administradores y conductores tienden a preferir (y considerar más eficientes) las rutas compactas y aisladas parece estar basada en características innatas del ser humano. Hay múltiples estudios que analizan los aspectos que los humanos buscan cuando deben hallar una solución óptima al Problema del Agente Viajero o *Traveling Salesman Problem* (TSP), es decir, el caso especial de un VRP con un único vehículo de capacidad ilimitada (para una revisión detallada de este trabajos puede referirse a MacGregor y Chu (2011)). La importancia de identificar estos aspectos recae en poder definir por qué las personas consideran algunas soluciones como más “agradables” que otras, esto es, más cercanas al óptimo.

El primer estudio relevante en la temática fue realizado por el ruso Polivanova en 1974 (trabajo en idioma ruso citado en Applegate et al., 2011) que comparó la performance de los individuos ante instancias de TSP presentadas en su forma geométrica, esto es, los nodos dibujados en el espacio y los costos de viajes representados por las distancias entre ellos, y en forma no geométrica brindándole a los individuos un listado explícito con los costos de viaje entre nodos. Si bien la pequeña escala de las instancias utilizadas (como máximo tenían 10 nodos) permitía hallar fácilmente los costos más bajos en el listado explícito, los participantes tuvieron una mejor performance en las instancias geométricas. Según Applegate et al. (2011) esto no es sorprendente si se considera que el aspecto geométrico del TSP fue sido utilizado en muchas ocasiones en la historia de la humanidad,

para lo cual brindan distintos ejemplos en la historia de las artes y las ciencias. Sin embargo, esto evidencia que los individuos hacen gran uso de su percepción, y no sólo de sus habilidades cognitivas, al resolver un TSP.

MacGregor y Ormerod (1996) sobre la base de un trabajo experimental sugirieron que los humanos relacionan las soluciones óptimas del TSP con los caminos que siguen el casco convexo del conjunto de nodos, es decir, el menor polígono convexo que encierra a todos los nodos, denominando a esta propiedad como “hipótesis del casco convexo”. Sin embargo, otros autores como Lee y Vickers (2000); Van Rooij et al. (2003) y Vickers et al. (2001) han criticado la validez de estos resultados. Además, Van Rooij et al. (2003) propusieron que los humanos encuentran las soluciones sin cruces entre caminos como más óptimas que aquellas que tienen cruces (véase también Vickers et al., 2003). Esta hipótesis es respaldada por el hecho que un tour óptimo en un TSP simétrico, esto es, donde la matriz de distancias repesta la desigualdad triangular o de Minkowski, no se intersecta a sí mismo (Flood, 1956). MacGregor et al. (2004) compararon ambas hipótesis mencionadas, la del casco convexo y la de la elusión de cruces, llegando a la conclusión de que ambas hipótesis no son mutuamente excluyentes. Cuando se les pide a los individuos construir un tour de TSP óptimo, a pesar de que mantienen el seguimiento del casco convexo circundante como estrategia principal tienden a evitar los cruces cuando conectan puntos interiores, esto es, ubicados lejos de la frontera del casco.

La presencia de clústers de nodos también está relacionado con la calidad de las soluciones construidas por los humanos en el TSP. Dry et al. (2012) estudió la relación entre la performance humana en resolver TSP y la distribución de los nodos, concluyendo que los individuos encuentran más fácil resolver (y obtienen mejores soluciones) en instancias donde los nodos forman grupos compactos, en oposición a los casos donde los nodos se encuentran uniformemente distribuidos. En relación a esto, MacGregor (2015) sugirió que el desempeño humano en resolver TSP se encuentra influenciado por la localización de los clientes, reconociendo que la instancias donde los puntos están cerca de su casco convexo son más fáciles de resolver. Relacionado a esto, Vickers et al. (2006) realizó un experimento donde se les mostraba a un grupo de personas soluciones de instancias del TSP (aunque sin decirle que efectivamente lo eran) y se les pedía que las cataloguen de acuerdo a su atractivo estético. Los resultados evidenciaron una fuerte correlación entre el atractivo estético de una solución y su compacidad.

Como resume de estos trabajo puede concluirse que, al momento de resolver un TSP, los humanos consideran características similares a aquellas que se introdujeron con el concepto de atracción visual en la Sección 5, tales como cruzamientos y compacidad. Por lo tanto, las soluciones que incluyen estas propiedades son más atractivas en la percepción humana y, generalmente, preferidas frente a aquellas que no las poseen.

5.1.2. Atracción visual y costo de los problemas de ruteo: ¿siempre una relación negativa?

Vickers et al. (2001) consultó a dos grupos diferentes de personas para que contruyeran soluciones de TSP bajo dos consignas diferentes. Mientras que a un grupo se le

solicitó que encontraran la solución con la menor distancia total, al otro se le pidió que construya la solución más natural, atractiva o estéticamente agradable. La diferencia entre las distancias de los tours hallados por ambos grupos fue notablemente pequeña. Esto coincide con los hallazgos de Ormerod y Chronicle (1999), que indican que en instancias simples de TSP, esto es, soluciones donde la mayor cantidad de puntos se encuentran cerca del casco convexo, los humanos tienden a considerar a las soluciones eficientes como más atractivas que las soluciones subóptimas. Similarmente, Lu y Dessouky (2006) observaron que, al comparar dos soluciones sin cruces de la misma instancia de TSP, la más cercana al casco convexo es más atractiva visualmente y tiene una mayor probabilidad de ser más corta. Sin embargo, Ormerod y Chronicle (1999) señalaron que cuando la instancia es más compleja, es decir, tiene un mayor número de puntos localizados lejos de los límites del polígono convexo, esta capacidad de construir buenas soluciones se deteriora debido a que el seguimiento de reglas simples para construir soluciones lleva, frecuentemente, a recorridos subóptimos. Esto significa que la habilidad humana innata de reconocer la calidad de la solución a través de la inspección visual disminuye cuando la complejidad del problema aumenta.

Este concepto puede extenderse si se considera que la complejidad puede no estar únicamente asociada a un mayor número de puntos interiores sino también a la inclusión de otras restricciones, como ocurre con la introducción de ventanas de tiempo de los clientes o capacidad limitada de los vehículos. Por lo tanto, no es necesariamente cierto que las soluciones atractivas visualmente para problemas VRP sean más eficientes en términos de las métricas tradicionales (Bräysy y Hasle, 2014; Poot et al., 2002, véase). Se ha encontrado evidencia de esta correlación negativa en diferentes variantes de los problemas de ruteo más complejos que el TSP. Pueden encontrarse ejemplos para VRPTW (Hollis y Green, 2012; Sahoo et al., 2005), CVRP (Rossit et al., 2016), *Mixed Capacitated Arc Routing Problem* (Constantino et al., 2015) y VRP con restricciones de tiempos de viaje (Tang y Miller-Hooks, 2006). Jang et al. (2006) aceptaron las modificaciones sugeridas por los administradores sobre las soluciones obtenidas con su algoritmo en un TSP periódico a pesar de que esto implicara un empeoramiento de los objetivos tradicionales. Esto facilitó la implementación del plan ya que los administradores estaban más dispuestos a realizar recorridos que le generaban confianza. Por otro lado, existen algunas excepciones en la literatura. Por ejemplo, en las pruebas realizadas por Bosch (2014), Lu y Dessouky (2006) (y Zhou et al., 2006) y Poot et al. (2002) la adición de restricciones de atracción visual derivó en una mejora de ambos aspectos: un aumento de la atracción visual y una reducción de costos.

En resumen, a pesar de ser el efecto más probable, no puede siempre asegurarse que la inclusión de la atracción visual disminuya la eficiencia del plan de ruteo en términos de los objetivos tradicionales. Sin embargo, los beneficios de un plan de ruteo agradable señalados al inicio de esta sección justifican el mejoramiento de la atracción visual aún cuando esto sea en desmedro de otros objetivos tradicionales (Constantino et al., 2015).

5.2. Revisión de la literatura

Como se mencionó previamente el concepto de atracción visual, introducido por Poot et al. (2002), es un concepto relativamente nuevo en la literatura de los problemas ruteo. Sin embargo, trabajos anteriores usaron conceptos similares, principalmente refiriéndose a la compacidad de las rutas. Además, diversos usos de este concepto también pueden encontrarse en problemas de delimitación de distritos o *districting problems*. Por esta razón, en la Sección 5.2.2 se incorpora una breve discusión de la compacidad en este tipo de problemas.

5.2.1. Atracción visual en problemas de ruteo

En Lu y Dessouky (2006) (y Zhou et al., 2006) se presenta una heurística de inserción para resolver un VRP con pickup y delivery de múltiples vehículos (*m*-PDPTW) que considera una penalización para evitar la generación de cruces en el cálculo del costo de inserción (en la Sección 6.4 se presentan detalles de como se computa esta penalización). Al comenzar la construcción de las rutas, es relativamente sencillo encontrar inserciones factibles y convenientes que no generen cruces ya que las rutas poseen pocos clientes asignados y hay muchos clientes disponibles para realizar la inserción. Sin embargo, cuando la construcción de rutas progresa y los vehículos tienen asignada una gran parte de su capacidad, la lógica del algoritmo debe centrarse más en la optimización del uso de la capacidad y la distancia total que en la atracción visual. Por lo tanto, a medida que aumenta el número de clientes asignados, el algoritmo permite inserciones crecientemente desagradables al reducirse la penalización a la generación de cruces. Se realizan pruebas sobre las instancias de Solomon (1987) en las que se lo compara con el algoritmo de inserción secuencial (SIA, por sus siglas en inglés *sequential insertion algorithm*), desarrollado también por Solomon (1987), y otra heurística de inserción en paralelo. El algoritmo de Lu y Dessouky (2006) (y Zhou et al., 2006) obtuvo mejores soluciones tanto en términos de objetivos tradicionales como de atracción visual. Lu y Dessouky (2006) también compararon su heurística con la metaheurística de Li y Lim (2001), obteniendo resultados peores en cuanto a número de vehículos utilizados y tiempos de viaje. No pudieron comparar la atracción visual de las soluciones debido a que Li y Lim (2001) no reportó la información necesaria sobre la conformación de las rutas.

Tang y Miller-Hooks (2006) presentaron una heurística iterativa que consiste en un algoritmo basado en la formación de clústeres para un problema VRP donde se encontraban acotados los máximos tiempos de viaje permisibles en las rutas. La heurística funciona de la siguiente manera. En una primera instancia, se seleccionan algunos clientes “semilla” y los demás clientes son asignados a la semilla más cercana resolviendo un problema de semi-asignación (SAP, por sus siglas en inglés *Semi-Assignment Problem*). El cronograma de las visitas y el tiempo de viaje dentro de cada ruta se calcula de forma aproximada a través de una resolución heurística de un problema TSP. Si alguno los tiempos de viaje excede el máximo permitido, vuelve a resolverse el problema SAP utilizando una nueva función de distancia que penaliza la asignación de clientes a los clientes

semilla que se saturaron en la resolución anterior y favorece la asignación de clientes a las semillas que no se saturaron. Esto incentiva la relocalización de clientes desde las rutas sobrecargadas a aquellas que poseen capacidad ociosa. Si luego de una cierta cantidad de iteraciones, el SAP no genera una solución factible, la asignación de clientes se realiza a través de otro modelo. Se utiliza un modelo de asignación multiobjetivo que intenta, por un lado, minimizar la cantidad de clientes que son asignados a otras rutas que la ruta más cercana y, por otro, minimizar la suma total de tiempos de viaje de todas las rutas, además de incorporar una restricción explícita para limitar el tiempo de viaje de cada ruta en particular. La heurística es comparada con la metaheurística desarrollada en Tang y Hu (2005) en instancias reales de la compañía de servicios de courier FedEx, observando la esperada relación de compromiso entre la atracción visual y los objetivos estándares.

Kim et al. (2006) desarrolló una heurística basada en la formación de clústeres para resolver un VRPTW que surge en la recolección de residuos con el objeto de mejorar la atracción visual de las rutas. La heurística consiste en dos etapas. Primero, se resuelve un problema de agrupamiento con restricciones de capacidad para estimar el número de clústeres y luego se utiliza un algoritmo de inserción para determinar el recorrido dentro de cada cluster. El agrupamiento comienza con la estimación de la cantidad de rutas necesarias, de acuerdo al total de la demanda, y con la selección de los clientes semilla. En el siguiente paso, los clientes son asignados a la semilla más cercana. Luego de esta primera asignación, el algoritmo calcula el centroide de los clústeres y luego el centroide de los centroides, que se denomina centroide principal. A continuación, se realiza una nueva asignación: se intenta insertar a los clientes en la semilla más cercana dándole prioridad a los clientes no asignados de mayor demanda. Durante este proceso, se corrobora la factibilidad del clúster tanto en términos de capacidad como de tiempo de viaje (lo cual se estima con un modelo de TSP). Estos pasos se repiten hasta que no se realiza ningún cambio en la composición de los clústeres en dos iteraciones sucesivas y puede pasarse a la segunda etapa del algoritmo. En esta etapa, se ordenan los clústeres de manera decreciente en relación al número de clientes que agrupan. Siguiendo este ordenamiento, se les aplica secuencialmente un algoritmo de inserción para determinar los recorridos dentro de cada clúster. Si al terminar de aplicar este algoritmo algunos clientes del clúster no pudieron ser asignados, los mismos son asignados al clúster más cercano al que aún no se le haya aplicado el algoritmo se reinsertan. Si al finalizar de aplicar el algoritmo de inserción a todos los clústeres permanecen clientes sin asignar, se aumenta el número de clústeres y se ejecuta nuevamente la primera etapa del algoritmo. Caso contrario, se aplica un operador de mejora de las rutas basados en la metodología de recocido simulado desarrollada por Taillard et al. (1997). Sahoo et al. (2005) también presenta una aplicación para diseñar las rutas de una empresa de recolección de residuos que incentiva la compactación de las mismas. El algoritmo utilizado tiene muchas similitudes con el de Kim et al. (2006) con la excepción de que utiliza un procedimiento un poco diferente en el proceso de agrupamiento de la primera etapa (en concreto, una variante del algoritmo *K-means* desarrollado por los mismos autores en Kim et al., 2004) que no utiliza el concepto de centroide principal. Con este algoritmo obtuvieron soluciones

más atractivas visualmente que las mejores soluciones conocidas al momento (BKS, por sus siglas en inglés *Best Known Solutions*) para las instancias de Solomon (1987). Por su parte, Kim et al. (2006) realizaron pruebas en instancias reales relacionadas a la recolección de residuos.

Otra compañía que han mostrado un marcado interés por las rutas visualmente atractivas son las de distribución de productos. Kant et al. (2008) presentó un algoritmo heurístico, implementado a través del software de ORTEC, que generó fuertes ahorros para la empresa COCA-COLA. La heurística se basa en un algoritmo de inserción para crear una solución inicial, que luego es mejorada con operadores de búsqueda local. Para asegurarse que la solución sea aceptada por los administradores en la etapa de búsqueda local no se permiten movimientos que conlleven un solapamiento de rutas y se incorpora una penalización para desincentivar la formación de rutas poco compactas. Esta penalización, denominada Penalización de Compacidad (PC), es proporcional a la suma de las distancias que posee el cliente en la posición intermedia de la ruta (según el orden de visita) a todos los demás clientes asignados a esa ruta. Los autores destacan que el parámetro PC debe adaptarse a las necesidades de los administradores. Las primeras veces que los administradores utilicen el software, pueden establecer un valor alto del parámetro PC para generar rutas similares a las diseñadas manualmente. A medida que los administradores y conductores se acostumbren a la nueva metodología de diseño, podrá irse disminuyendo el valor de PC para generar rutas más eficientes. A pesar de que este proceso, que fue también sugerido en Poot et al. (2002), no produce una reducción inmediata de los costos, permite suavizar la transición desde la etapa de diseño manual de las rutas hacia rutas más eficientes. Poot et al. (2002) trabajó también con clientes de ORTEC. Ellos adaptaron el algoritmo de los ahorros (véase Clarke y Wright, 1964) para favorecer la compacidad de las soluciones. En una etapa de preprocesamiento, se aplica el algoritmo de los ahorros a subconjuntos de clientes que son definidos considerando el tipo de vehículo que requieren para ser atendidos, la compatibilidad entre las ventanas de tiempo y su localización geográfica. Esta etapa tiene por objetivo reducir el tamaño del problema. Luego se aplica el algoritmo de los ahorros sobre todo el conjunto considerando un “factor de región” para promover la compacidad de la solución final. Los resultados se compararon con los obtenidos por un algoritmo de inserción, dando mejores resultados especialmente en términos de atracción visual. Otro estudio sobre la modificación del software de la compañía ORTEC fue realizado por Bosch (2014). Basado sobre el hecho de que los planificadores experimentados eran capaces de mejorar las soluciones operando manualmente sobre ella, el autor encontró que la inclusión de restricciones de atracción visual (basadas en el método de cobertura circular de Savelsbergh (1990)) provocó una reducción de los costos de transporte de la empresa de distribución neerlandesa Zeeman.

Otro ejemplo puede ser encontrado en Hollis y Green (2012), donde se desarrolla una compleja heurística con el objeto de generar soluciones visualmente atractivas para la empresa Schweppes Australia Pty. Ltd. El algoritmo está compuesto por una serie de operadores divididos en dos etapas principales. La primera incluye una novedosa variante del SIA de Solomon (1987) y la segunda es un proceso de búsqueda local basado en el algoritmo desarrollado por Kilby et al. (1999) (GLSA, por sus siglas en inglés *Guided*

Local Search Algorithm). Al igual que otros autores, Hollis y Green (2012) encuentran que diseñar un plan de distribución sólo con técnicas de inserción puede derivar en soluciones poco atractivas. Cuando una ruta, a través de la adición de clientes, tiende a tener un tiempo de viaje total cercano al máximo permitido, sólo podrán asignarse aquellos clientes que se encuentran entre el conjunto de clientes ya asignados y el depósito. Esto puede generar rutas estiradas y no compactas. Como remedio, los autores propusieron un criterio alternativo donde a medida que la ruta se acerca a su saturación sólo pueden ser incorporados los clientes que se encuentren crecientemente cerca de un cliente que ya se encuentra en la ruta. En la segunda parte del algoritmo, se aplica un proceso de búsqueda local. La función que evalúa la conveniencia de los cambios intenta minimizar los costos y disminuir el solapamiento. Los autores realizaron pruebas tanto en instancias reales de Schweppes Australia Pty. Ltd de la ciudad de Melbourne como en las instancias de Solomon (1987) obteniendo un número mayor de rutas y distancias totales que las BKS.

Gretton y Kilby (2013) presentaron una aplicación para aumentar la atracción visual de las soluciones obtenidas por el software Indigo, diseñado por Kilby y Verden (2011). El algoritmo se basa en una adaptación de la conocida heurística de *Large Neighborhood Search* (ALNS) desarrollada por Ropke y Pisinger (2006), que repetidamente extrae una gran cantidad de clientes de las rutas y los reinserta buscando alguna mejora en algún objetivo determinado. Gretton y Kilby (2013) consideraron un algoritmo de inserción con dos métricas de atracción visual: distancia de los clientes a la “media de la ruta”, esto es, el cliente que se encuentra más cercano al centro geométrico, y la suma de los ángulos de los cambios de dirección de la ruta. Esto último fue denominado como “energía de flexión” (*bending energy*) (véase la Sección 6.3). Presentaron un resumen de los resultados de la aplicación de la heurística propuesta tanto a dos conocidos conjuntos de instancias de la literatura (Gehring y Homberger, 1999; Solomon, 1987) como a algunas instancias reales.

En el contexto de los problemas de ruteo de arcos, Constantino et al. (2015) consideró el *Bounded overlapping MCARP* (BCARP), que es una variante del tradicional *Mixed Capacitated Arc Routing Problem* (MCARP). Para producir rutas separadas entre ellas limitaron la cantidad de nodos que pueden ser compartidos por más de una ruta. Pequeñas instancias de estos problemas fueron resueltas con CPLEX mientras que las instancias más grandes fueron resueltas heurísticamente. La heurística consiste en primero resolver un SAP para crear conjuntos de arcos que respetaran las restricciones de capacidad y luego resolver cada conjunto como un MCARP simplificado sin restricciones de capacidad. El algoritmo fue testeado en las instancias para MCARP de Belenguer et al. (2006). La inclusión de conceptos asociados a la atracción visual provocó soluciones más ineficientes en el sentido de los objetivos tradicionales.

Recientemente, Rossit et al. (2016) presentaron una heurística para optimizar la atracción visual y la distancia total en un CVRP. Se halla una solución inicial usando el algoritmo para formación de clústeres de Kim et al. (2006) y se la mejora con búsqueda local. El algoritmo fue testeado en las instancias de Uchoa et al. (2017) produciendo soluciones más agradables que las BKS pero con menor distancia.

5.2.2. Atracción visual en problemas de Delimitación de Distritos

Si bien la “atracción visual” como tal no se menciona en los trabajos que tratan sobre problemas que son netamente de delimitación de distritos, numerosos autores han considerado atributos visuales durante el proceso de optimización. Muyldermans et al. (2003) define el problema de delimitación de distritos como la partición de una área (o red) geográficamente extensa en sub-áreas (o sub-redes) más pequeñas por motivos organizacionales o administrativos. De acuerdo a estos autores, una buena solución a este problema debe contener unidades de demanda cercanas entre sí (y cercanas también al centro de servicio) dentro de cada distrito. En varias aplicaciones de este tipo es muy importante asegurar que los distritos sean compactos y no se solapen; por ejemplo, cuando la delimitación de distritos es aplicada para formar subconjuntos de clientes que luego conformarán rutas de distribución. En este tipo de aplicaciones, como sugieren Mourgaya y Vanderbeck (2007), puede haber una correlación positiva entre la compacidad de los distritos y la eficiencia del ruteo posterior. En particular, distritos geográficamente compactos y continuos, es decir, que es posible viajar entre dos puntos del distrito sin abandonar el mismo, se espera que requieran menores tiempos de viaje (Kalcsics, 2015). Por ejemplo, en el contexto del mantenimiento de rutas durante la temporada invernal, Muyldermans et al. (2003) establecieron que los distritos compactos que poseen el centro de servicios en una posición céntrica del mismo permitían una programación de rutas más eficiente. Los autores presentaron tres heurísticas para generar distritos compactos para diferentes rangos de capacidad de los vehículos utilizados. González-Ramírez et al. (2011) presentó una metaheurística multiobjetivo para generar distritos compactos y balanceados en cantidad de demanda para una compañía de servicios de courier. Mourão et al. (2009) consideraron medidas de dispersión mientras fraccionaban en conjuntos una red de arcos en un ARP. En Lei et al. (2012), los autores resolvieron heurísticamente un problema que involucraba conjuntamente un VRP y un problema de delimitación de distritos con clientes de demanda estocástica (VRDPSC, por sus siglas en inglés *Vehicle Routing and Districting Problem with Stochastic Customers*) teniendo en cuenta la compacidad de la solución. El algoritmo consistía en generar una solución inicial con una heurística constructiva y aplicar luego un algoritmo LNS para mejorarla. La función que guía este último algoritmo consideraba tres costos diferentes: uno proporcional a la compacidad de los distritos, otro proporcional a los tiempos de viaje dentro de cada distrito (estimados mediante la fórmula de Beardwood-Halton-Hammersley (1959) para aproximar la longitud del recorrido mínimo de un TSP) y el último costo proporcional a la cantidad de distritos. Wong y Beasley (1984) usaron inspección visual para medir el desempeño de un algoritmo de delimitación de distritos reconociendo que los distritos compactos eran una característica de una “buena solución”.

Los problemas de delimitación de distritos como etapa previa al diseño de un plan de rutas no son los únicos casos donde la compacidad ha demostrado ser importante. La política y la división administrativa ha sido una motivación tradicional para generar distritos compactos que eviten ventajas injustas para cierto partido o grupo político, lo que en la bibliografía especializada se conoce a esta práctica como *gerrymandering* (véase, por ejemplo, Bozkaya et al., 2003; Mehrotra et al., 1998; Niemi et al., 1990; Ricca

y Simeone, 2008; Young, 1988).. También encontramos casos en compañías comerciales, conocido como *commercial districting* (véase, por ejemplo, López-Pérez y Ríos-Mercado, 2013; Ríos-Mercado y López-Pérez, 2013; Ríos-Mercado y Escalante, 2016). Finalmente, también pueden encontrarse aplicaciones en manejo de redes energéticas (véase, por ejemplo, Bergey et al., 2003; De Assis et al., 2014; Yanik et al., 2016).

5.2.3. Características de los algoritmos utilizados

Los algoritmos exactos son escasos en el marco de los problemas de ruteo o de delimitación de distritos que tengan en cuenta aspectos de atracción visual. Una notable excepción son Battarra et al. (2014) que desarrollaron dos algoritmos de ramificación y corte, específicamente uno de *branch-and-cut* y otro de *branch-and-cut-and-price*, para generar soluciones para grandes instancias del problema conocido como *clustered VRP* en tiempos de cómputo razonables. En una situación intermedia, Jarrah y Bard (2012) y Mourgaya y Vanderbeck (2007) usaron combinaciones del método de generación de columnas y técnicas heurísticas. La mayoría de los trabajos utilizan enfoques heurísticos, lo cual no es sorprendente si se tiene en cuenta la desafiante combinación de la naturaleza NP-hard de los problemas de ruteo (Lenstra y Kan, 1981) y la subjetiva definición de la atracción visual que involucra diversos criterios (compacidad, elusión de cruces, solapamiento, etc.). Una lista de los algoritmos utilizados en las principales referencias puede verse en la Tabla 6.2 descripta en el siguiente Capítulo.

Otra característica deseable de los procesos de optimización que involucran a la atracción visual es la interacción con los administradores dado que, al ser un concepto eminentemente subjetivo, la opinión de los expertos es muy valiosa. Es por esto que algunos autores incorporaron con éxito estas opiniones en sus algoritmos (Matis, 2008; Tang y Miller-Hooks, 2006). Por la misma razón, es deseable utilizar técnicas de visualización gráfica de la información y de la solución obtenida. Con este objetivo, algunos autores incorporaron Sistemas de Información Geográficos (SIG) en su procesos de optimización (Matis, 2008; Sahoo et al., 2005).

5.2.4. Discusión

El primer objetivo de este capítulo fue organizar la literatura disponible a modo de proveer un punto de referencia para futuros desarrollos de la atracción visual en los problemas de ruteo. A pesar de que en los problemas de delimitación de distritos el objetivo de la compacidad ha sido integrado eficientemente en diversos algoritmos de la literatura, en los problemas de ruteo la literatura es más escasa y está traccionada principalmente por los requerimientos de los clientes. De todas formas, la bibliografía analizada resalta los beneficios prácticos de considerar la atracción visual en los procesos de optimización de los problemas de ruteo. Las planificaciones que son consideradas “planes de laboratorio”, esto es, planes excesivamente diferentes a aquellos generados por los administradores, son usualmente rechazadas. Esto puede reducir el grado de colaboración y, por lo tanto, aumentar el tiempo y esfuerzo necesario para implementarlos, obstaculizando el funcionamiento de una organización. Además, existen otros beneficios prácticos de los planes

visualmente atractivos, como ,por ejemplo, el hecho de que favorecen la especialización del conductor.

Capítulo 6

Análisis de las métricas para medir la atracción visual

Del capítulo anterior se desprende que elaborar una definición rigurosa e inequívoca del concepto de atracción visual es una tarea difícil. Teniendo esto en cuenta, puede pensarse que generar un único indicador mensurable que considere los distintos aspectos subjetivos de este concepto es aún más complejo. Esta es la principal razón por la cual la mayoría de los autores utilizaron una serie de indicadores para captar la atracción visual de una solución (Constantino et al., 2015; Gretton y Kilby, 2013; Hollis y Green, 2012; Matis, 2008; Poot et al., 2002; Rossit et al., 2016; Tang y Miller-Hooks, 2006). frente a aquellos que utilizaron un único parámetro como Lu y Dessouky (2006) (y Zhou et al., 2006). En este capítulo, se describen las diferentes métricas propuestas en la literatura utilizadas para medir la atracción visual. Las mismas se encuentran resumidas en la Table 6.2.

6.1. Compacidad en rutas

Como fue mencionado en la Sección 5.2, la compacidad es una de las métricas más utilizadas para representar la atracción visual. Como el concepto más amplio de atracción visual, es difícil elaborar una definición precisa de la compacidad a pesar de parecer un concepto intuitivo (Kalcics, 2015; MacEachren, 1985). Constantino et al. (2015) clasificó la literatura de acuerdo a tres formas distintas de medir la compacidad:

- en base a la similitud existente entre la entidad sobre la cual se requiere medir la compacidad y alguna forma geométrica estándar, como, por ejemplo, en Jarrah y Bard (2012);
- en base a la compacidad geométrica, geográfica o visual, como, por ejemplo, en Lei et al. (2012) y Perrier et al. (2008);
- o en base a la proximidad entre clientes, como, por ejemplo, en Muyldermans et

al. (2003), Poot et al. (2002), Salazar-Aguilar et al. (2012) y Tang y Miller-Hooks (2006).

Los mismos autores propusieron otra clasificación para los elementos que se utilizaron en las diferentes métricas de compacidad de la literatura. Pueden encontrarse métricas basadas en:

- el máximo tiempo de viaje, como, por ejemplo, en Mourão et al. (2009) y González-Ramírez et al. (2011));
- la máxima distancia euclidiana, como, por ejemplo, en Kim et al. (2006), Mourgaya y Vanderbeck (2007) y Salazar-Aguilar et al. (2012);
- o la distancia promedio entre los clientes y un punto de referencia como, por ejemplo, en Hollis y Green (2012), Kant et al. (2008), Poot et al. (2002) y Tang y Miller-Hooks (2006).

Diversos autores han utilizado métricas de compacidad en los problemas de delimitación de distritos que involucraban aplicaciones relacionadas con la logística del transporte. En ellas, en general, la delimitación de distritos es un procesamiento previo para dividir el conjunto de clientes en subconjuntos sobre los cuales luego se resolverá un problema de ruteo. En este tipo de problemas, la forma geométrica de los distritos debe ser lo más compacta posible ya que las formas alargadas y tortuosas tienden a afectar la eficiencia en el diseño de las rutas (De Assis et al., 2014). Mourão et al. (2009) consideró dos métricas de compacidad: el promedio y el desvío estándar de las distancias entre los clientes del distrito y el cliente considerado “semilla” del mismo, esto es, como origen del distrito. Lei et al. (2012) utilizaron la fórmula de compacidad desarrollada por Bozkaya et al. (2003) que está basada en la diferencia entre el perímetro de un distrito y el perímetro total de la región de estudio. Lin y Kao (2008) y Larsen (2015) utilizaron métricas similares. Jarrah y Bard (2012) mantuvieron la compacidad de la solución durante la ejecución de su algoritmo de inserción obligando a que los nuevos clientes que se insertaban en un distrito ya creado estuvieran dentro de radio máximo de distancia del distrito en formación. Butsch et al. (2014) utilizó dos métricas distancias en la delimitación de distritos de un problema ARC: la compacidad local (dentro de un mismo distrito), que es proporcional a la suma de las distancias desde cada nodo a la mediana del distrito, y la compacidad global, que es proporcional a la sumatoria de áreas solapadas entre los rectángulos de área mínima que encierran a los distritos.

En el contexto de problemas exclusivamente de ruteo de vehículos, Matis y Koháni (2011) y Matis (2010) evaluaron la compacidad a través de la relación entre la superficies del polígono no-convexo de menor área capaz de incluir a todos los nodos asignados a un distrito y del círculo que posee el mismo perímetro que dicho polígono. Sin embargo, en otro trabajo Matis (2008) midió la compacidad como la relación entre la distancia promedio entre cualesquiera dos clientes consecutivos en la ruta y la distancia que se obtiene de promediar el 20 % los tramos más largos de la ruta. Kim et al. (2006), Hollis y Green

(2012) y Tang y Miller-Hooks (2006) midieron la compacidad de las rutas calculando la sumatoria de las distancias entre los clientes de la ruta y el centro de la misma. Rossit et al. (2016) utilizó el promedio de esos valores. Kant et al. (2008) consideró la distancia promedio entre los clientes de una ruta y el cliente ubicado en la posición media del recorrido (según el orden de visitas). Poot et al. (2002) adoptaron como métrica para la compacidad la distancia promedio entre cualesquiera par de clientes asignados a una misma ruta, esto es, tanto si fueran consecutivos en el recorrido como si no lo son. Constantino et al. (2015) usó el promedio de los tiempos mínimos de viaje entre dos unidades de demanda dentro de un mismo área de servicio.

El concepto de compacidad de las rutas puede asociarse a la “proximidad entre rutas”, es decir, la idea de que los clientes deben asignarse a la ruta más cercana: si los clientes son siempre asignados a la “la ruta más cercana”, sin importar por el momento cuan arbitrario parezca este concepto, la compacidad será máxima. Matis (2008), Hollis y Green (2012), Rossit et al. (2016) y Tang y Miller-Hooks (2006) utilizan para medir la atracción visual el número de clientes asignados a una ruta diferente a la ruta que tienen más cerca. Generalmente la localización de una ruta está definida por la ubicación del “centro de una ruta”. Distintos autores han arribado a diversas definiciones de los que se conoce como “centro de una ruta”. Intuitivamente, algunos han establecido como centro de ruta el centro de gravedad o baricentro que surge de promediar las coordenadas geográficas de los clientes asignados, sin importar si en esa ubicación hubiese o no un cliente (Hollis y Green, 2012; Matis, 2008; Poot et al., 2002). Por otro lado, otros autores identificaron a un cliente determinado con centro de la ruta. Entre ellos puede nombrarse: a Kant et al. (2008), que seleccionaron al cliente localizado en la posición intermedia del orden de visitas del recorrido; a Kim et al. (2006) y Rossit et al. (2016), que eligieron el cliente que tiene la mínima distancia al centro de gravedad de la ruta; y a Gretton y Kilby (2013) y Tang y Miller-Hooks (2006) que seleccionaron al cliente que minimiza la distancia total a todos los demás clientes de la ruta. En la Tabla 6.1 se resumen las distintas definiciones de los centro de ruta con orden del algoritmo necesario para hallarlo suponiendo el peor caso posible.

Tabla 6.1: Diferentes definiciones del centro de una ruta utilizadas en la literatura.

Id.	Descripción	Orden del algoritmo(*)	Referencias
c_I^1	Centro de gravedad calculado desde las coordenadas de los clientes asignados a la ruta I .	$O(n)$	Hollis y Green (2012); Matis (2008); Poot et al. (2002)
c_I^2	Cliente localizado en la posición intermedia de la ruta I .	$O(1)$	Kant et al. (2008)
c_I^3	Cliente con la mínima distancia al centro de gravedad de la ruta I .	$O(n)$	Kim et al. (2004, 2006); Rossit et al. (2016)
c_I^4	Cliente que minimiza la sumatoria de distancias desde todos los demás clientes de la ruta I .	$O(n^2)$	Gretton y Kilby (2013); Tang y Miller-Hooks (2006)

(*)donde n es el número de clientes.

Utilizar el centro de gravedad como centro de ruta puede acarrear ciertas compleji-

dades. Por ejemplo, cuando la ruta cambia, es muy probable que el centro de gravedad se desplace y calcular su nueva ubicación requiere un esfuerzo adicional ya que todas las distancias (desde los otros clientes al nuevo centro de ruta deben computarse, a diferencia de si usáramos como centro a un cliente determinado ya que, en general, las distancias entre clientes son un dato de entrada del problema. Esta dificultad puede empeorar si además no se trabaja con distancias euclidianas y se utilizan, por ejemplo, distancias urbanas que consideren los sentidos de circulación de las calles. Una forma de paliar este efecto es suponer que el centro de gravedad se mantiene constante durante un cierto número de iteraciones asumiendo el supuesto que la conformación ruta no cambia radicalmente. Sin embargo, Gretton y Kilby (2013) demostraron que para su algoritmo el cálculo constante de los centros de ruta, es decir, en cada modificación de la ruta, permitía mejorar significativamente la atracción visual de la solución frente a la estrategia de cálculos discontinuados, a la vez que sólo tuvo un impacto limitado en el uso de memoria y el tiempo de cómputo.

6.2. Solapamiento de rutas y cruces

El casco convexo de una ruta es el polígono convexo de menor área que contiene a todos los clientes. Frecuentemente, la presencia de clientes que están incluidos en más de un casco convexo es la característica más antiestética de una solución (Poot et al., 2002). En la Figura 6.1 pueden verse los cascos convexos de dos soluciones diferentes para una misma instancia de VRPTW: una con donde el área de intersección entre los cascos es extensa y otra donde esta es más reducida. En general, el depósito (origen de los vehículos) es ignorado para construir los cascos convexos. Algunos autores consideran como una métrica de atracción visual la cantidad de clientes que pertenecen a más de un casco convexo (Hollis y Green, 2012; Kim et al., 2006; Poot et al., 2002; Rossit et al., 2016).

Kim et al. (2006) y Rossit et al. (2016) utilizaron el algoritmo de Graham (1972) para determinar el casco convexo de las rutas, mientras que Hollis y Green (2012) utilizaron la librería Boost C++ (Gehrels et al., 2017). Ambos algoritmos tienen la misma complejidad temporal $O(n \log n)$. En el contexto del problema de ruteo de arcos, como ya fue mencionado en la Sección 5.2, Constantino et al. (2015) propone el “Route Overlapping Index” que compara el número de nodos compartidos entre diversas rutas de la solución.

Naturalmente los cruces entre arcos que pertenecen a distintas rutas (en adelante llamados como “cruces entre rutas”) ocurren si y sólo si hay intersección de los cascos convexos (Hollis y Green, 2012). Los cruces entre caminos son un aspecto crucial de la atracción visual ya que las rutas sin cruces son consideradas como más eficientes (Van Rooij et al., 2003).

Poot et al. (2002) consideró ambos tipos de cruces, los cruces entre rutas y los cruces entre caminos pertenecientes a una misma ruta (en adelante llamados como “cruces intraruta”). Por otro lado, Matis (2008) y Rossit et al. (2016) consideraron sólo los cruces entre rutas.

De acuerdo a Tang y Miller-Hooks (2006), es más difícil incorporar la verificación de

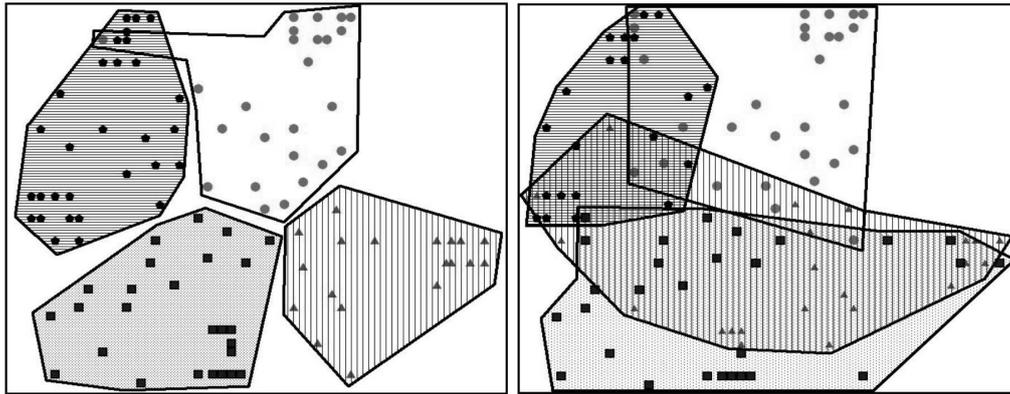


Figura 6.1: Cascos convexos de las rutas de la instancia RC205 de Solomon (1987) con dos enfoques de resolución distintos. El de la izquierda considera la maximización de la atracción visual mientras que el de la derecha la minimización de costos. Fuente: Sahoo et al. (2005).

la existencia de cruces en un algoritmos que otros aspectos de atracción visual. Además, verificar cruzamientos en tiempo real durante la ejecución del algoritmo es computacionalmente costoso debido a la cantidad de arcos que deben chequearse. Una alternativa computacionalmente más económica aplicamos en nuestro trabajo Rossit et al. (2016) donde sólo se verifican aquellos pares de arcos cuyos puntos intermedios se encuentren separados por una distancia menor a cierta distancia umbral. Finalmente, los cruces que ocurren en los caminos iniciales y finales de las rutas (desde y hacia el depósito) no son considerados (Matis, 2008; Poot et al., 2002; Rossit et al., 2016) ya que en las zonas cercanas al depósito, en general, ocurren una gran cantidad de cruzamientos inevitables debido a la alta densidad de arcos.

6.3. Complejidad de las rutas

En esta sección se incluyen las características asociadas a cada ruta individualmente y no a los costos de ruteo generalizados del plan. Entre estos aspectos, Gretton y Kilby (2013) propusieron la medición de la atracción visual a través de la reducción de la energía de flexión (“*bending energy*”), un concepto tomado del campo de la visión computacional (Young et al., 1974). Estos autores definieron a la energía de flexión como la suma de los ángulos de giro a lo largo del recorrido. Por lo tanto, los planes con baja energía de flexión no tienen transiciones abruptas entre clientes. Relacionado a esto puede mencionarse el caso presentado en Bertero (2015), donde la ruta diseñada por el autor para la recolección de residuos de la ciudad de Concordia, Argentina, debió ser modificada debido a las reticencias que presentó la municipalidad para aceptar un plan con una gran cantidad de giros. Además, se ha encontrado evidencia que las soluciones humanas a problemas TSP tienen una relativa baja cantidad de conexiones entre los

puntos ubicados cerca del casco convexo del conjunto y los puntos interiores al mismo (MacGregor, 2012). Como puede visualizarse en la Figura 6.2, las soluciones con un gran número de estas conexiones punto límite- punto interior poseen numerosas transiciones abruptas a lo largo del camino y, por lo tanto, una alta energía de flexión.

Los cruzamientos intra-ruta también afectan la atracción visual. Poot et al. (2002) consideró esta métrica con el objeto de comparar las soluciones obtenidas mediante dos algoritmos distintos. Lu y Dessouky (2006) (y Zhou et al., 2006) sólo consideraron los cruces intra-ruta para medir la atracción visual. Es más, utilizaron una fórmula que denominaron “porcentaje de longitud de cruzamiento” (CLP por sus siglas en inglés *crossing length percentage*) que expresaba cuando intrincados eran estos cruces en la estructura de la ruta. De hecho, consideraron que el número de cruzamientos no era suficiente para medir la tracción visual de las rutas ya que también interesa cuan profundos son esos cruces y si se enmarañan entre ellos. Como el CLP, y su relación con cuan intrincados son los cruces, no es un concepto simple se presenta un ejemplo ilustrativo desallorado por los mismos autores (Lu y Dessouky, 2006) en la Sección 6.4.

Finalmente, Constantino et al. (2015) propuso un “Índice de Conectividad” como indicador proporcional al número de zonas conexas para medir la atracción visual. Una zona es considerada conexas si es posible trasladarse entre cualesquiera dos puntos de la zona sin abandonarla.

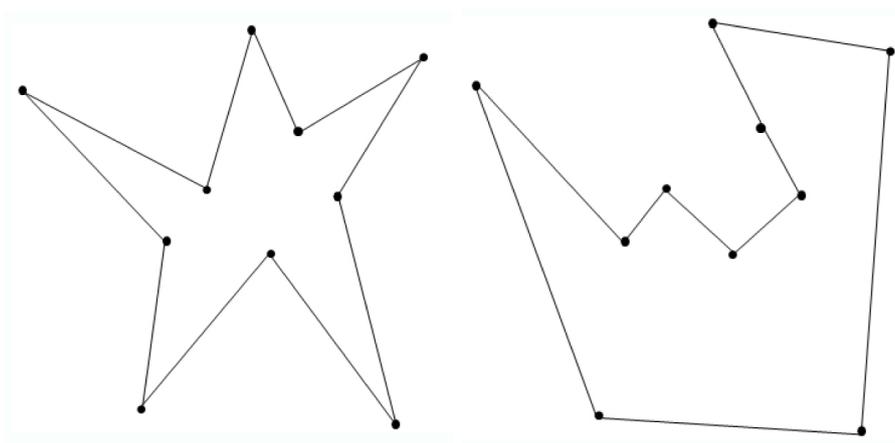


Figura 6.2: Diferentes soluciones a un problema de TSP (panel izquierdo: soluciones con numerosas transiciones abruptas; panel derecho: solución con menor cantidad de transiciones abruptas). Fuente: MacGregor (2012).

Tabla 6.2: Bibliografía principal sobre atracción visual en problemas VRP

Autores/Fuente	Tipo de problema	Aplicación en casos reales	Enfoque de resolución	Métrica		
				Compacidad	Solapamiento	Complejidad de la ruta
Bosch (2014)	VRPTW	Y	Clu/LS	Y	-	Y
Constantino et al. (2015)	BCARP	-	LS/IA/Clu	Y	Y	Y
Gretton y Kilby (2013)	VRPTW	Y	LNS	Y	-	Y
Hasle et al. (2010, 2011)	NEARP	Y	Clu/LS	Y	Y	-
Hollis y Green (2012)	VRPTW	Y	LS/IA/Clu	Y	Y	-
Kant et al. (2008)	SRP	Y	IA/LS/Clu	Y	-	-
Kim et al. (2006)	MDVRPTW	Y	Clu/IA/LS	Y	Y	-
Lu y Dessouky (2006); Zhou et al. (2006)	PDPTW	-	IA/Mh	-	-	Y
Matis (2008)	SRP	-	SA/Mh/OH	Y	Y	-
Matis y Koháni (2011)	SRP	Y	Clu/TS	Y	-	-
Mourgaya y Vanderbeck (2007)	PVRP	-	CG/OH	Y	-	-
Sahoo et al. (2005)	VRPTW	Y	Clu/IA/LS	Y	-	-
Tang y Miller-Hooks (2006)	VRPTL	Y	Clu	Y	Y	-
Poot et al. (2002)	VRPTW	Y	SA	Y	Y	Y
Rossit et al. (2016)	CVRP	-	Clu/LS	Y	Y	Y

Tipo de problema: VRPTW: VRP with Time Windows; BCARP: Bounded Capacitated Arc Routing Problem; NEARP: Node-Edge Arc Routing Problem; SRP: Street Routing Problem; MDVRPTW: multi-depot VRPTW; PDPTW: Pick and Delivery with Time Windows; PVRP: Periodic VRP; VRPTL: VRP with time limit; CVRP: Capacitated VRP

Enfoque de resolución: SA : algoritmo de los ahorros; CG: generación de columnas; Clu: algoritmo basado en la formación de clusters; IA: algoritmo de inserción; Mth: metaheurística; OH: otro tipo de heurística; LNS: Large Neighbourhood Search; LS: Búsqueda Local; TS: búsqueda tabú

6.4. Métricas de atracción visual: descripción y experimentación

Con el objetivo de aplicar las distintas métricas que se describen en este capítulo y comparar su comportamiento se utilizarán dos conjuntos de instancias correspondientes a dos variantes típicas del problema de ruteo: CVRP y VRPTW. A los efectos de brindar una definición precisa nos referimos al libro de Toth y Vigo (2014), ampliamente reconocido en el ámbito de la investigación operativa (su primera edición se realizó en el año 2002). En el mismo (Irnich et al., 2014) se define al CVRP, *Capacitated Vehicle Routing Problem*, como el problema de ruteo que consiste en la distribución de productos desde un depósito único a un conjunto de clientes que poseen una demanda individual dada a través de una flota homogénea de vehículos con una capacidad determinada. Los vehículos deben comenzar y finalizar sus recorridos en el depósito. En otro capítulo de la misma obra (Desaulniers et al., 2014), se define al VRPTW, *Vehicle Routing Problem with Time Windows*, como una extensión del CVRP donde el cliente debe ser visitado dentro de un intervalo de tiempo, llamado ventana de tiempo. La variante CVRP se eligió teniendo en cuenta que es una de las primeras variantes que ha surgido del VRP (Frahi et al., 2017) y, por lo tanto, uno de las más estudiadas (Irnich et al., 2014). Se utilizará para la aplicación de las métricas el conjunto de instancias de instancias de CVRP de gran escala desarrollado por Uchoa et al. (2017) (publicada previamente en el 2014). Por otro lado, la selección de la variante de VRPTW se fundamenta por el hecho que representa un buen ejemplo de un problema restringido donde las restricciones tienen un fuerte impacto en la compacidad de la solución. Se utilizará el conjunto de instancias de VRPTW propuesto por Gehring y Homberger (1999) (en adelante denominado instancias de GH99). Tanto el CVRP como el VRPTW son considerados problemas NP-hard (Lenstra y Kan, 1981).

6.4.1. Descripción de métricas

A continuación se describen las fórmulas de cálculo de las métricas de atracción visual que se utilizarán (Ecuaciones 6.1-6.11). Para la presentación de las fórmulas utilizadas, y sin pérdida de generalidad, se supone que existe una ruta I perteneciente a un conjunto de rutas K y una función $dist(x, y)$ que devuelve la distancia (euclidiana) entre dos puntos x e y . La definición de los centros de ruta se encuentra dada en la Tabla 6.1. Una comparación del esfuerzo computacional requerido para calcular cada métrica desde el inicio, esto es, sin la información previa que puede poseerse en una etapa intermedia de resolución, se informan en la Tabla 6.3.

6.4.1.1. Compacidad

Se implementarán nueve métricas de compacidad de diversos autores. Las primeras seis, identificadas como $COMP_I^a - COMP_I^f$ utilizan información espacial y geográfica de la compacidad de la solución. El detalle de las métricas es:

Tabla 6.3: Análisis de tiempos del peor caso de las métricas de atracción visual.

Métrica	Complejidad temporal	Métrica	Complejidad temporal
$COMP^a$	$O(n)$	$PROX^b$	$O(n^2)$
$COMP^b$	$O(n)$	$PROX^c$	$O(n^2)$
$COMP^c$	$O(n)$	CH	$O(n^2)$
$COMP^d$	$O(n)$	$Inter - C$	$O(n \log n)$
$COMP^e$	$O(n \log n)$	$Intra - C$	$O(n \log n)$
$COMP^f$	$O(n^2)$	CLP	$O(n^2 \log n)$
$PROX^a$	$O(n^2)$	BE	$O(n)$

(*) donde n es el número de clientes asignados a una ruta.

- Métrica de compacidad desarrollada por Matis (2008):

$$COMP_I^a = \frac{AvgDist_I}{AvgMaxDist_I} \quad (6.1)$$

donde $AvgDist_I$ es la distancia promedio entre dos clientes consecutivos en una ruta I y $AvgMaxDist_I$ es la distancia promedio del 20 % de las mayores distancias entre dos clientes consecutivos de la ruta I . A mayor valor de este indicador más compacta es la solución.

- Métrica de compacidad desarrollada por Kim et al. (2004):

$$COMP_I^b = \sum_{i \in I} dist(i, c_I^3) \quad (6.2)$$

donde c_I^3 es el centro de la ruta I definido por Kim et al. (2004) (véase Tabla 6.1). A menor valor de este indicador más compacta es la ruta.

- Métrica de compacidad desarrollada por Kant et al. (2008):

$$COMP_I^c = \sum_{i \in I} dist(i, c_I^2) \quad (6.3)$$

donde c_I^2 es el centro de la ruta I definido por Kant et al. (2008) (véase Tabla 6.1). A menor valor de este indicador más compacta es la ruta.

- Métrica de compacidad desarrollada por Poot et al. (2002):

$$COMP_I^d = \frac{\sum_{i \in I} dist(i, c_I^1)}{|I|} \quad (6.4)$$

donde c_I^1 es el centro de la ruta I definido por Poot et al. (2002) (véase Tabla 6.1). A menor valor de este indicador más compacta es la ruta.

- Métrica de compacidad desarrollada por Poot et al. (2002):

$$COMP_I^e = \frac{\sum_{i \in I} \sum_{\substack{h \in I \\ h \neq i}} dist(i, h)}{|I|} \quad (6.5)$$

A menor valor de este indicador más compacta es la ruta.

- Métrica de compacidad desarrollada por Tang y Miller-Hooks (2006):

$$COMP_I^f = \frac{\sum_{i \in I} dist(i, c_I^4)}{|I|} \quad (6.6)$$

donde c_I^4 es el centro de la ruta I definido por Tang y Miller-Hooks (2006) (véase Tabla 6.1). A menor valor de este indicador más compacta es la ruta.

También se implementan tres métricas de proximidad entre rutas, identificadas como $PROX_I^a$, $PROX_I^b$, y $PROX^c$ cuyo detalle es:

- Métrica de proximidad desarrollada por Matis (2008):

$$PROX_I^a = 2 \cdot \left(1 - \frac{O'_I}{|I|} \right) - 1 \quad (6.7)$$

donde O'_I es el número de clientes en la ruta I que se encuentran más cerca del centro de otra ruta $J \in K$, $J \neq I$. El centro de ruta considerado es c_I^1 (véase Tabla 6.1). A mayor valor de este indicador mejor es la solución.

- Métrica de proximidad desarrollada por Rossit et al. (2016):

$$PROX_I^b = \frac{O'_I}{|I|} \quad (6.8)$$

donde O'_I es el número de clientes en la ruta I que se encuentran más cerca del centro de otra ruta $J \in K$, $J \neq I$. El centro de ruta considerado es c_I^3 (véase Tabla 6.1). A menor valor de este indicador mejor es la solución.

- Métrica de proximidad desarrollada por Tang y Miller-Hooks (2006):

$$PROX^c = \sum_{I \in K} O'_I \quad (6.9)$$

donde O'_I es el número de clientes en la ruta I que se encuentran más cerca del centro de otra ruta $J \in K$, $J \neq I$. El centro de ruta considerado es c_I^4 (véase Tabla 6.1). A menor valor de este indicador mejor es la solución.

6.4.1.2. Solapamientos de rutas y cruces entre rutas

En esta categoría se implementan dos métricas diferentes.

- Número de clientes que pertenecen a más de un único casco convexo (CH) como en Kim et al. (2006), Rossit et al. (2016) y Poot et al. (2002). Para determinar el casco convexo se utiliza el algoritmo de Graham (1972).
- Número de cruces entre rutas ($Inter - C$): número total de cruces que ocurren entre dos arcos que pertenecen a dos rutas distintas. No se consideran los cruces que involucran caminos iniciales y finales de las rutas (desde y hacia el depósito).

6.4.1.3. Complejidad de la ruta

En esta última categoría se consideran tres métricas.

- Número de cruces intra-ruta (*Intra - C*): número total de cruces que ocurren entre arcos que pertenecen a la misma ruta. Como en el caso de *Inter - C*, no se consideran cruces que involucran caminos iniciales y finales de las rutas (desde y hacia el depósito).
- Porcentaje de longitud de cruces (CLP_I), desarrollado por Lu y Dessouky (2006) (y Zhou et al., 2006):

$$CLP_I = \frac{\sum_{k \in P_I} \min(\beta_k, \lambda_I - \beta_k)}{|I|} \quad (6.10)$$

donde P_I es el conjunto de puntos de intersección de los cruces intra-ruta de la ruta I , β_k es igual a la longitud de la porción de ruta que comienza y finaliza en el punto de intersección $k \in P_I$ y λ_I es la longitud de la ruta I . A menor valor de este indicador mejor es la solución. Para explicar mejor esta métrica se presenta un ejemplo en la Figura 6.3. La ruta de la Figura 6.3(a) contiene solo un cruce. El valor CLP de esta ruta es $\min\{4 + 4 + 2, 1 + 1 + 1\}/13 = 0,23$. La ruta de la Figura 6.3(b) contiene múltiples cruces. La longitud de los cruces de los tres puntos de intersección B, C and E es igual a $\overline{BC} + \overline{CD} + \overline{DE} + \overline{EF} + \overline{FB}$, $\overline{CD} + \overline{DE} + \overline{EF} + \overline{FB} + \overline{BG} + \overline{GC}$ and $\overline{EF} + \overline{FB} + \overline{BG} + \overline{GC} + \overline{CE}$ respectivamente. Por lo tanto, el CLP puede calcularse como $CLP = (\overline{BC} + 2 * \overline{CD} + 2 * \overline{DE} + 3 * \overline{EF} + 3 * \overline{FB} + 2 * \overline{BG} + 2 * \overline{GC} + \overline{CE})/13 = 0,56$. Este ejemplo muestra que de todos los segmentos, \overline{EF} y \overline{FB} fueron contabilizados la mayor cantidad de veces. Por consiguiente, estos segmentos representan la parte más intrincada de la ruta y, por lo tanto, son los que deberían ser reasignados para volver a la ruta más visualmente atractiva (Lu y Dessouky, 2006)).

- Métrica de energía de flexión (*BE*) propuesta por Gretton y Kilby (2013):

$$BE_I = \frac{\sum_{i=2}^{|I|} (\alpha_{i-2, i-1, i})}{|I|} \quad (6.11)$$

donde $\alpha_{i-2, i-1, i}$ es el menor ángulo, en radianes, entre los vectores formados por los clientes $i - 2$ e $i - 1$, por un lado, y los clientes $i - 1$ e i , por el otro. A menor valor de este indicador mejor es la solución.

6.4.2. Evaluación experimental

Las catorce métricas descritas en la sección anterior fueron implementadas en C++. A los efectos de proveer de una base de comparación común entre las distintas fórmulas, cuando una métrica está definida para una ruta individual del plan, y no para el conjunto

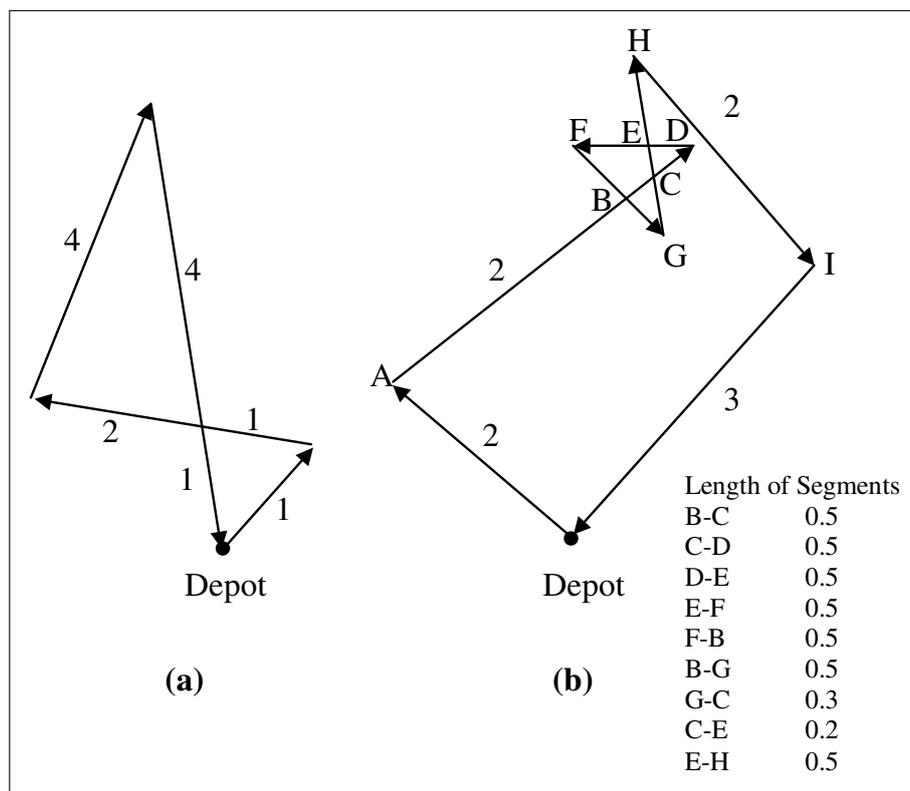


Figura 6.3: Datos para el cálculo del porcentaje de longitud de cruce (CLP). Fuente: Lu y Dessouky (2006).

del plan, se utiliza para comparación el promedio de todas las rutas individuales. Esto es, si la métrica $M()$ se aplica individualmente a cada ruta $I \in K$, entonces se toma para comparar el promedio $\frac{\sum_{I \in K} M(I)}{|K|}$. Esto sucede para casi todas las métricas propuestas en la Sección 6.4.1, a excepción de las de $PROX^c$ e $Inter - C$ que son métricas globales. Además, con el mismo objetivo de facilitar la base de comparación entre métricas, el valor de la aplicación de una métrica x en cada instancia t perteneciente al conjunto de instancias T , se reporta como la desviación porcentual relativa con respecto al mejor valor obtenido dentro del conjunto T , que se denomina $rel(x, t)$. Esto puede expresarse matemáticamente como:

$$rel(x, t) = \frac{|Value(x, t) - Best_T(x)|}{|Worst_T(x) - Best_T(x)|}, T = C, R, RC \text{ or } X \quad (6.12)$$

donde $Best_T(x)$ y $Worst_T(x)$ son, respectivamente, los mejores y peores valores obtenidos por la métrica de atracción visual x en el conjunto de instancias T . En la mayoría de los casos el mejor resultado es el menor valor, excepto para $COMP^a$ y $PROX^a$ donde es el mayor valor (véase Sección 6.4.1.1). Debe notarse que un mayor valor de $rel(x, t)$

se corresponde con una peor solución en términos de atracción visual. El conjunto de instancias X se refiere a las instancias de CVRP de Uchoa et al.. Los conjuntos de instancias C, R y RC se corresponden a tres grupos de las instancias GH99 que se explican a continuación.

Se computan las métricas de atracción visual para un subconjunto de las instancias GH99 para las cuales las BKS están disponibles constituyendo a los efectos estadísticos una población. Esto implica, además de conocer la distancia total de la solución, tener información sobre la estructura de las rutas, esto es, el orden de visita de los clientes. La información sobre las instancias de GH99 fue tomada de la plataforma colaborativa *Vehicle Routing Problem Repository* ([dataset] Gehring y Homberger, 1999) (VRP-REP) mientras que la información sobre las BKS se extrajo de *Transportation Optimization Portal of the Norwegian Foundation for Scientific and Industrial Research* (Transportation Optimization Portal of the Norwegian Foundation for Scientific and Industrial Research (SINTEF, *Stiftelsen for industriell og teknisk forskning*), 2017). Siguiendo la clasificación propuesta por Solomon (1987), el benchmark GH99 utiliza tres clases para dividir las instancias. En la Clase C los clientes se encuentran fuertemente aglutinados formando clusteres, mientras que en la Clase R los clientes se encuentran fuertemente dispersos. La Clase RC es una situación intermedia entre estos dos casos extremos. A su vez, se establece una segunda clasificación relacionada con el horizonte de planificación, estas son las clases 1 y 2. En la Clase 1 el horizonte de planificación es corto, esto es, la relación $\frac{\text{demandaclientes}}{\text{capacidadvehiculo}}$ permite que pocos clientes sean abastecidos por el mismo vehículo, mientras que en la Clase 2 el horizonte de planificación es más largo. Del total de instancias GH99 para las cuales la información sobre las BKS está disponible, se seleccionaron ochenta y cinco instancias con el fin de obtener una muestra balanceada en términos de las seis Clases (C1, C2, R1, R2, RC1 y RC2) y los diferentes tamaños de las instancias (200, 400, 600, 800 y 1000 clientes). En particular se seleccionaron tres instancias de cada clase y tamaño, con la excepción de la Clase R2 con los tamaños 200, 400, 600 y 800 para los cuales no existían suficiente BKS disponibles. En la Tabla 6.4 se presentan los resultados para las Clases C1 y C2, en la Tabla 6.5 para las Clases R1 y R2 y en la Tabla 6.6 para las Clases RC1 y RC2.

Tabla 6.4: Cálculo de las métricas de atracción visual para las BKS de la Clase C de instancias GH99.

Instancia	Longitud	K	COMP ^a	COMP ^b	COMP ^c	COMP ^d	COMP ^e	COMP ^f	PROX ^a	PROX ^b	PROX ^c	CH	Inter - C	Intra - C	CLP	BE
C1_2_1	2679,09	20	4,43%	0,43%	0,39%	1,05%	8,70%	0,24%	1,86%	6,36%	0,14%	0,63%	2,08%	0,00%	0,00%	71,91%
C1_2_5	2678,70	20	0,00%	0,00%	0,00%	0,00%	2,71%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	71,58%
C1_2_9	2687,82	18	84,84%	4,58%	20,23%	24,78%	10,83%	21,84%	72,90%	58,41%	13,64%	8,16%	11,81%	10,10%	14,94%	23,65%
C1_4_2	7686,38	36	83,28%	7,33%	25,80%	32,81%	0,02%	18,02%	88,12%	77,56%	19,24%	24,90%	50,69%	21,21%	20,12%	81,03%
C1_4_4	6803,24	36	74,09%	6,63%	14,63%	20,37%	0,00%	10,26%	44,98%	75,73%	13,64%	5,86%	10,42%	4,04%	2,73%	40,92%
C1_4_8	7347,23	37	90,17%	4,14%	19,16%	24,32%	5,33%	22,55%	63,66%	45,09%	29,74%	14,23%	25,00%	7,86%	3,53%	64,12%
C1_6_1	14051,60	60	4,11%	0,47%	1,07%	2,10%	6,47%	0,31%	1,69%	3,34%	1,23%	0,00%	0,69%	0,00%	0,00%	82,03%
C1_6_4	13501,30	56	32,74%	2,40%	10,49%	13,51%	3,47%	9,24%	19,65%	20,14%	14,60%	2,09%	1,30%	1,30%	0,16%	58,76%
C1_6_7	15649,70	57	96,29%	4,41%	34,72%	44,86%	5,51%	28,91%	96,43%	53,96%	38,47%	22,59%	47,92%	8,93%	2,54%	85,48%
C1_8_3	24133,70	72	66,62%	4,50%	20,68%	26,52%	0,00%	15,54%	41,11%	41,21%	27,01%	12,76%	22,92%	8,59%	4,35%	68,34%
C1_8_6	26976,60	79	54,96%	3,76%	22,93%	27,13%	2,28%	13,86%	49,61%	43,82%	18,83%	31,17%	49,31%	11,05%	6,53%	91,92%
C1_8_7	26287,50	77	74,78%	4,05%	29,34%	37,36%	7,57%	24,94%	82,27%	45,24%	39,56%	29,50%	44,44%	10,86%	5,06%	72,60%
C1_10_2	41855,80	90	70,62%	5,86%	39,91%	48,86%	4,33%	24,95%	85,62%	43,12%	41,47%	42,05%	57,64%	16,97%	4,22%	100,00%
C1_10_6	43562,00	99	38,94%	2,68%	17,19%	22,05%	3,44%	11,87%	50,77%	33,25%	21,56%	25,31%	48,61%	4,04%	1,95%	95,59%
C1_10_8	42220,20	93	100,00%	7,55%	41,73%	55,26%	6,00%	48,60%	87,74%	58,30%	74,90%	65,69%	100,00%	11,34%	3,87%	61,69%
C2_2_1	1901,65	6	35,61%	21,81%	51,19%	45,26%	84,85%	29,43%	12,66%	12,67%	4,37%	2,30%	6,25%	42,42%	36,57%	38,68%
C2_2_2	1859,74	6	34,29%	33,83%	57,39%	47,30%	63,78%	29,60%	15,74%	59,27%	3,27%	4,39%	6,25%	42,42%	43,73%	31,00%
C2_2_7	1833,78	6	40,23%	30,72%	59,88%	46,97%	100,00%	29,50%	12,91%	51,43%	4,09%	3,97%	4,17%	24,24%	29,45%	3,08%
C2_4_3	4018,02	11	54,42%	48,88%	66,73%	65,24%	47,94%	34,34%	87,29%	80,35%	26,19%	30,75%	22,22%	59,50%	67,86%	12,20%
C2_4_4	3702,49	11	64,76%	48,57%	72,15%	62,15%	48,24%	40,23%	65,08%	78,85%	22,78%	24,27%	13,19%	42,98%	43,78%	0,00%
C2_4_8	4303,69	11	70,85%	47,47%	74,43%	69,54%	48,17%	52,59%	81,23%	100,00%	34,79%	46,03%	41,67%	62,81%	64,49%	26,99%
C2_6_10	7255,69	17	58,15%	49,15%	73,91%	67,92%	70,45%	49,01%	75,92%	65,94%	39,43%	45,19%	25,69%	47,06%	81,01%	1,90%
C2_6_2	8264,92	17	70,03%	60,29%	89,10%	78,54%	67,56%	46,29%	100,00%	90,01%	33,83%	71,87%	38,33%	68,45%	88,02%	28,54%
C2_6_7	7512,07	18	63,32%	51,36%	64,85%	57,29%	74,96%	45,48%	48,24%	77,32%	37,52%	52,51%	36,81%	40,40%	56,72%	13,58%
C2_8_2	12285,00	23	79,03%	68,13%	91,43%	85,19%	71,33%	45,71%	80,56%	87,30%	43,93%	73,85%	61,11%	60,08%	50,25%	29,63%
C2_8_7	11370,80	24	57,18%	53,22%	67,55%	60,54%	79,19%	39,19%	38,93%	80,74%	41,47%	33,47%	23,61%	28,79%	26,10%	13,66%
C2_8_9	11645,20	23	75,97%	59,65%	83,20%	75,77%	57,21%	67,77%	58,81%	73,45%	54,43%	52,09%	36,81%	71,15%	77,79%	15,77%
C2_10_3	16884,10	28	86,14%	100,00%	92,82%	89,02%	82,39%	51,09%	72,77%	96,84%	56,62%	77,41%	59,03%	100,00%	100,00%	17,10%
C2_10_5	16561,30	30	73,86%	45,76%	68,03%	63,97%	59,71%	77,38%	48,96%	62,69%	72,58%	56,68%	48,61%	25,45%	19,36%	19,99%
C2_10_8	16577,30	28	87,00%	58,24%	100,00%	100,00%	75,92%	100,00%	90,47%	64,39%	100,00%	100,00%	72,22%	27,27%	19,80%	10,01%
MAX			0,59	3184,20	35,51	29,65	659,54	85,74	0,98	0,67	744,00	479,00	144,00	2,75	0,48	1,53
MIN			0,37	49,62	5,82	3,96	18,84	6,89	0,38	0,05	11,00	1,00	0,00	0,00	0,00	1,14
PROMEDIO			0,46	922,98	19,78	15,91	253,41	32,88	0,65	0,40	238,07	153,93	47,47	0,79	0,14	1,32

Tabla 6.5: Cálculo de las métricas de atracción visual para las BKS de la Clase R de las instancias GH99.

Instancia	Longitud	K	COMP ^a	COMP ^b	COMP ^c	COMP ^d	COMP ^e	COMP ^f	PROX ^a	PROX ^b	PROX ^c	CH	Inter - C	Intra - C	CLP	BE
R1_2_1	4784,11	20,00	0,00 %	1,21 %	6,92 %	7,20 %	0,54 %	5,36 %	70,59 %	55,80 %	1,88 %	5,09 %	8,52 %	2,46 %	2,02 %	100,00 %
R1_2_4	3057,81	18,00	15,79 %	0,75 %	0,10 %	0,98 %	0,21 %	1,37 %	22,00 %	3,96 %	0,00 %	0,62 %	0,79 %	0,15 %	0,00 %	16,42 %
R1_2_8	2951,99	18,00	36,36 %	0,89 %	0,00 %	0,00 %	0,01 %	0,00 %	0,00 %	0,00 %	0,42 %	0,00 %	0,00 %	0,00 %	0,02 %	14,84 %
R1_4_1	10372,30	40,00	46,64 %	1,54 %	4,09 %	5,04 %	0,15 %	6,59 %	39,95 %	53,45 %	21,36 %	10,01 %	13,47 %	5,08 %	3,95 %	91,14 %
R1_4_5	9085,49	36,00	8,15 %	0,22 %	2,28 %	3,44 %	0,19 %	7,60 %	38,22 %	8,03 %	18,81 %	4,66 %	4,94 %	4,00 %	3,19 %	84,35 %
R1_4_9	8590,88	36,00	35,43 %	0,00 %	1,25 %	2,08 %	0,00 %	5,05 %	29,82 %	2,73 %	13,86 %	2,87 %	4,08 %	2,55 %	1,76 %	69,71 %
R1_6_2	18863,40	54,00	65,40 %	4,66 %	14,26 %	16,13 %	2,13 %	20,20 %	68,37 %	59,85 %	48,37 %	19,63 %	15,69 %	2,62 %	1,71 %	50,97 %
R1_6_5	19771,90	54,00	46,84 %	3,78 %	14,64 %	15,67 %	2,25 %	21,68 %	72,79 %	68,74 %	45,12 %	20,87 %	18,77 %	3,54 %	2,38 %	71,78 %
R1_6_9	18700,40	54,00	72,66 %	3,60 %	12,29 %	13,22 %	1,90 %	20,97 %	52,84 %	41,96 %	41,87 %	17,71 %	16,19 %	2,47 %	1,70 %	56,70 %
R1_8_2	32598,50	72,00	73,73 %	6,83 %	20,29 %	20,65 %	2,70 %	25,56 %	62,88 %	73,32 %	66,90 %	27,14 %	22,21 %	2,47 %	1,53 %	48,80 %
R1_8_5	33861,40	72,00	63,42 %	5,68 %	20,14 %	19,84 %	2,72 %	28,07 %	56,77 %	50,79 %	67,47 %	22,96 %	22,64 %	4,99 %	3,35 %	70,73 %
R1_8_9	33630,00	72,00	50,50 %	5,75 %	18,30 %	18,67 %	2,50 %	25,32 %	61,08 %	66,87 %	66,34 %	21,23 %	19,56 %	3,49 %	2,31 %	60,04 %
R1_10_2	49105,20	91,00	100,00 %	7,62 %	25,40 %	26,58 %	3,47 %	36,75 %	75,18 %	76,09 %	88,97 %	33,56 %	31,73 %	2,33 %	1,06 %	51,43 %
R1_10_5	51131,40	91,00	64,88 %	3,76 %	21,82 %	22,62 %	2,73 %	36,45 %	50,86 %	40,72 %	77,51 %	25,93 %	28,15 %	4,26 %	2,09 %	89,18 %
R1_10_9	49771,80	91,00	37,70 %	3,18 %	19,05 %	19,08 %	2,32 %	32,48 %	41,42 %	34,94 %	76,52 %	19,99 %	20,99 %	2,73 %	1,54 %	81,00 %
R2_2_9	3092,04	4,00	73,11 %	29,22 %	43,55 %	30,16 %	17,27 %	17,27 %	37,49 %	7,24 %	0,42 %	6,07 %	4,58 %	16,09 %	17,97 %	36,16 %
R2_4_1	9210,15	8,00	58,69 %	40,70 %	39,13 %	37,17 %	44,38 %	27,26 %	69,20 %	70,61 %	20,08 %	23,55 %	29,66 %	54,41 %	45,20 %	58,50 %
R2_4_5	7128,93	8,00	52,03 %	38,43 %	34,48 %	33,87 %	41,96 %	29,75 %	66,98 %	78,61 %	26,31 %	18,10 %	13,54 %	28,21 %	26,90 %	29,83 %
R2_4_9	6400,10	8,00	59,35 %	42,42 %	35,56 %	31,56 %	39,19 %	24,97 %	59,24 %	100,00 %	20,37 %	15,46 %	9,89 %	23,62 %	26,93 %	26,13 %
R2_6_1	18206,80	11,00	48,22 %	65,04 %	48,60 %	51,06 %	61,84 %	53,48 %	57,50 %	78,00 %	45,83 %	33,86 %	35,87 %	100,00 %	100,00 %	56,30 %
R2_6_5	15096,20	11,00	61,69 %	62,06 %	73,75 %	55,32 %	65,79 %	52,21 %	64,38 %	64,92 %	45,54 %	34,61 %	28,08 %	44,02 %	46,76 %	34,89 %
R2_6_9	13377,60	11,00	80,75 %	69,06 %	50,70 %	50,87 %	62,15 %	50,64 %	56,21 %	95,31 %	41,16 %	33,69 %	21,06 %	34,73 %	33,53 %	31,10 %
R2_8_1	28114,20	15,00	34,25 %	77,98 %	75,45 %	71,37 %	78,39 %	75,76 %	84,16 %	71,11 %	63,37 %	54,66 %	67,98 %	73,95 %	64,71 %	59,29 %
R2_8_5	24285,90	15,00	45,95 %	88,03 %	74,45 %	70,39 %	76,93 %	76,86 %	88,04 %	88,71 %	73,55 %	52,80 %	46,63 %	45,30 %	43,32 %	31,98 %
R2_10_1	42149,40	19,00	50,69 %	100,00 %	100,00 %	100,00 %	100,00 %	100,00 %	100,00 %	75,94 %	100,00 %	100,00 %	100,00 %	60,25 %	45,80 %	62,68 %
R2_10_5	36186,60	19,00	45,29 %	96,41 %	92,79 %	91,41 %	92,68 %	98,03 %	91,82 %	78,76 %	98,02 %	83,59 %	70,27 %	39,02 %	30,09 %	46,24 %
R2_10_8	17484,10	19,00	97,76 %	91,80 %	70,95 %	65,90 %	69,42 %	92,48 %	59,79 %	70,02 %	86,99 %	30,89 %	5,01 %	3,43 %	3,33 %	0,00 %
MAX			0,56	8000,46	126,37	102,44	3394,75	166,38	0,49	0,85	826,00	3125,00	1405,00	38,27	9,25	1,74
MIN			0,47	238,22	21,06	15,43	90,68	25,39	-0,42	0,52	119,00	59,00	9,00	0,11	0,02	0,91
PROMEDIO			0,52	2683,62	50,95	43,80	1064,08	76,16	-0,04	0,71	448,19	876,11	350,30	8,11	1,78	1,35

Tabla 6.6: Cálculo de las métricas de atracción visual para las BKS de la Clase RC de las instancias GH99.

Instancia	Longitud	K	COMP ^a	COMP ^b	COMP ^c	COMP ^d	COMP ^e	COMP ^f	PROX ^a	PROX ^b	PROX ^c	CH	Inter - C	Intra - C	CLP	BE
RC1_2_2	3249,05	18,00	1,25%	1,06%	3,38%	5,24%	0,90%	5,55%	49,68%	44,47%	4,86%	4,21%	3,19%	2,69%	2,27%	40,69%
RC1_2_4	2851,68	18,00	0,61%	0,57%	1,74%	0,00%	0,19%	0,72%	0,00%	37,38%	2,00%	0,00%	0,00%	0,00%	0,00%	8,32%
RC1_2_9	3081,13	18,00	10,46%	0,59%	1,74%	1,54%	0,37%	0,00%	7,27%	19,11%	1,29%	0,44%	0,58%	1,92%	1,15%	53,86%
RC1_4_1	8378,75	36,00	0,00%	0,41%	1,64%	3,15%	0,21%	3,27%	22,52%	0,00%	12,14%	5,66%	7,39%	3,46%	1,44%	92,24%
RC1_4_10	7517,93	36,00	20,04%	0,00%	0,00%	1,33%	0,07%	4,11%	11,55%	2,52%	18,43%	1,89%	2,17%	1,35%	1,21%	35,91%
RC1_4_5	8080,49	36,00	21,40%	0,38%	0,79%	2,10%	0,00%	3,55%	18,43%	25,65%	16,00%	4,84%	6,81%	2,88%	1,92%	67,86%
RC1_6_1	16581,30	55,00	0,93%	5,23%	5,23%	6,89%	0,56%	9,05%	13,36%	3,76%	32,29%	8,99%	6,09%	4,27%	2,79%	91,08%
RC1_6_5	16359,40	55,00	46,79%	0,78%	6,05%	7,16%	0,71%	13,02%	5,83%	3,10%	32,29%	8,99%	7,54%	4,27%	2,42%	83,60%
RC1_6_9	15668,40	55,00	26,16%	0,75%	7,43%	8,91%	1,00%	13,32%	11,17%	2,05%	35,86%	6,14%	5,22%	2,51%	1,32%	50,10%
RC1_8_1	30998,00	72,00	67,80%	2,59%	14,92%	17,91%	2,10%	24,70%	52,14%	29,59%	57,14%	22,44%	28,12%	6,92%	4,34%	100,00%
RC1_8_5	30277,10	72,00	72,51%	5,26%	19,71%	22,48%	2,87%	24,42%	72,05%	70,93%	65,14%	31,38%	32,61%	5,87%	4,01%	60,46%
RC1_8_9	28978,30	72,00	66,19%	5,05%	17,22%	20,02%	2,62%	22,51%	69,75%	60,94%	66,43%	32,25%	30,87%	2,98%	2,05%	38,38%
RC1_10_1	46272,10	90,00	70,42%	6,46%	23,27%	26,06%	3,22%	25,95%	61,07%	63,51%	87,00%	33,80%	37,54%	6,15%	3,54%	64,35%
RC1_10_5	45564,80	90,00	68,30%	6,20%	21,96%	24,59%	3,06%	24,42%	63,69%	64,53%	83,00%	35,06%	30,72%	6,85%	3,91%	68,67%
RC1_10_9	44280,80	90,00	72,10%	5,54%	20,00%	22,83%	2,84%	22,81%	53,73%	62,98%	81,14%	23,50%	21,30%	3,23%	2,27%	43,63%
RC2_2_3	2601,87	4,00	43,77%	26,89%	34,92%	29,83%	36,05%	18,21%	22,35%	61,68%	0,57%	3,82%	2,75%	77,50%	100,00%	0,00%
RC2_2_6	2873,12	4,00	66,00%	31,05%	40,10%	40,98%	44,22%	20,67%	52,76%	97,45%	6,43%	7,64%	6,23%	63,65%	71,82%	45,12%
RC2_2_8	2292,53	4,00	68,16%	26,09%	34,25%	28,45%	35,58%	15,12%	16,69%	5,54%	0,00%	1,50%	0,72%	37,69%	45,14%	27,17%
RC2_4_1	6682,38	11,00	49,21%	22,53%	31,88%	32,85%	26,07%	24,62%	73,53%	47,95%	23,29%	20,21%	24,78%	83,32%	79,63%	56,93%
RC2_4_2	6180,62	9,00	56,45%	32,66%	40,58%	34,97%	35,03%	30,01%	55,58%	79,91%	23,14%	18,33%	22,61%	87,31%	84,24%	30,01%
RC2_4_8	4793,06	8,00	80,01%	37,06%	35,68%	33,19%	39,42%	27,37%	32,83%	55,22%	18,00%	12,72%	6,96%	49,81%	65,79%	18,81%
RC2_6_1	13324,90	14,00	57,28%	41,56%	56,60%	52,19%	45,21%	47,95%	85,99%	75,19%	50,71%	39,94%	46,81%	80,22%	77,80%	49,55%
RC2_6_2	11555,50	12,00	71,96%	53,77%	58,98%	62,78%	63,40%	50,51%	93,62%	92,53%	59,29%	46,57%	33,91%	78,65%	77,65%	23,53%
RC2_6_6	11933,90	11,00	82,76%	60,53%	62,98%	62,03%	69,21%	48,45%	78,17%	70,30%	46,43%	40,38%	35,94%	76,40%	72,48%	30,25%
RC2_8_1	20981,10	18,00	62,21%	53,10%	77,78%	71,22%	60,39%	62,61%	86,28%	60,98%	69,86%	59,33%	64,20%	95,00%	93,09%	54,68%
RC2_8_5	19136,00	15,00	75,98%	79,84%	85,25%	79,00%	80,91%	65,62%	80,09%	88,03%	64,86%	67,99%	61,30%	81,31%	69,53%	41,17%
RC2_8_9	15360,00	15,00	95,48%	80,01%	68,46%	72,71%	74,20%	65,80%	57,35%	79,21%	72,14%	49,37%	29,38%	45,77%	42,25%	24,01%
RC2_10_1	30278,50	20,00	79,94%	94,64%	97,61%	96,62%	89,52%	92,35%	91,75%	100,00%	100,00%	100,00%	100,00%	100,00%	83,76%	58,22%
RC2_10_6	26645,60	18,00	95,85%	94,75%	100,00%	100,00%	100,00%	100,00%	100,00%	72,21%	97,29%	89,46%	59,57%	78,08%	78,28%	41,39%
RC2_10_9	22976,70	18,00	100,00%	100,00%	87,99%	87,90%	88,03%	81,69%	79,67%	97,36%	76,86%	66,44%	40,00%	49,23%	48,13%	30,73%
MAX			0,49	8457,81	105,07	85,30	2916,48	167,80	0,43	0,87	793,00	2129,00	699,00	14,50	2,94	1,52
MIN			0,37	210,33	16,15	12,64	66,47	22,16	-0,22	0,47	93,00	61,00	9,00	0,06	0,02	1,02
PROMEDIO			0,43	2605,01	47,49	38,19	929,06	68,20	0,10	0,68	395,67	640,73	182,70	5,54	1,11	1,26

La información sobre todas las instancias de Uchoa et al. (2017) se extrajo, nuevamente, de *Vehicle Routing Problem Repository* ([dataset] Gehring y Homberger, 1999) (VRP-REP) y la mejor solución encontrada fue recabada del repositorio *Capacitated Vehicle Routing Problem Library* [dataset] Uchoa et al. (2014). Siguiendo la misma metodología aplicada al benchmark GH99, se presentan las Tablas 6.7 y 6.8 con los valores numéricos de las desviaciones relativas porcentuales de las métricas de cada instancia con respecto a la mejor medición de todo el conjunto.

Las Tablas 6.7 y 6.8 muestran un resultado peculiar: algunas instancias que presentan cruces intra-rutas. Es conocido que en el problema CVRP con distancias simétricas, esto es que se sostiene la desigualdad triangular, los cruces entre caminos de la misma ruta son una evidencia de sub-optimalidad en la solución (véase Flood Flood (1956)). Sin embargo, luego de aplicar un simple procedimiento para reparar los cruces intra-ruta basado en el conocido operador *two-opt*, se encuentra que la distancia total de las soluciones, en general, no ha cambiado con la excepción de la instancia X-n317-k53 donde incluso se incrementa en una unidad (véase la Tabla 6.9). La razón de este comportamiento inesperado radica en que Uchoa et al. (2017) utiliza la convención de TSPLIB de redondear las distancias entre clientes al entero más próximo (Reinelt Reinelt (1991)).

Tabla 6.7: Cálculo de las métricas de atracción visual para las BKS de las instancias de Uchoa et al. (parte A).

Instancia	Longitud	K	COMP ^a	COMP ^b	COMP ^c	COMP ^d	COMP ^e	COMP ^f	PROX ^a	PROX ^b	PROX ^c	CH	Inter-C	Intra-C	CLP	BE
X-n101-k25	27591	26	23,90%	32,16%	34,11%	17,62%	17,62%	41,19%	32,64%	1,45%	2,00%	3,96%	0,00%	0,00%	0,00%	69,94%
X-n106-k14	26362	14	52,49%	10,84%	24,96%	7,23%	7,23%	25,52%	47,21%	2,37%	2,33%	1,49%	0,00%	0,00%	0,00%	31,77%
X-n110-k13	14971	13	49,34%	53,42%	53,42%	16,79%	28,44%	9,31%	23,90%	0,00%	0,00%	0,50%	0,00%	0,00%	0,00%	21,74%
X-n115-k10	12747	10	67,73%	60,36%	60,36%	40,16%	37,17%	36,28%	43,04%	3,02%	3,00%	0,50%	0,00%	0,00%	0,00%	12,64%
X-n120-k6	13332	6	68,12%	80,83%	97,48%	83,50%	66,30%	18,48%	61,23%	2,89%	2,17%	0,50%	0,00%	0,00%	0,00%	4,37%
X-n125-k30	55539	30	18,21%	30,14%	28,35%	14,70%	17,77%	75,77%	51,19%	3,68%	4,00%	7,92%	0,00%	0,00%	0,00%	81,83%
X-n129-k18	28940	18	67,83%	49,18%	45,01%	13,05%	30,84%	30,80%	45,54%	4,07%	3,67%	2,48%	0,00%	0,00%	0,00%	14,83%
X-n134-k13	10916	13	73,21%	26,21%	25,52%	22,59%	33,54%	33,54%	33,54%	3,68%	2,50%	1,49%	0,00%	0,00%	0,00%	20,65%
X-n139-k10	13590	10	63,76%	75,12%	74,71%	44,45%	47,20%	18,94%	55,39%	3,55%	1,33%	0,99%	0,00%	0,00%	0,00%	5,66%
X-n143-k7	15700	7	74,96%	97,43%	100,00%	100,00%	100,00%	30,15%	48,37%	5,78%	8,17%	3,47%	0,00%	0,00%	0,00%	7,07%
X-n148-k46	42448	47	22,55%	1,86%	25,71%	12,08%	12,08%	50,77%	27,22%	3,15%	1,83%	5,45%	0,00%	0,00%	0,00%	87,16%
X-n153-k22	21220	23	50,72%	7,71%	29,83%	17,92%	17,92%	79,33%	56,65%	9,33%	14,33%	9,41%	0,00%	0,00%	0,00%	42,77%
X-n157-k13	16876	13	74,18%	17,35%	28,87%	28,31%	15,48%	46,70%	57,79%	7,23%	4,17%	0,99%	0,00%	0,00%	0,00%	3,89%
X-n162-k11	14138	11	69,62%	61,33%	67,33%	42,92%	46,38%	38,02%	50,68%	6,83%	7,50%	1,98%	0,00%	0,00%	0,00%	8,11%
X-n167-k10	20557	10	66,91%	67,83%	68,63%	55,27%	63,76%	19,20%	30,70%	2,48%	3,67%	2,48%	0,00%	0,00%	0,00%	12,06%
X-n172-k51	45607	53	0,00%	1,93%	21,05%	1,57%	9,29%	40,06%	21,82%	4,86%	3,67%	4,46%	0,00%	0,00%	0,00%	100,00%
X-n176-k26	47812	26	54,66%	63,47%	66,79%	15,79%	46,26%	84,06%	70,79%	11,96%	11,00%	12,87%	0,00%	0,00%	0,00%	29,15%
X-n181-k23	25669	23	55,76%	6,08%	21,49%	14,20%	14,20%	21,75%	41,55%	8,28%	1,83%	0,50%	0,00%	0,00%	0,00%	23,93%
X-n186-k15	24145	15	66,49%	39,00%	51,50%	30,03%	30,03%	28,38%	64,05%	5,78%	5,50%	2,48%	0,00%	0,00%	0,00%	10,13%
X-n190-k8	16980	8	100,00%	85,74%	39,84%	46,92%	54,88%	64,12%	100,00%	14,72%	11,00%	11,00%	0,00%	0,00%	0,00%	9,04%
X-n195-k51	44225	53	18,54%	2,20%	22,27%	21,12%	1,79%	40,02%	30,84%	6,57%	4,33%	5,94%	0,00%	0,00%	0,00%	71,36%
X-n200-k36	58578	36	59,84%	4,19%	13,69%	15,71%	8,24%	39,90%	54,07%	7,10%	3,00%	5,45%	0,00%	0,00%	0,00%	35,92%
X-n204-k19	19665	19	61,43%	17,00%	36,27%	41,57%	19,61%	31,50%	51,76%	7,49%	6,50%	1,49%	0,00%	0,00%	0,00%	17,10%
X-n209-k16	30656	16	72,48%	53,91%	57,50%	32,66%	24,96%	21,01%	51,89%	11,56%	5,17%	4,46%	0,00%	0,00%	0,00%	13,53%
X-n214-k11	10856	11	81,91%	45,57%	47,07%	45,30%	33,95%	79,38%	86,68%	14,45%	26,33%	5,94%	0,00%	0,00%	0,00%	0,38%
X-n219-k73	117595	73	13,14%	10,43%	9,96%	0,00%	0,00%	0,00%	0,00%	2,50%	0,00%	0,00%	0,00%	0,00%	0,00%	83,74%
X-n223-k34	40437	34	51,52%	8,42%	28,81%	31,60%	18,36%	31,58%	46,31%	9,72%	7,83%	3,47%	0,00%	0,00%	0,00%	31,62%
X-n228-k23	25742	23	72,67%	32,12%	35,32%	35,32%	15,58%	60,27%	64,13%	13,93%	11,50%	8,42%	0,00%	0,00%	0,00%	22,09%
X-n233-k16	19280	17	71,82%	41,96%	44,51%	31,61%	32,15%	24,56%	44,98%	12,88%	4,50%	3,96%	0,00%	0,00%	0,00%	17,86%
X-n237-k14	27042	14	65,81%	60,18%	64,03%	51,94%	50,95%	39,53%	72,53%	17,08%	4,00%	1,49%	0,00%	0,00%	0,00%	18,24%
X-n242-k48	82751	48	49,48%	25,39%	27,59%	4,13%	16,51%	39,35%	49,75%	12,35%	6,33%	9,41%	0,00%	0,00%	0,00%	42,59%
X-n247-k47	37274	51	52,15%	18,10%	16,89%	8,22%	8,22%	74,96%	57,02%	13,40%	22,83%	20,30%	0,00%	0,00%	0,00%	44,36%
X-n251-k28	38684	28	67,48%	13,22%	33,25%	11,89%	20,67%	34,25%	59,04%	12,48%	5,50%	3,47%	0,00%	0,00%	0,00%	16,71%
X-n256-k16	18880	17	75,25%	32,58%	35,89%	26,43%	24,91%	35,93%	46,03%	11,04%	11,50%	1,49%	0,00%	0,00%	0,00%	10,63%
X-n261-k13	26558	13	84,55%	95,20%	86,01%	79,86%	78,38%	56,86%	92,89%	18,66%	26,33%	5,94%	0,00%	0,00%	0,00%	1,06%
X-n266-k58	75478	58	43,06%	17,24%	19,10%	2,22%	10,30%	30,97%	37,56%	12,35%	5,17%	5,45%	0,00%	0,00%	0,00%	45,57%
X-n270-k35	35291	36	55,09%	7,37%	24,42%	26,75%	7,94%	27,44%	51,47%	14,85%	4,50%	2,97%	0,00%	0,00%	0,00%	19,77%
X-n275-k28	21245	28	66,27%	15,91%	17,73%	12,43%	9,05%	24,12%	44,89%	15,77%	3,33%	0,50%	0,00%	0,00%	0,00%	21,06%
X-n280-k17	33503	17	68,98%	74,53%	78,06%	61,02%	61,02%	67,23%	79,69%	22,34%	28,00%	13,37%	0,00%	0,00%	0,00%	2,44%
X-n284-k15	20226	15	90,55%	30,28%	36,68%	37,70%	37,70%	50,44%	81,13%	21,55%	29,67%	7,43%	0,00%	0,00%	0,00%	1,80%
X-n289-k60	95185	61	35,47%	24,58%	26,24%	11,66%	11,66%	56,73%	49,04%	13,27%	9,00%	16,34%	0,00%	0,00%	0,00%	55,33%
X-n294-k50	47167	51	56,45%	26,17%	29,25%	5,84%	5,84%	47,27%	44,95%	14,72%	9,67%	11,39%	0,00%	0,00%	0,00%	36,27%
X-n298-k31	34231	31	65,05%	32,52%	36,74%	14,35%	22,97%	34,51%	63,67%	14,32%	8,83%	7,43%	0,00%	0,00%	0,00%	16,20%
X-n303-k21	21744	21	78,53%	39,13%	27,44%	27,88%	27,88%	55,79%	72,03%	20,50%	17,17%	4,95%	0,00%	0,00%	0,00%	12,90%
X-n308-k13	25859	13	85,12%	75,59%	85,34%	96,89%	76,02%	62,34%	91,33%	27,99%	32,83%	9,41%	0,00%	0,00%	0,00%	0,00%
X-n313-k71	94044	72	33,95%	22,38%	24,67%	14,58%	14,58%	73,81%	40,45%	16,16%	15,83%	18,81%	0,00%	0,00%	0,00%	58,80%
X-n317-k53	78355	53	51,51%	6,40%	6,71%	1,98%	3,65%	31,15%	31,15%	13,01%	1,00%	0,00%	0,00%	0,00%	0,00%	23,52%
X-n322-k28	29856	28	64,90%	32,90%	37,85%	24,14%	24,14%	21,15%	54,31%	16,29%	8,17%	4,46%	0,00%	0,00%	0,00%	13,34%
X-n327-k20	27556	20	67,74%	40,85%	43,58%	48,77%	38,05%	44,49%	65,36%	20,11%	17,83%	3,96%	0,00%	0,00%	0,00%	8,66%
X-n331-k15	31103	15	75,01%	64,56%	66,02%	68,38%	57,51%	36,61%	65,61%	25,76%	9,50%	3,47%	0,00%	0,00%	0,00%	5,15%
X-n336-k84	139210	86	22,22%	26,87%	28,93%	12,13%	2,49%	68,65%	44,88%	16,56%	7,50%	25,74%	0,00%	0,00%	0,00%	79,05%
X-n344-k43	42099	43	53,36%	22,56%	26,82%	16,13%	16,13%	35,69%	60,33%	19,05%	8,50%	8,42%	0,00%	0,00%	0,00%	20,24%

Tabla 6.8: Cálculo de las métricas de atracción visual para las BKS de las instancias de Uchoa et al. (parte B).

Instancia	Longitud	K	COMP ^a	COMP ^b	COMP ^c	COMP ^d	COMP ^e	COMP ^f	PROX ^a	PROX ^b	PROX ^c	CH	Intra - C	Inter - C	CLP	BE
X-n351-k40	25946	41	64,80%	7,06%	15,35%	16,83%	7,51%	12,17%	45,69%	67,11%	22,86%	25,50%	11,39%	0,00%	0,00%	15,48%
X-n359-k29	51509	29	70,04%	25,28%	33,91%	39,70%	21,61%	30,23%	38,12%	72,11%	26,41%	18,00%	8,42%	0,00%	0,00%	11,20%
X-n367-k17	22814	17	83,66%	57,37%	36,75%	39,25%	47,36%	32,95%	68,01%	79,13%	33,38%	46,50%	0,00%	0,00%	0,00%	3,80%
X-n376-k94	147713	94	32,92%	0,77%	9,43%	9,12%	0,70%	3,63%	3,68%	24,62%	9,33%	0,00%	0,00%	0,00%	0,00%	54,94%
X-n384-k52	66081	53	47,05%	7,22%	21,03%	23,07%	12,63%	13,60%	20,77%	58,20%	17,48%	5,17%	0,00%	0,00%	0,00%	23,72%
X-n393-k38	38269	38	68,62%	13,27%	29,14%	27,69%	16,36%	18,49%	28,36%	55,66%	21,94%	8,67%	0,00%	0,00%	0,00%	12,38%
X-n401-k29	66243	29	84,09%	28,09%	33,66%	30,02%	20,79%	24,52%	58,24%	78,33%	25,62%	29,67%	18,81%	0,00%	0,00%	9,05%
X-n411-k19	19718	19	80,71%	56,95%	33,86%	43,25%	48,27%	36,81%	77,99%	86,63%	32,33%	45,67%	8,91%	0,00%	0,00%	2,72%
X-n420-k130	107998	130	13,50%	0,35%	11,33%	10,09%	0,29%	3,78%	46,11%	33,43%	18,33%	5,67%	19,31%	0,00%	0,00%	83,86%
X-n429-k61	65501	62	49,53%	5,28%	17,86%	20,31%	5,66%	21,60%	48,32%	48,32%	27,07%	5,83%	7,43%	0,00%	0,00%	26,00%
X-n439-k37	36395	37	61,24%	15,49%	24,15%	27,62%	15,17%	18,40%	26,12%	56,75%	23,92%	7,33%	1,49%	0,00%	0,00%	12,83%
X-n449-k29	55358	29	82,07%	43,32%	44,14%	50,33%	34,82%	45,46%	62,95%	92,83%	37,06%	39,00%	20,30%	0,00%	0,00%	3,72%
X-n459-k26	24181	26	77,17%	25,20%	30,19%	28,33%	28,75%	21,36%	61,52%	76,36%	38,37%	29,17%	5,94%	0,00%	0,00%	4,72%
X-n469-k138	222070	140	19,65%	0,75%	12,80%	12,16%	0,43%	5,03%	49,85%	44,70%	22,08%	8,33%	25,74%	0,00%	0,00%	72,41%
X-n480-k70	89335	70	55,15%	4,36%	11,96%	13,60%	3,87%	8,82%	34,22%	56,33%	24,57%	11,33%	10,89%	42,87%	0,76%	24,93%
X-n481-k59	66633	60	69,00%	11,65%	19,73%	24,00%	8,13%	15,34%	41,39%	71,06%	35,61%	24,00%	20,30%	0,00%	0,00%	15,98%
X-n502-k39	69253	39	70,07%	10,65%	12,07%	14,70%	10,59%	12,37%	32,65%	66,33%	33,77%	10,83%	2,97%	0,00%	0,00%	9,47%
X-n513-k21	24201	21	77,17%	58,28%	46,58%	46,78%	59,59%	38,89%	38,62%	78,08%	39,03%	31,33%	8,42%	0,00%	0,00%	4,24%
X-n524-k137	954711	156	50,11%	3,49%	35,05%	30,83%	2,60%	13,96%	95,58%	43,30%	35,35%	27,17%	92,08%	0,00%	0,00%	51,18%
X-n536-k96	95122	97	55,67%	2,58%	7,03%	8,77%	2,68%	5,81%	48,84%	51,21%	34,95%	14,50%	16,34%	30,93%	1,91%	37,84%
X-n548-k50	86822	50	70,10%	13,12%	23,04%	25,16%	12,56%	17,18%	20,78%	69,97%	35,48%	6,00%	1,49%	0,00%	0,00%	12,56%
X-n561-k42	42756	42	74,54%	22,08%	28,04%	31,42%	19,85%	24,53%	37,11%	71,48%	39,82%	23,17%	13,37%	71,44%	2,49%	10,55%
X-n573-k30	50780	30	86,61%	36,76%	21,95%	23,43%	25,89%	25,18%	88,14%	97,60%	54,80%	68,67%	26,73%	100,00%	2,68%	0,89%
X-n586-k159	190543	159	29,91%	0,58%	8,78%	8,68%	0,48%	3,07%	43,59%	44,60%	29,30%	9,17%	19,80%	37,74%	11,47%	61,75%
X-n599-k92	108813	94	54,45%	4,48%	13,98%	16,09%	3,75%	9,77%	27,20%	51,93%	31,67%	12,67%	13,37%	0,00%	0,00%	27,66%
X-n613-k62	59778	62	70,68%	14,65%	23,23%	27,73%	11,91%	20,89%	46,28%	70,16%	44,68%	31,33%	21,29%	0,00%	0,00%	12,13%
X-n627-k43	62366	43	85,54%	21,05%	20,88%	23,59%	16,73%	19,49%	59,78%	93,84%	54,14%	40,17%	15,84%	0,00%	0,00%	3,83%
X-n641-k35	63839	35	76,78%	39,71%	34,83%	37,58%	33,06%	33,61%	52,11%	82,22%	57,03%	36,00%	11,39%	0,00%	0,00%	5,49%
X-n655-k131	106780	131	50,15%	0,00%	0,00%	0,00%	0,51%	1,60%	100,00%	62,31%	53,22%	0,00%	0,50%	45,81%	3,06%	38,55%
X-n670-k126	146705	134	47,02%	5,96%	30,53%	29,99%	5,20%	15,74%	100,00%	62,31%	53,22%	48,17%	76,73%	67,18%	100,00%	45,35%
X-n685-k75	68425	75	68,99%	12,24%	19,29%	21,14%	9,75%	15,15%	46,13%	69,42%	49,41%	39,00%	17,82%	0,00%	0,00%	22,67%
X-n701-k44	82292	44	86,25%	38,91%	31,55%	37,31%	26,53%	32,70%	61,33%	97,63%	60,84%	46,17%	25,74%	0,00%	0,00%	1,93%
X-n716-k35	43525	35	89,61%	39,74%	23,52%	26,01%	29,32%	36,85%	73,82%	92,90%	72,67%	96,00%	35,15%	0,00%	0,00%	3,85%
X-n733-k159	136366	160	52,51%	2,04%	10,32%	11,60%	1,45%	5,64%	43,60%	47,10%	42,05%	16,50%	20,79%	18,75%	2,87%	48,10%
X-n749-k98	77700	98	66,73%	5,23%	11,54%	13,14%	4,87%	10,43%	48,03%	64,43%	55,32%	33,17%	33,17%	30,60%	3,44%	19,91%
X-n766-k71	114683	71	66,15%	24,42%	36,46%	36,63%	18,07%	26,81%	92,42%	83,16%	72,40%	78,17%	50,50%	0,00%	0,00%	23,85%
X-n783-k48	72727	48	74,73%	34,87%	32,51%	36,06%	33,50%	33,30%	49,38%	81,37%	66,49%	53,17%	25,25%	0,00%	0,00%	7,48%
X-n801-k40	73587	40	80,05%	43,21%	33,08%	37,61%	36,31%	29,69%	47,17%	95,25%	67,28%	25,83%	10,89%	0,00%	0,00%	4,91%
X-n819-k171	158611	173	50,37%	0,76%	4,06%	4,36%	0,74%	1,78%	41,21%	47,13%	45,20%	13,83%	23,76%	17,34%	0,38%	42,34%
X-n837-k142	194266	142	60,41%	2,55%	9,05%	10,26%	2,45%	6,31%	35,00%	61,05%	51,12%	16,33%	21,78%	21,12%	4,40%	31,27%
X-n856-k95	99115	95	64,08%	5,75%	11,18%	12,54%	5,84%	8,33%	54,75%	52,17%	52,17%	5,50%	1,49%	0,00%	0,00%	16,54%
X-n876-k59	89715	59	90,31%	21,64%	19,16%	24,17%	18,32%	29,33%	77,52%	90,68%	83,57%	100,00%	65,84%	0,00%	0,00%	2,93%
X-n895-k37	54172	38	84,22%	53,93%	37,53%	40,61%	49,48%	40,42%	51,19%	89,68%	88,96%	57,83%	20,30%	0,00%	0,00%	1,54%
X-n916-k207	329836	208	49,65%	0,99%	6,90%	7,67%	0,88%	3,83%	44,90%	49,62%	51,38%	15,67%	26,73%	0,00%	0,00%	46,59%
X-n936-k151	133105	159	46,74%	6,14%	21,90%	21,90%	5,20%	11,86%	92,86%	66,97%	77,40%	67,17%	100,00%	37,74%	59,46%	43,56%
X-n957-k87	85672	87	69,96%	7,87%	13,66%	15,04%	9,08%	11,54%	27,32%	60,74%	71,22%	23,33%	7,43%	0,00%	0,00%	10,96%
X-n979-k58	119194	58	79,62%	27,93%	15,30%	19,05%	22,18%	22,10%	60,80%	83,83%	89,49%	75,33%	21,78%	51,73%	0,76%	7,61%
X-n1001-k43	72742	43	85,15%	60,78%	39,00%	43,57%	50,88%	47,76%	59,29%	91,09%	100,00%	92,33%	40,10%	0,00%	0,00%	0,76%
MAX ⁽¹⁾			0,82	8125,77	267,59	183,42	2355,24	452,13	0,84	0,80	796,00	600,00	202,00	0,03	0,01	2,43
MIN ⁽¹⁾			0,38	107,44	22,30	16,30	16,71	24,68	-0,14	0,19	35,00	0,00	0,00	0,00	0,00	0,88
PROMEDIO ⁽¹⁾			0,55	1952,17	98,61	72,13	506,56	130,94	0,40	0,56	246,09	119,15	26,93	0,00	0,00	1,26

Obs: ⁽¹⁾ los valores máximo, mínimo y promedio presentados en esta tabla están calculados para todo el conjunto de instancias de Uchoa et al., esto es, las Tablas 6.7 y 6.8.

Tabla 6.9: Cálculo de las métricas de atracción visual para las BKS corregidas de las instancias de Uchoa et al..

Instancia	Longitud	K	COMP ^a	COMP ^b	COMP ^c	COMP ^d	COMP ^e	COMP ^f	PROX ^a	PROX ^b	PROX ^c	CH	Inter - C	Intra - C	CLP	BE
X-n317-k53	78356	53	54,81 %	1,71 %	6,30 %	6,71 %	5,91 %	3,65 %	16,80 %	31,15 %	13,01 %	1,00 %	0,00 %	0,00 %	0,00 %	33,17 %
X-n480-k70	89535	70	56,77 %	4,36 %	11,96 %	13,60 %	13,36 %	8,82 %	34,22 %	56,33 %	24,57 %	11,33 %	10,89 %	0,00 %	0,00 %	24,67 %
X-n536-k96	95122	97	57,78 %	2,58 %	7,03 %	8,77 %	8,66 %	5,81 %	48,84 %	51,21 %	34,95 %	14,50 %	16,34 %	0,00 %	0,00 %	37,68 %
X-n561-k42	42756	42	75,98 %	22,08 %	28,04 %	31,42 %	76,21 %	24,53 %	37,11 %	71,48 %	39,82 %	23,17 %	13,37 %	0,00 %	0,00 %	10,42 %
X-n573-k30	50780	30	88,49 %	36,76 %	21,95 %	23,43 %	100,00 %	25,18 %	88,14 %	97,60 %	54,80 %	68,67 %	26,73 %	0,00 %	0,00 %	0,66 %
X-n586-k159	190543	159	31,96 %	0,58 %	8,81 %	8,68 %	0,00 %	3,57 %	43,59 %	44,60 %	29,30 %	9,17 %	19,80 %	0,00 %	0,00 %	61,62 %
X-n655-k131	106780	131	54,20 %	0,00 %	0,01 %	0,00 %	0,11 %	0,00 %	1,60 %	21,09 %	28,25 %	0,00 %	0,50 %	0,00 %	0,00 %	38,30 %
X-n670-k126	146705	134	47,28 %	5,98 %	30,50 %	29,99 %	18,54 %	15,70 %	100,00 %	62,47 %	53,22 %	48,17 %	76,73 %	0,00 %	0,00 %	45,32 %
X-n733-k159	136366	160	53,93 %	2,04 %	10,31 %	11,60 %	3,82 %	5,64 %	43,60 %	47,10 %	42,05 %	16,50 %	20,79 %	0,00 %	0,00 %	48,04 %
X-n749-k98	77700	98	69,04 %	5,23 %	11,54 %	13,14 %	17,28 %	10,43 %	48,03 %	64,43 %	55,32 %	38,17 %	33,17 %	0,00 %	0,00 %	19,85 %
X-n819-k171	158611	173	52,96 %	0,76 %	4,06 %	4,36 %	1,04 %	1,78 %	41,21 %	47,13 %	45,20 %	13,83 %	23,76 %	0,00 %	0,00 %	42,28 %
X-n837-k142	194266	142	62,07 %	2,55 %	9,05 %	10,26 %	7,75 %	6,31 %	35,00 %	61,05 %	51,12 %	16,33 %	21,78 %	0,00 %	0,00 %	31,27 %
X-n936-k151	133105	159	47,19 %	6,15 %	21,97 %	21,56 %	18,58 %	11,84 %	92,86 %	66,97 %	77,40 %	67,17 %	100,00 %	0,00 %	0,00 %	43,54 %
X-n979-k58	119194	58	82,86 %	27,93 %	15,30 %	19,05 %	85,41 %	22,10 %	60,80 %	83,83 %	89,49 %	75,33 %	21,78 %	0,00 %	0,00 %	7,57 %
MAX ⁽¹⁾			0,82	8125,77	267,59	183,42	2335,24	452,13	0,84	0,80	796,00	600,00	202,00	0,03	0,01	2,43
MIN ⁽¹⁾			0,38	107,44	22,30	16,30	16,71	24,68	-0,14	0,19	35,00	0,00	0,00	0,00	0,00	0,88
PROMEDIO ⁽¹⁾			0,55	1952,17	98,61	72,13	506,56	130,94	0,40	0,56	246,09	119,15	26,93	0,00	0,00	1,26

Obs: ⁽¹⁾ los valores máximo, mínimo y promedio presentados en esta tabla son los calculados para las Tablas 6.7 and 6.8.

6.4.2.1. Análisis de correlación

Para analizar la relación entre las diferentes medidas de atracción visual presentadas se calcula la matriz de correlación covariada para cada par de métricas considerando los coeficientes propuestos por Pearson (1896), Spearman (1904) y Kendall (1938). Estas matrices se presentan separadamente para las Clases C, R y RC del benchmark GH99 en las Figuras 6.4-6.6, respectivamente, y para el benchmark de Uchoa et al. en la Figura 6.7.

En la mitad inferior izquierda de cada matriz se incluyen las gráficas de la relación existente entre cada par de métricas de atracción visual, con su curva de tendencia relacionada. Por otro lado, en la parte superior derecha, comenzando desde la parte superior con dirección descendente, se presentan los coeficientes de correlación de Pearson (1896), Spearman (1904) y Kendall (1938), respectivamente. El coeficiente de Pearson, que es ampliamente utilizado en los análisis de correlación entre variables, mide la asociación lineal entre variables normales a diferencia de Spearman y Kendall que son coeficientes no-paramétricos, esto es, que no asumen ninguna distribución particular de las variables aleatorias analizadas. Además, estos dos últimos coeficientes son estadísticos basados en rangos, es decir, la magnitud de los valores observados es únicamente utilizada para determinar su posición relativa en el ordenamiento. Por lo tanto, la estadística basada en rangos depende solamente de las magnitudes relativas de las observaciones (Gibbons y Chakraborti, 2011). De esta forma, la incorporación de los coeficientes de Spearman y Kendall permite un análisis más robusto de la relación entre variables. Los valores de los tres coeficientes mencionados varían entre -1 y 1. Un valor positivo refleja una relación positiva: cuando una variable crece, la otra variable crece también. Por el contrario, si el valor del coeficiente es negativa, cuando una variable decrece la otra crece y vice-versa. La relación entre variables (ya sea positiva o negativa) será más fuerte a medida que aumenta el valor absoluto del coeficiente.

De las Figuras 6.4 a 6.6 puede verse que las métricas de compacidad están fuertemente relacionadas. En particular, $COMP^b$, $COMP^c$, $COMP^d$, $COMP^e$, $COMP^f$, $PROX^a$, $PROX^b$, CH y $Inter - C$ tienen una alta correlación positiva. La excepción es la Clase C donde: $PROX^a$ está correlacionado únicamente con $COMP^a$; e $Inter - C$ con $COMP^a$, $PROX^a$, $PROX^c$ y CH . En la Clase RC, $COMP^a$ tiene una fuerte correlación con las otras medidas de compacidad, las métricas de proximidad, CH y $Inter - C$. Sin embargo, como sucede con $PROX^a$, el signo de la correlación es negativo. Esto es esperable ya que, según las Ecuaciones 6.1 y 6.7, a medida que aumenta la atracción visual estas métricas disminuyen. En general, $Intra - C$ y CLP están fuertemente correlacionadas entre ellas y, a su vez, están asociadas a numerosas medidas de compacidad, demostrando que los planes con rutas poco compactas, en general, tienen más cruzamientos. Finalmente, BE parece no tener ninguna relación especial con las otra métricas, excepto por la Clase C donde está correlacionada con algunas medidas de compacidad y con CLP .

En la Figura 6.7 puede verse que también en estas instancias existe una fuerte correlación entre $COMP^b$, $COMP^c$, $COMP^d$, $COMP^e$ y $COMP^f$. Sin embargo, comparado con lo que sucede en las instancias GH99, la relación entre estas medidas de compacidad, por un lado, y las métricas $PROX^a$, $PROX^b$, CH y $Inter - C$, por otro, es

casi inexistente (sólo $PROX^b$ presenta una débil asociación). $COMP^a$ está altamente correlacionada con $COMP^b$, $COMP^e$, $COMP^f$ y BE . Además, y a diferencia de los casos de VRPTW, BE tiene una correlación positiva con todas las demás medidas de compacidad y con $PROX^b$. Una vez más, es evidente la fuerte relación que existe entre los pares $Inter - C$ y CH , por un lado, e $Intra - C$ y CLP , por otro.

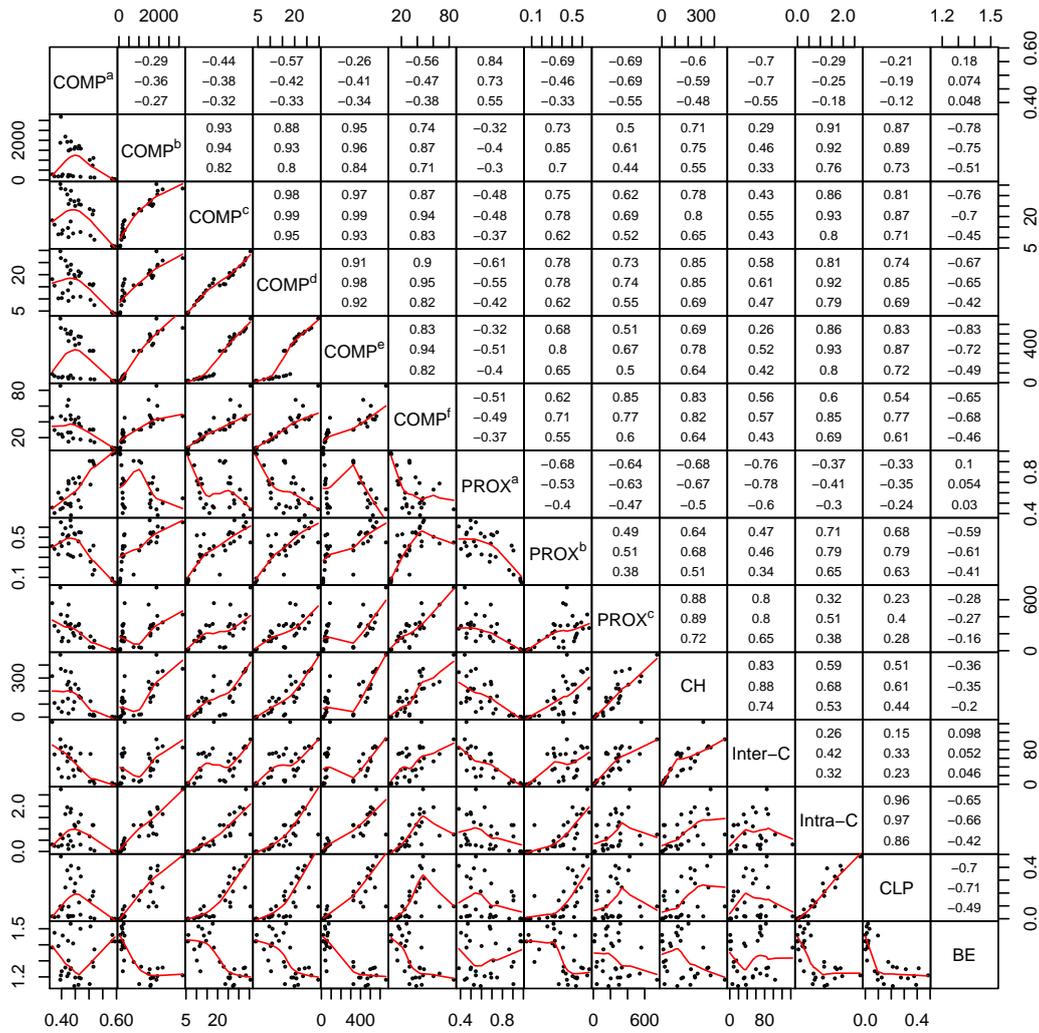


Figura 6.4: Matriz de correlación de la Clase C de las instancias GH99.

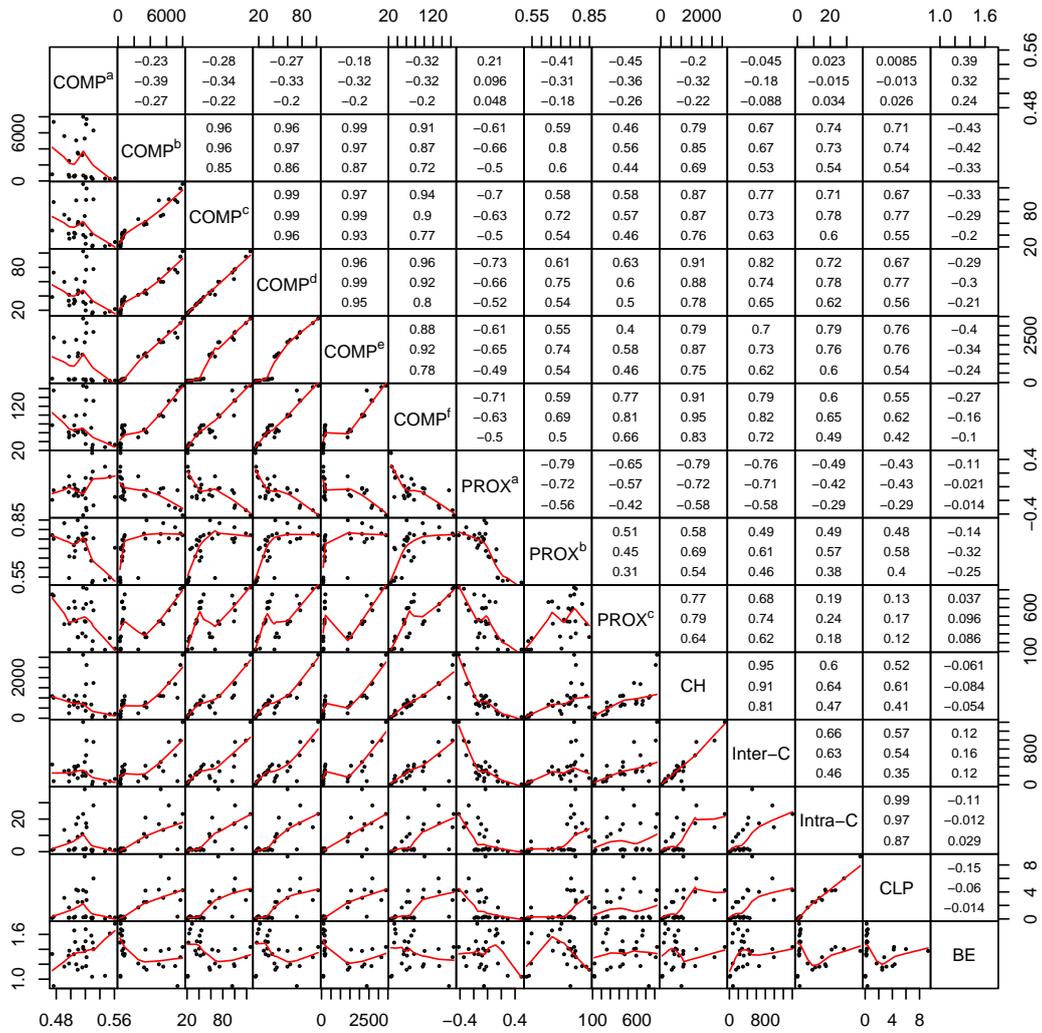


Figura 6.5: Matriz de correlación de la Clase R de las instancias GH99.

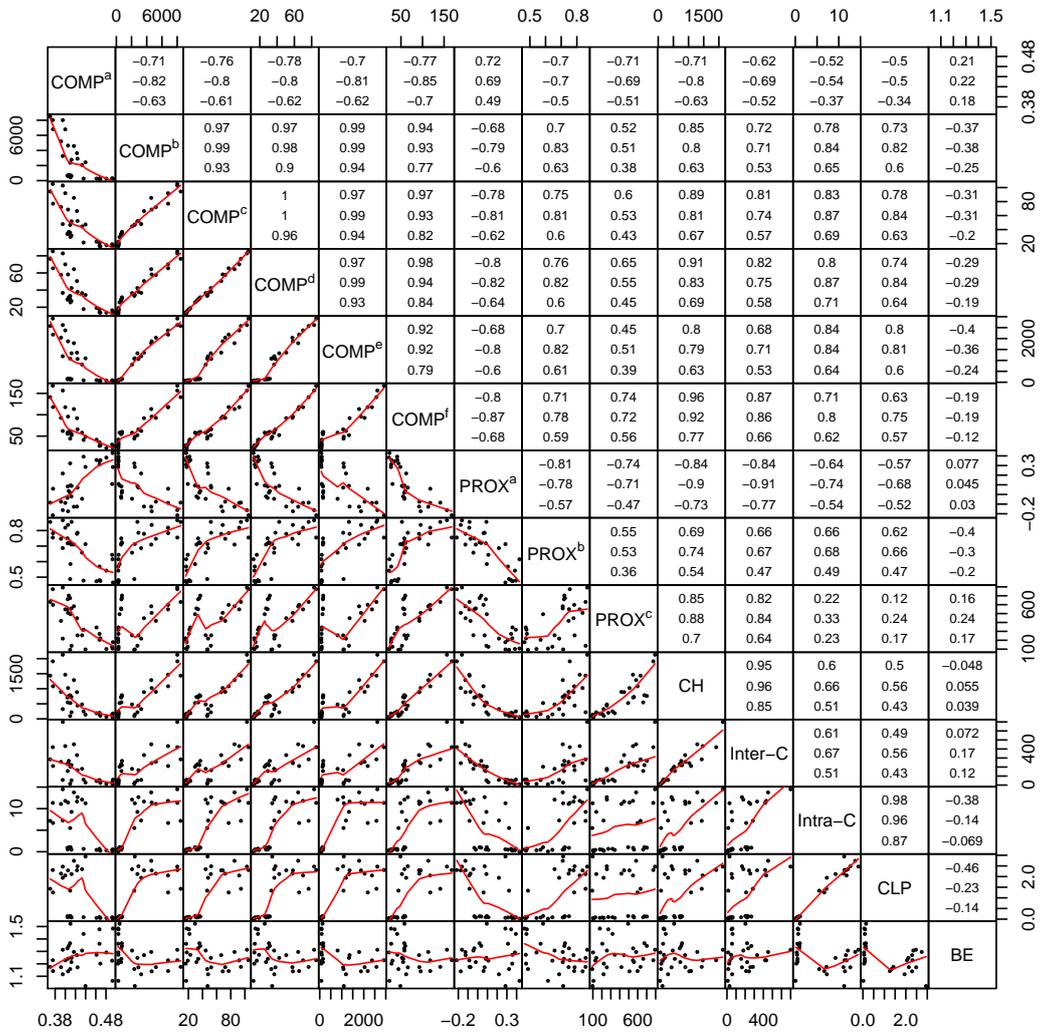


Figura 6.6: Matriz de correlación de la Clase RC de las instancias GH99.

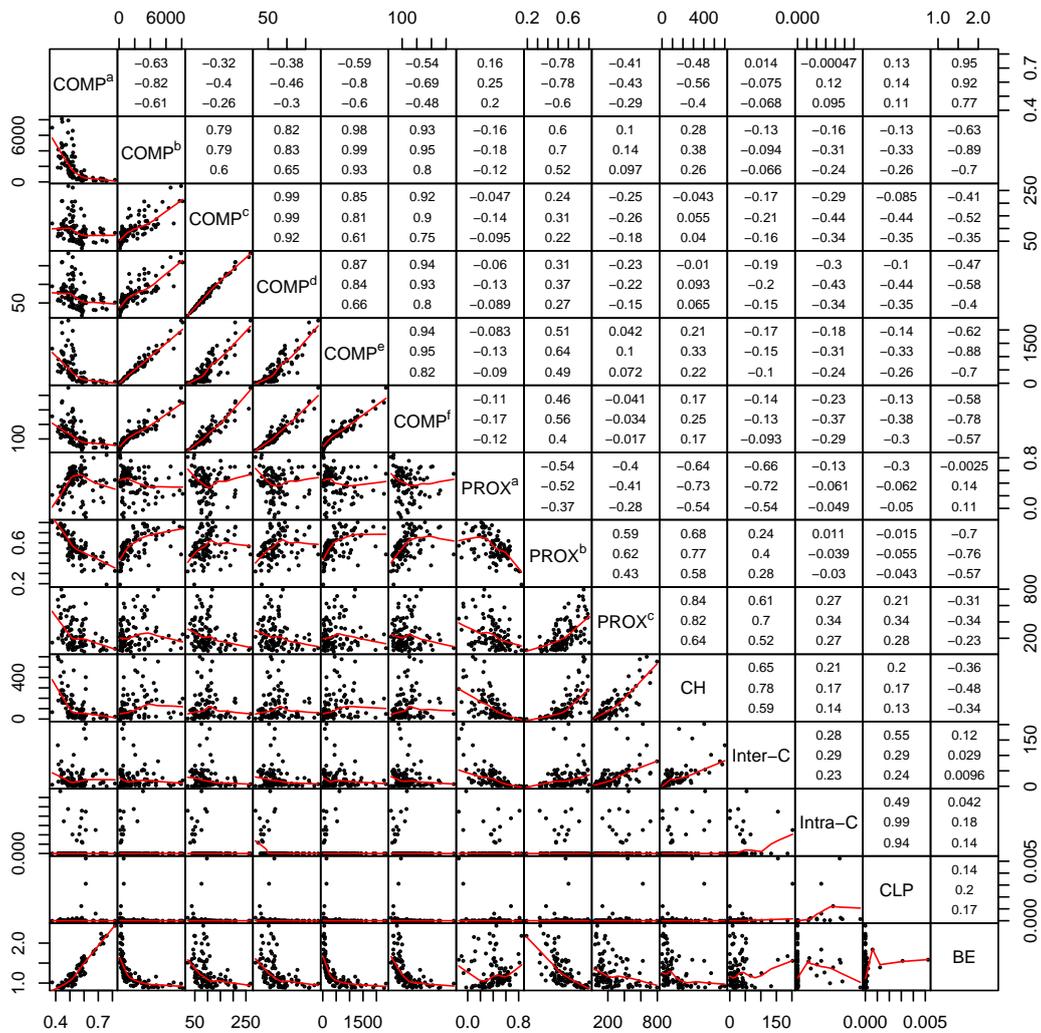


Figura 6.7: Matriz de correlación de las instancias CVRP de Uchoa et al.

6.4.2.2. Ejemplos ilustrativos

Como la atracción visual es un concepto subjetivo se presenta información visual de las soluciones utilizadas para completar el análisis¹. Las soluciones están agrupadas en conjuntos de tres imágenes, presentándose, en general, uno por cada métrica: la Figura 6.8 para $COMP^a$, la Figura 6.9 para $COMP^b$, la Figura 6.11 para $PROX^a$ y la Figura 6.12 para $PROX^b$. Sin embargo, debido a que están fuertemente correlacionadas sólo se presenta una figura para ilustrar $COMP^c$, $COMP^d$, $COMP^e$ y $COMP^f$ (Figura 6.10), $PROX^c$, CH y $Inter - C$ (Figura 6.13) e $Intra - C$ y CLP (Figura 6.14). Los grupos son homogéneos en términos de cantidad de clientes y clase de horizonte de planificación. por ejemplo, en la Figura 6.8 las tres instancias poseen 200 clientes y un horizonte de planificación extenso (tipo 2), permitiendo que muchos clientes sean abastecidos por el mismo vehículo.

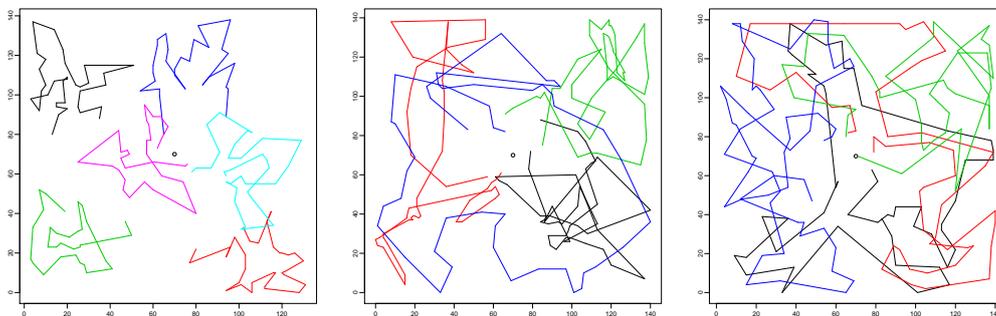


Figura 6.8: De izquierda a derecha se muestran las soluciones para las instancias C2_2_1, RC2_2_3 y R2_2_9 con un valor agradable, intermedio y desagradable de $COMP^a$. Las tres instancias tienen 200 clientes.

¹Se presentan sólo algunas gráficas con fines ilustrativos. El resto de las gráficas se encuentran a disposición previa solicitud al autor.

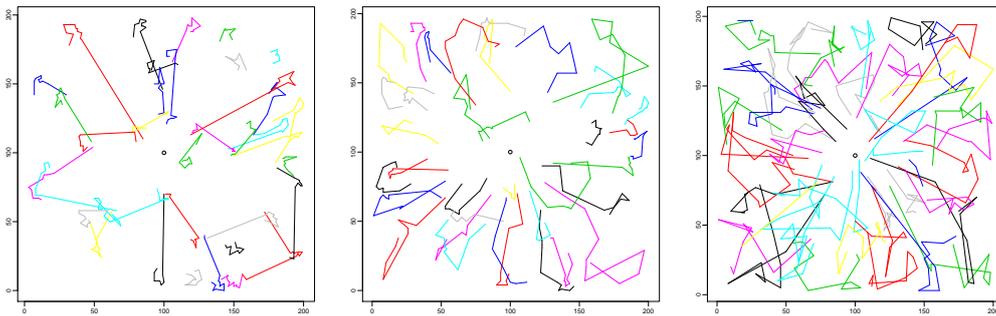


Figura 6.9: De izquierda a derecha se muestran las soluciones para las instancias C1_4_8, RC1_4_10 and R1_4_1 con un valor agradable, intermedio y desagradable de $COMP^b$. Las tres instancias tienen 400 clientes.

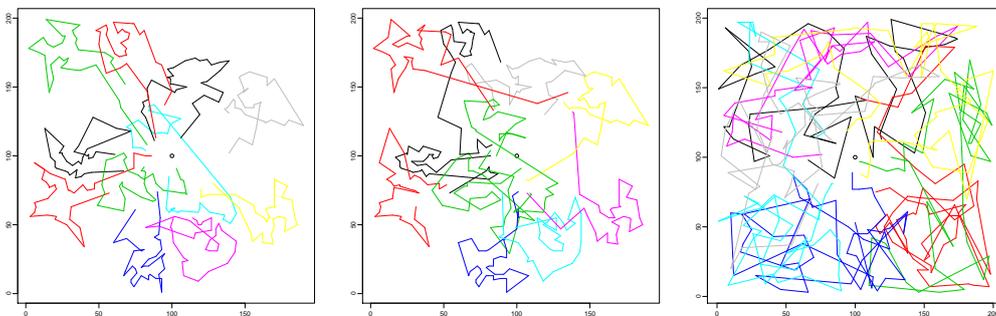


Figura 6.10: De izquierda a derecha se muestran las soluciones para las instancias C2_4_4, C2_4_8 and R2_4_1 con un valor agradable, intermedio y desagradable de $COMP^c$ ($COMP^d$, $COMP^e$ o $COMP^f$). Las tres instancias tienen 400 clientes.

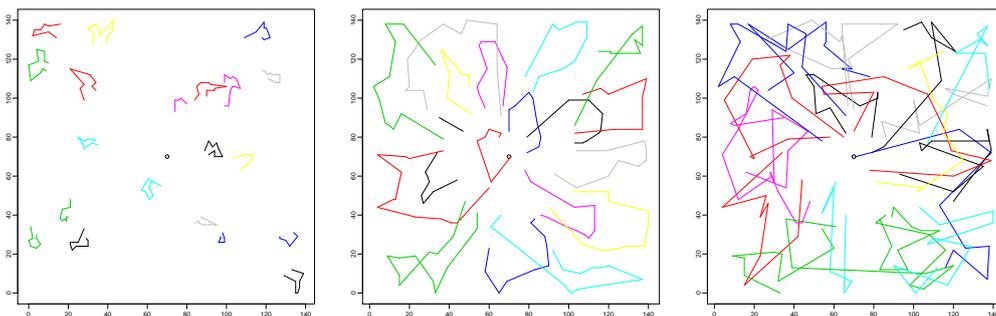


Figura 6.11: De izquierda a derecha se muestran las soluciones para las instancias C1_2_5, R1_2_8 and R1_2_1 con un valor agradable, intermedio y desagradable de $PROX^a$. Las tres instancias tienen 200 clientes.

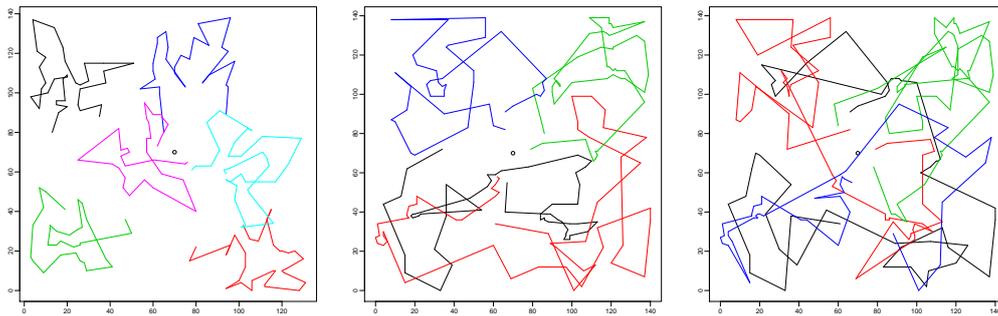


Figura 6.12: De izquierda a derecha se muestran las soluciones para las instancias C2_2_1, RC2_2_8 and RC2_2_6 con un valor agradable, intermedio y desagradable de $PROX^b$. Las tres instancias tienen 200 clientes.

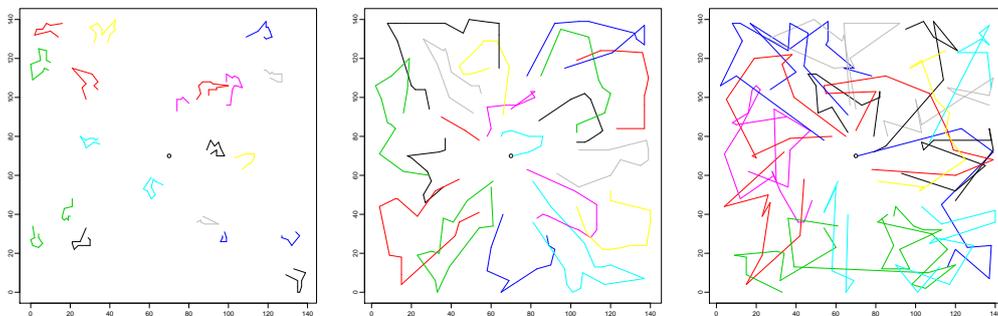


Figura 6.13: De izquierda a derecha se muestran las soluciones para las instancias C1_2_5, R1_2_4 and R1_2_1 con un valor agradable, intermedio y desagradable de $PROX^c$ (CH o $Inter - C$). Las tres instancias tienen 200 clientes.

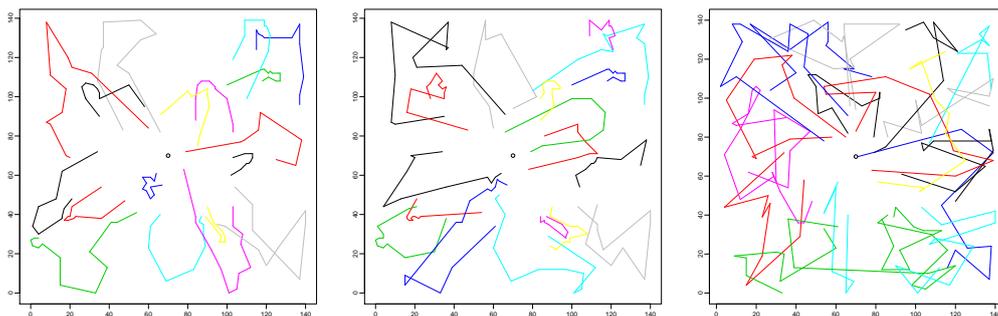


Figura 6.14: De izquierda a derecha se muestran las soluciones para las instancias RC1_2_4, RC1_2_9 and R1_2_1 con un valor agradable, intermedio y desagradable de $Intra - C$ (o CLP). Las tres instancias tienen 200 clientes.

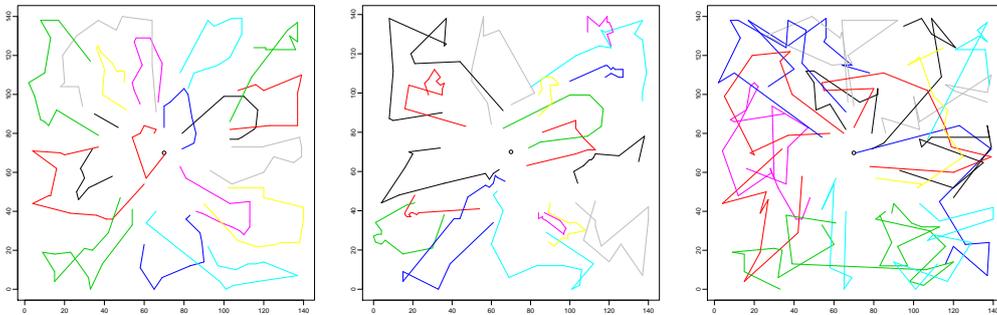


Figura 6.15: De izquierda a derecha se muestran las soluciones para las instancias R1_2_8, RC1_2_9 and R1_2_1 con un valor agradable, intermedio y desagradable de BE . Las tres instancias tienen 200 clientes.

6.4.3. Recomendaciones

Del análisis de correlación experimental desarrollado se desprende la imposibilidad de identificar relaciones inequívocas globales que entre las diferentes métricas que permitan proponer la medida más adecuada para cada característica. Sin embargo, basados en el análisis bibliográfico y las pruebas computacionales pueden proponerse algunas recomendaciones generales:

- La energía de flexión es un concepto particularmente útil en planificación de rutas en ambiente urbanos. En estas planificaciones, las rutas pueden ser repetidas en numerosas ocasiones en un corto periodo de tiempo. Es por esto que las rutas con cambios bruscos de dirección pueden tener un impacto negativo en el desgaste de neumáticos y frenos de los vehículos. Además, muchos giros en los recorridos de los vehículos pueden ocasionar mayores tiempos de viaje si se considera el tiempo adicional requerido para doblar a la izquierda en calles con semáforos (Lacomme et al., 2005). Contrariamente, en planes interurbanos donde un nodo puede representar una ciudad entera y los detalles de los recorridos dentro de la misma no son especificados, la energía de flexión no provee ninguna información valiosa.
- Al menos para el conjunto de instancias analizado en este capítulo no parece demasiado útil utilizar la métrica CLP dado que el número de cruces intra-ruta ($Intra - C$) brinda información similar a un costo computacional menor (véase la Tabla 6.3).
- Debido a que ambas métricas, solapamiento de cascos convexos (CH) y cruces entre rutas ($Inter - C$) proveen información similar y son ambas computacionalmente costosas de calcular parece adecuado sugerir que se elija una de ellas. Sin embargo, de la Tabla 6.3 puede verse que, al menos para nuestra implementación, $Inter - C$ es más rápida de calcular. Adicionalmente, $PROX^c$ tiene un comportamiento similar a ambas métricas y, por lo tanto, puede usarse para aproximarlas.
- Las medidas $COMP^b$, $COMP^c$ y $COMP^d$ generan resultados similares. Debido a que $COMP^b$ and $COMP^d$ requieren conocer las distancias desde el centro de gravedad de la ruta, se recomienda el uso de $COMP^c$ (véase la Tabla 6.3).
- Las métricas $PROX^a$ y $PROX^b$ producen información muy similar. Sin embargo, se recomienda el uso de $PROX^b$ debido a que su cálculo no requiere el conocimiento de las distancias desde el centro de gravedad de la ruta (véase la Tabla 6.3).

Capítulo 7

Heurística para optimizar la atracción visual en un CVRP

Este capítulo tiene como objetivo presentar los resultados de una heurística desarrollada para optimizar la atracción visual de un problema VRP con restricciones de capacidad (CVRP). Se intenta perseguir este objetivo a la vez de deteriorar significativamente otros objetivos cuantitativos como la longitud, siendo esta una de las principales relaciones de compromiso que se evidencian en la literatura. El CVRP fue definido en sus orígenes por Dantzig y Ramser (1959) y es el caso especial de un VRP con una flota homogénea de vehículos que deben servir a un conjunto de clientes y sólo considera las restricciones de capacidad de los vehículos.

7.1. Descripción de la heurística

Un esquema general de la heurística se presenta en la Figura 7.1. La heurística comienza con la construcción de una solución factible inicial. Luego, esta solución es mejorada con operadores de búsqueda local y de reconstrucción. La heurística termina cuando se alcanza el máximo número de iteraciones ($maxIt$ en la Figura 7.1) o cuando para una cantidad determinada de iteraciones consecutivas ($stop = p1\ maxIt$ en la Figura 7.1) no se logra mejorar la solución. Se considera una mejora cuando ocurre algún avance en las métricas de atracción visual utilizadas que no empeora en demasía a la distancia total de la solución.

7.1.1. Aceptación de una nueva solución

Como se ha planteado en el Capítulo 5, puede medirse la atracción visual con diferentes métricas. Para la evaluación de la misma, en esta heurística se utilizan el número de cruces entre rutas $Inter-C$, la métrica de proximidad $PROX^b$, la métrica de compacidad $COMP^b$ y la cantidad de clientes que pertenecen a más de un polígono convexo CH . Nuevamente, para construir el polígono convexo se utiliza el algoritmo de Graham Graham

(1972). Una nueva solución sólo es aceptada, a través de la función *CheckAccep()* de la Figura 7.1, si cumple simultáneamente las siguientes condiciones:

- realiza una mejora considerable en alguno de los criterios de atracción visual mencionados.
- no empeora en demasía alguno de los otros criterios de atracción visual o la longitud total de la ruta.

Estos tres criterios son relativos y dependen de dos parámetros que los regulan. Esto son α para la variación relativa en la mejora que se exige en una medida de la atracción visual y α_w para la variación relativa en el empeoramiento que se permite en el resto de las métricas de atracción visual o la longitud total. α_w puede variar dentro de un rango determinado de forma de favorecer o restringir la aceptación de un cambio a lo largo del proceso de optimización.

7.1.2. Solución inicial

Para construir una solución inicial se utiliza el método propuesto por Kim et al. (2006) (véase la Sección 5.2.1) ya que permite construir una solución atractiva en un corto periodo de tiempo (función *Initial* en Figura 7.1). Una vez que fueron formados los clústeres con esta técnica, el orden de visita dentro de cada ruta se establece con la heurística para TSP desarrollada por Lin y Kernighan (1973) y modificada en Helsgaun (2000) conocida como heurística de Lin-Kernighan-Helsgaun (LKH). Se intenta mejorar la solución inicial con dos procedimientos: búsqueda local y reconstrucción.

7.1.3. Operadores de búsqueda local

La búsqueda local fue realizada a través de cuatro operadores diferentes (función *LS()* de la Figura 7.2). c_{r_A} y $dist(x, y)$ son dos funciones que devuelven el centro de una ruta r_A y la distancia euclidiana entre las coordenadas de x y y , respectivamente. A su vez d_x es la demanda del nodo x y $C(r_A)$ es la función que devuelve la capacidad disponible (libre) del vehículo que sirve la ruta r_A . Entonces se utilizan los siguientes operadores:

1. **Uno-a-Cero.** Este operador selecciona un nodo $x \in r_A$ tal que $d(x, c_{r_A}) < u_x^1$ donde u_x^1 es un cierto valor umbral. Luego, intenta reinsertar a x en una ruta r_B tal que $C(r_B) \geq d_x$ y $d(x, c_{r_B}) < u_x^2$ donde u_x^2 es también un cierto valor umbral. Los valores u_x^1 y u_x^2 dependen del nodo en cuestión y se determinan en función de las distancias del nodo con sus diez vecinos más próximo, dependiendo del parámetro indicado como β en la Figura 7.1. Además, varían a lo largo del proceso de optimización para incentivar o desincentivar este operador.
2. **Uno-a-Uno.** Este operador trabaja de forma análoga que el anterior pero en forma simétrica. Se seleccionan dos nodos $x \in r_A$ e $y \in r_B$ que cumplen las siguientes condiciones $d(x, c_{r_A}) < u_x^1$, $d(y, c_{r_B}) < u_y^1$, $d(x, c_{r_B}) < u_x^2$, $d(y, c_{r_A}) < u_y^2$, $C(r_B) +$

$d_y \geq d_x$ y $C(r_A) + d_x \geq d_y$. El nodo x se inserta en r_B e y en r_A . u_x^1 y u_x^2 se calculan de forma análoga al operador Uno-a-Cero.

3. **Mezclar-y-Separar**. Este operador selecciona dos rutas r_A y r_B que posean al menos dos nodos $x \in r_A$ e $y \in r_B$ que cumplan alguna de las siguientes características:

- a) $d(x, c_{r_A}) > d(x, c_{r_B})$ y $d(y, c_{r_B}) > d(y, c_{r_A})$;
- b) x está incluido en el casco convexo de r_B e y está incluido en el casco convexo de r_A .

Entonces el operador reasigna todos los nodos de ambas rutas. Para esto selecciona el par de nodos que tengan la máxima distancia entre ellos como nodos semilla de las nuevas rutas. Alternadamente, intenta adicionar a cada ruta el cliente más cercano a la semilla. Si una ruta satura su capacidad, entonces se intenta asignar el resto de los nodos a la otra ruta. Este operador reemplazará a las rutas primitivas por las nuevas solamente si se encuentra una asignación factible. Este operador es ligeramente diferente al propuesto por Hollis y Green (2012) ya que no requiere que las semillas pertenezcan a diferentes rutas primitivas.

4. **Cotar-Camino-Largo**. Este operador reconoce un camino que es anormalmente largo e intenta eliminarlo y dividir esta ruta en dos rutas. La definición de lo que es anormalmente largo depende de la máxima distancia existente entre dos clientes de la instancia considerada.
5. **Two-Opt**. Este operador intenta eliminar los cruzamientos al intercambiar las partes de la rutas siempre y cuando este cambio sea factible.

7.1.4. Reconstrucción

Si luego de $p2*maxIt$ iteraciones no se consigue ninguna mejora, se aplica el operador de reconstrucción (función $Rec()$ en la Figura 7.1). Este operador intenta relocalizar los nodos de la ruta con menor demanda ($x \in r_{min}$) siempre y cuando ese valor sea menor a cierto valor límite $minDem$, en otras rutas de acuerdo a las siguientes opciones jerárquicas:

1. mover el nodo x a una ruta r_A tal que $C(r_A) > d(x)$ y $CH(r_A)$ incluya al nodo x . $CH(r_A)$ es el casco convexo de la ruta r_A ;
2. mover el nodo x a una ruta r_A tal que $C(r_A) > d(x)$ y $COMP_{r_A \cup x}^b$ es el mínimo de $\min_{r_I \in K'} COMP_{r_I \cup x}^b$ donde K' es el conjunto de la rutas donde es factible la inclusión de x ;
3. inicializar una nueva ruta y asignar el nodo a ella.

En el último caso, el operador de reconstrucción crea una ruta que posee sólo un nodo asignado. Dada su relativamente pequeña demanda esta ruta tendrá una alta probabilidad

de ser seleccionada por el mismo operador en la siguiente iteración. Para evitar esto se prohíbe a este operador seleccionar las dos últimas rutas creadas.

Cuando una ruta es modificada por un operador, ya sea de búsqueda local o reconstrucción, puede obtenerse una reducción de la distancia reordenando las visitas dentro de la ruta. Por esta razón, se aplica la heurística LKH cada vez que la ruta cambia.

Figura 7.1 Heurística

```

1: procedure HEURÍSTICA( $\beta_i, \beta_{max}, \alpha_i^w, \alpha_{max}^w, \alpha_{min}^w, \alpha, itmax, p_1, p_2, minDem$ )
2:    $S \leftarrow Initial(); BestS \leftarrow S$ 
3:    $i \leftarrow 0; CallRec \leftarrow False; stop \leftarrow p_1 itmax$ 
4:    $\alpha^w \leftarrow \alpha_i^w; \beta \leftarrow \beta_i$ 
5:    $improve \leftarrow notImproving \leftarrow notImprovingGlobal \leftarrow 0$ 
6:   while ( $i < maxIt$  and  $notImprovingGlobal < stop$ ) do
7:      $Change \leftarrow False$ 
8:     if ( $CallRec == False$ ) then
9:        $(S, Change) \leftarrow LS(S, Change, \beta)$ 
10:      if ( $Change == True$  and  $CheckAccep(S, \alpha^w, \alpha) == True$ ) then
11:         $BestS \leftarrow S$ 
12:         $improve ++; notImproving \leftarrow notImprovingGlobal \leftarrow 0$ 
13:      else  $improve \leftarrow 0; notImproving ++; notImprovingGlobal ++$ 
14:    else
15:       $S \leftarrow Rec(S, minDem)$ 
16:    if ( $CallRec == True$ ) then
17:       $improve \leftarrow notImproving \leftarrow 0$ 
18:       $\alpha^w \leftarrow \alpha_i^w; \beta \leftarrow \beta_i;$ 
19:       $CallRec \leftarrow False$ 
20:    else if ( $Change == False$ ) then
21:       $\beta \leftarrow 2\beta$ 
22:      if ( $\beta > \beta_{max}$ ) then  $\beta \leftarrow \beta_{max}$ 
23:    if ( $notImproving > p_2 itmax$ ) then  $CallRec \leftarrow True$ 
24:    else if ( $notImproving > 0,05 itmax$ ) then
25:       $\alpha^w \leftarrow 2\alpha^w$ 
26:      if ( $\alpha^w > \alpha_{max}^w$ ) then  $\alpha^w \leftarrow \alpha_{max}^w$ 
27:    if ( $improve > 0,05 itmax$ ) then
28:       $\alpha^w \leftarrow \frac{\alpha^w}{2}$ 
29:      if ( $\alpha^w < \alpha_{min}^w$ ) then  $\alpha^w \leftarrow \alpha_{min}^w$ 
30:     $i ++$ 

```

Figura 7.2 Búsqueda local

```

1: procedure  $LS(S, Change, \beta)$ 
2:    $w_1 \leftarrow rand(0, 1)$ 
3:   if ( $w_1 == 0$ ) then  $S' \leftarrow UnoaCero(S)$ 
4:   else  $S \leftarrow UnoaUno(S)$ 
5:   if ( $Check(S') == True$ ) then  $S \leftarrow S'; Cambio \leftarrow TRUE$ 
6:    $w_2 \leftarrow rand(0, 2)$ 
7:   if ( $w_2 == 0$ ) then  $S \leftarrow MezclarySeparar(S)$ 
8:   else if ( $w_2 == 1$ ) then  $S \leftarrow CotarCaminoLargo(S, \beta)$ 
9:   else  $S \leftarrow TwoOpt(S, \beta)$ 
10:  if ( $CheckFeasibility(S') == True$ ) then  $S \leftarrow S'; Change \leftarrow True$ 
11:  return ( $S, Change$ )

```

7.2. Experimentación computacional

El algoritmo fue implementado en C++ y se usaron en su experimentación una selección de las instancias de Uchoa et al. (2017). Los resultados se reportan en la Tabla 7.1 y el valor de los parámetros utilizados son $itmax = 40$, $p_1 = 0,4$, $p_2 = 0,1$, $minDem = \frac{Capacity}{3}$, $\beta_i = 0,0001$, $\beta_{max} = 0,001$, $\alpha_i^w = 0,01$, $\alpha_{min}^w = 0,01$, $\alpha_{max}^w = 0,08$, α . Los experimentos se realizaron en una computadora personal con 16GB de RAM, un procesador 3.60GHz y sistema operativo Windows 10 de 64 bits.

Tabla 7.1: Resultados de la heurística y desviación de soluciones selectas reportadas en 2016 para algunas de las instancias de Uchoa et al..

Instancia	Longitud (m) ⁽¹⁾	COMP ^{b(1)}	PROX ^{b(1)}	CH ⁽¹⁾	NC ⁽¹⁾	Tiempo (seg)					
X-n106-k14	27342	3.72%	763.571	-21.77%	0.2345	15.34%	3	-78.57%	4	33.33%	69.1561
X-n120-k6	15227	14.21%	4942.17	-24.98%	0.131	-22.3%	3	-76.92%	0	-100%	49.5705
X-n139-k10	14907	9.69%	2446.1	-23.96%	0.0935	-45.3%	2	-75%	0	-100%	42.0918
X-n143-k7	17484	11.36%	7799.57	-1.52%	0.1637	-27.63%	26	-46.94%	4	-42.86%	46.0452
X-n209-k16	33099	7.97%	2316.44	-7.9%	0.1681	-7.18%	4	-87.1%	1	-88.89%	146.9020
X-n237-k14	29374	8.62%	3141.79	-33.39%	0.1190	-56.54%	6	-75%	1	-66.67%	123.1180
X-n284-k15	23401	15.7%	2927.73	-29.55%	0.2663	-18.34%	27	-84.83%	10	-33.33%	259.468
X-n331-k15	34649	11.4%	3440.93	-45.8%	0.1217	-52.83%	6	-89.47%	0	-100%	183.213
X-n411-k19	24749	25.51%	2498.05	-46.54%	0.2678	-42.01%	78	-71.53%	33	83.33%	239.144
X-n641-k35	69624	9.06%	1857.09	-43.57%	0.1598	-52.2%	39	-81.94%	7	-69.57%	1155.08
X-n801-k40	77832	5.77%	2172.77	-39.17%	0.13	-58.06%	26	-83.23%	1	-95.45%	848.841
X-n1001-k43	79597	9.42%	2559.21	-48.62%	0.1706	-53.85%	83	-85.02%	31	-61.73%	7541.47
Promedio	-	11.04%	-	-30.56%	-	-35.07%	-	-77.96%	-	-53.48%	-

⁽¹⁾La desviación de BKS está en términos porcentuales.

7.2.1. Resultados

En la Tabla 7.1 se presentan para las instancias seleccionadas los resultados obtenidos por la heurística y la respectiva desviación de las BKS en cuanto a longitud y atracción visual, esta última en términos de las métricas descritas en la Sección 7.1.1. Las soluciones heurísticas tienen la misma cantidad de rutas que las BKS. En promedio, la heurística muestra un mejor desempeño en términos de la atracción visual (30,56 %, 35,075 %, 77,96 % y 53,49 % mejor en términos de $COMP^b$, $PROX^b$, CH y $Inter - C$, respectivamente) pero peor en términos de distancia total (11,04 %). La heurística, asimismo, presenta extensos tiempos de cálculo.

La peor desviación de la longitud ocurre en la instancia X-n411-k19 donde la solución heurística es 25,51 % más alta que la BKS. El mayor porcentaje de reducción en $COMP^b$ se obtuvo en X-n1001-k13 (48,62 %) con un deterioro de la longitud de 9,42 %. En la instancia X-n801-k40 se produjo la mayor reducción de $PROX^b$ (58,06 %) con una longitud 5,77 % peor. En cuanto a CH , la máxima mejora relativa fue en la instancia X-n209-k16 (87,1 %) con una longitud 7,97 % mayor que la BKS, Y para el $Inter - C$, la mejor reducción que se logró fue de 100 % en la instancia X-n120-k6 a costa de un empeoramiento de 14,21 % en la longitud. A modo de ejemplo, se presenta el plan de ruteo para la instancia X-n801-k40 en la Figura 7.3. La imagen izquierda es la BKS y la derecha es la obtenida por la heurística. Los caminos iniciales y finales de las rutas (desde y hacia el depósito) no se grafican para claridad de la imagen.

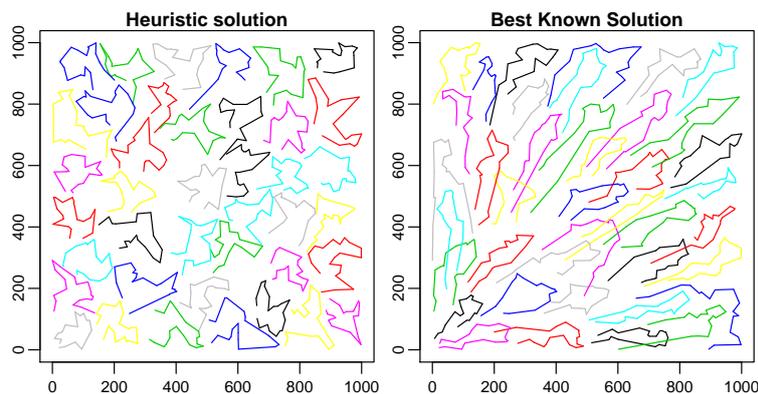


Figura 7.3: Solución para la instancia X-n801-k40. Fuente: Rossit et al. (2016).

7.3. Discusión de resultados

Los resultados obtenidos con la heurística tuvieron un buen desempeño en términos de atracción visual, mejoraron, en general, las cuatro métricas de atracción visual consideradas. Por otro lado, las soluciones halladas presentaron distancias más largas que las BKS conocidas. Sin embargo, para algunas instancias se lograron grandes mejoras de la atracción visual para deterioros relativamente bajos de la longitud. Los tiempos de cálculo fueron extensos. Si bien los resultados obtenidos con esta heurística relativamente simple lograron evidenciar la relación de compromiso entre las métricas tradicionales y

la atracción visual, la misma necesita ser mejorada para ser más competitiva en términos de tiempos de cómputo y longitud de las soluciones.

Parte IV

Conclusiones

Capítulo 8

Conclusión: un intento por resolver problemas reales

El manejo de los residuos en países en desarrollo dista de ser considerado eficiente. La situación aplica a Argentina donde, en general, la tasa de reciclado es muy baja. La separación en origen es algo crucial que facilita el reciclado y la reutilización de los residuos. Esta situación se replica en otros países en vías de desarrollo, que luchan por transformar su sistema de gestión de Residuos Sólidos Urbanos (RSU) en un sistema más sustentable. Esta Tesis trató la aplicación de herramientas de la Investigación Operativa en los elementos iniciales de la cadena logística de RSU. Estas herramientas se enfocaron al estudio de la localización óptima de puntos de acumulación de residuos en donde los ciudadanos pudieran depositar sus desechos y la optimización de la atracción visual en problemas de vehículos, objetivo que ha sido utilizado en la bibliografía sobre diseño de rutas en la gestión de RSU.

Del desarrollo de esta Tesis se destaca un intento por abordar problemáticas reales y cotidianas, que tienen un impacto importante en las actividades humanas. Tanto el diseño de un sistema de contenedores comunitarios eficientes, que soporte recolección diferenciada, y la inclusión de la atracción visual en los problemas de optimización de ruteo, para facilitar disminuir la dificultad en implementación de los planes de ruteo, son temas acuciantes que requieren aún gran cantidad de análisis.

8.1. Localización de contenedores

En cuanto a la primera parte de la Tesis se destaca la propuesta de modelos matemáticos para la localización óptima de contenedores de residuos en un ambiente urbano. Se desarrollaron dos distintos basados en dos casos de aplicación. En ambos, se propusieron diversas soluciones no sólo teniendo en cuenta una minimización de costos sino también optimizar la calidad del servicio. En el caso de Bahía Blanca, se optimizó el costo total del sistema y la distancia promedio entre los usuarios y los contenedores asignados. A pesar de las dificultades que presentaba este caso debido a la falta de datos precisos, se

lograron obtener algunas soluciones y comparar dos métodos diferentes de resolución: el método de las ponderaciones y el método de las ε -restricciones aumentado (AUGMECON2). Debe tenerse en cuenta que la ciudad no cuenta actualmente con un sistema de contenedores comunitarios. El segundo caso se realizó en la ciudad de Montevideo, ciudad que actualmente ya cuenta con un sistema de contenedores comunitarios. A través del intercambio con profesionales de la ciudad y el estudio del caso, se decidió incorporar un tercer objetivo a los dos anteriores de forma de intentar captar la exigencia que produce la frecuencia de recolección requerida por cada contenedor sobre el proceso de recolección. Al ser escenarios más complejos que en el caso de Bahía Blanca, debió modificarse la parte inicial para hallar la matriz de pagos del método AUGMECON2 ya que el método lexicográfico no lograba hallar soluciones factibles en tiempos razonables. A través de un proceso que involucró una primera etapa de optimización monobjetivo y un refinamiento con un método de las ponderaciones desbalanceado, se logró hallar la matriz de pagos y encontrar algunas soluciones multiobjetivo en este problema más complejo.

8.2. Ruteo de vehículos

En la segunda parte se analizaron las rutas de recolección de residuos. Luego de un primer estudio de la bibliografía relacionada, se encontró que en algunos trabajos se incluía un concepto relativamente novedoso y poco desarrollado como era la atracción visual. Al aumentar la profundidad del análisis se hallaron diversas fórmulas propuestas por distintos autores para medir este aspecto. Además, algunos autores utilizaban un concepto similar bajo otra denominación, por ejemplo “compacidad”. Por estas causas, se abordó una extensa revisión bibliográfica sobre la atracción visual en los problemas de ruteo de vehículos (y, por completitud, en los problemas de delimitación de distritos) a los efectos de comprender la relación entre la atracción visual y los objetivos tradicionales, profundizar los aspectos innatos de la percepción humana que dan sustento a este concepto y, asimismo, evaluar su importancia dentro de las aplicaciones prácticas del problema de ruteo de vehículos. Posteriormente, se procedió a comparar las distintas métricas utilizadas en la bibliografía a los efectos de hallar potenciales similitudes entre ellas, utilizándose para ello información gráfica, estadística y de análisis de algoritmos. Con esta información se pudieron realizar algunas recomendaciones sobre cuáles métricas son más adecuadas en distintos tipos de problemas, lo que permitirá a otros autores seleccionar aquellas métricas que mejor se ajusten a sus intereses. Finalmente, se presentó una heurística para optimizar la atracción visual en problemas de ruteo con restricciones de capacidad. Si bien esta heurística es relativamente simple, permitió explorar la relación de compromiso existente entre la atracción visual y un objetivo tradicional como lo es la longitud del recorrido.

8.3. Líneas de trabajo a futuro

Las líneas de trabajo a futuro que se plantean son extender el análisis de localización de instalaciones utilizando técnicas heurísticas que puedan lidiar con instancias más grandes ya que las pruebas que se realizaron sólo incluían sectores limitados de las ciudades. Si bien los modelos presentados en este trabajo permitirían abordar el problema para una ciudad a través de una partición de la misma en sectores más pequeños, resultaría interesante expandir el análisis con la incorporación de heurísticas. Estas heurísticas podrían validarse con los modelos que se presentaron en esta Tesis.

Como tareas pendientes en el ámbito de la atracción visual en los problemas de ruteo de vehículos debería profundizarse la definición conceptual del término de atracción visual a la vez de realizar investigaciones sobre las maneras de integrar eficientemente los objetivos tradicionales, por ejemplo, la minimización de distancias, costos y número de vehículos utilizados, con la atracción visual en los procesos de optimización. Esto se debe a que ni la literatura existente ni la heurística presentada en esta Tesis han respondido de forma completamente satisfactoria aún sobre enfoques que permitan mejorar la atracción visual sin afectar en demasía los objetivos tradicionales.

Finalmente, en muchas ciudades el manejo actual del sistema de RSU se basa en la experiencia y el conocimiento empírico de los tomadores de decisiones. A pesar de que estos factores son invaluable, la literatura es contundente sobre las mejoras que pueden obtenerse a través de la generación de herramientas eficientes que sirvan como sistema de apoyo a la toma de decisiones en la gestión de los RSU. Por esta razón, se considera necesario profundizar el estudio sobre la aplicación de modelos de optimización en este área de la logística inversa de manera de, por un lado, reducir el nivel de inversión necesario y los costos operativos del servicio pero también, por otro lado, promover la sustentabilidad del sistema a través de la disminución de los impactos sociales y ambientales asociados.

Bibliografía

- ACHTERBERG, T. y WUNDERLING, R. Mixed integer programming: Analyzing 12 years of progress. En *Facets of combinatorial optimization* (editado por M. Jünger y G. Reinelt), capítulo 18, páginas 449–481. Springer, Berlin, Germany, 2013.
- ACURIO, G. J., ROSSIN, A., TEIXEIRA, P. F. P. y ZEPEDA PORRAS, F. Diagnosis of municipal solid waste management in Latin America and the Caribbean. Environmental Series 18, Banco Interamericano de Desarrollo y Organización Panamericana de la Salud, Washington D. C, Estado Unidos de América, 1998.
- ADAMS, W. P. y FORRESTER, R. J. A simple recipe for concise mixed 0-1 linearizations. *Operations Research Letters*, vol. 33(1), páginas 55–61, 2005.
- ADAMS, W. P., FORRESTER, R. J. y GLOVER, F. W. Comparisons and enhancement strategies for linearizing mixed 0-1 quadratic programs. *Discrete Optimization*, vol. 1(2), páginas 99–120, 2004.
- ANDERSON, D. R., SWEENEY, D. J., WILLIAMS, T. A., CAMM, J. D. y COCHRAN, J. J. *An introduction to management science: quantitative approaches to decision making*. Cengage learning, Estados Unidos de América, catorceava edición, 2015.
- ANTUNES, C. H., ALVES, M. J. y CLÍMACO, J. *Multiobjective linear and integer programming*, capítulo Formulations and Definitions. Springer, 2016.
- APPLEGATE, D. L., BIXBY, R. E., CHVATAL, V. y COOK, W. J. *The Traveling Salesman Problem: a Computational Study*, capítulo The Problem, páginas 1–58. Princeton University Press, Princeton, Estados Unidos de América, 2011.
- AREMU, A. y SULE, B. A case study evaluation of the impacts of optimised waste bin locations in a developing city. *Civil Engineering and Environmental Systems*, vol. 29(2), páginas 137–146, 2012.
- BALLESTERO, E. y ROMERO, C. *Multiobjective Optimisation Methods*, capítulo 2, páginas 11–30. Springer, Boston, United States, 2013.
- BATTARRA, M., ERDOGAN, G. y VIGO, D. Exact Algorithms for the Clustered Vehicle Routing Problem. *Operations Research*, vol. 62(1), páginas 58–71, 2014.

- BAUTISTA, J. y PEREIRA, J. Modeling the problem of locating collection areas for urban waste management. An application to the metropolitan area of Barcelona. *Omega*, vol. 34(6), páginas 617–629, 2006.
- BEARDWOOD, J., HALTON, J. H. y HAMMERSLEY, J. M. The shortest path through many points. *Mathematical Proceedings of the Cambridge Philosophical Society*, vol. 55(4), páginas 299–327, 1959.
- BELINGUER, J.-M., BENAVENT, E., LACOMME, P. y PRINS, C. Lower and upper bounds for the mixed capacitated arc routing problem. *Computers & Operations Research*, vol. 33(12), páginas 3363–3383, 2006.
- BELIËN, J., DE BOECK, L. y VAN ACKERE, J. Municipal solid waste collection and management problems: a literature review. *Transportation Science*, vol. 48(1), páginas 78–102, 2012.
- BELTON, V., CROWE, D. V., MATTHEWS, R. y SCOTT, S. A survey of public attitudes to recycling in Glasgow (UK). *Waste Management & Research*, vol. 12(4), páginas 351–367, 1994.
- BENES, E. y MILMANDA, B. F. El nuevo liderazgo sindical en la Argentina postneoliberal: el caso del gremio de camioneros. *Desarrollo Económico: Revista de Ciencias Sociales*, vol. 52(205), páginas 31–62, 2012.
- BERGEY, P. K., RAGSDALE, C. T. y HOSKOTE, M. A decision support system for the electrical power districting problem. *Decision Support Systems*, vol. 36(1), páginas 1–17, 2003.
- BERTERO, F. *Optimización de recorridos en ciudades. Una aplicación al sistema de recolección de residuos sólidos urbanos en el Municipio de Concordia*. Tesis de grado, Facultad de Ciencias Exactas, Ingeniería y Agrimensura, Universidad Nacional de Rosario, Rosario, Argentina, 2015.
- BIANCHETTI, M. L. *Algoritmos de zonificación para recolección de residuos*. Tesis de Grado, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires, Buenos Aires, Argentina, 2015.
- BING, X., BLOEMHOF, J. M., RAMOS, T. R. P., BARBOSA-POVOA, A. P., WONG, C. Y. y VAN DER VORST, J. G. Research challenges in municipal solid waste logistics management. *Waste Management*, vol. 48, páginas 584–592, 2016.
- BONOMO, F., DURÁN, G., LARUMBE, F. y MARENCO, J. Optimización de la Recolección de Residuos en la Zona Sur de la Ciudad de Buenos Aires. *Revista de Ingeniería de Sistemas*, vol. 23, 2009.
- BONOMO, F., DURÁN, G., LARUMBE, F. y MARENCO, J. A method for optimizing waste collection using mathematical programming: a Buenos Aires case study. *Waste Management & Research*, vol. 30(3), páginas 311–324, 2012.

- BOSCH, A. *Seed selection in multi-period planning with time windows*. Tesis de Maestría, Faculty of Behavioural, Management and Social Sciences, University of Twente, Enschede, Netherlands, 2014.
- BOSKOVIC, G. y JOVICIC, N. Fast methodology to design the optimal collection point locations and number of waste bins: A case study. *Waste Management & Research*, vol. 33(12), páginas 1094–1102, 2015.
- BOZKAYA, B., ERKUT, E. y LAPORTE, G. A tabu search heuristic and adaptive memory procedure for political districting. *European Journal of Operational Research*, vol. 144(1), páginas 12–26, 2003.
- BRAIER, G., DURÁN, G., MARENCO, J. y WESNER, F. Una aplicación del problema del cartero rural a la recolección de residuos reciclables en argentina. *Revista de Ingeniería de Sistemas*, vol. 29, 2015.
- BRAIER, G., DURÁN, G., MARENCO, J. y WESNER, F. An integer programming approach to a real-world recyclable waste collection problem in argentina. *Waste Management & Research*, vol. 35(5), páginas 525–533, 2017.
- BRÄYSY, O. y HASLE, G. Software Tools and Emerging Technologies for Vehicle Routing and Intermodal Transportation. En *Vehicle Routing: Problems, Methods, and Applications* (editado por P. Toth y D. Vigo), vol. 18, capítulo 12, páginas 351–380. Society for Industrial and Applied Mathematics, segunda edición, 2014.
- BROZ, D., ROSSIT, D. A., ROSSIT, D. G. y CAVALLIN, A. Challenge in supply chains management in Argentina: The case of forestry-industrial sector. En *8th International Conference on Production Research ICPR-AMERICAS'2016*. Universidad Pontificia de Valparaíso, Valparaíso, Chile, 2016.
- BROZ, D., ROSSIT, D. A., ROSSIT, D. G. y CAVALLIN, A. The Argentinian forest sector: opportunities and challenges in supply chain management. *Uncertain Supply Chain Management*, 2018. Estado: en prensa.
- BUTSCH, A., KALCSICS, J. y LAPORTE, G. Districting for arc routing. *INFORMS Journal on Computing*, vol. 26(4), páginas 809–824, 2014.
- CABEZA, D. *Logística inversa en la gestión de la cadena de suministro*. Marge books, Barcelona, España, 2012.
- CARAMIA, M. y DELL'OLMO, P. *Multi-objective Management in Freight Logistics: Increasing Capacity, Service Level and Safety with Optimization Algorithms*, capítulo Multi-objective optimization, páginas 11–36. Springer, Londres, Reino Unido, 2008.
- CAVALLIN, A., FRUTOS, M., VIGIER, H. P. y ROSSIT, D. G. An integrated model of data envelopment analysis and artificial neural networks for improving efficiency in the municipal solid waste management. En *Handbook of Research on Emergent*

- Applications of Optimization Algorithms* (editado por P. Vasant, S. Z. AlparslanGok y G. W. Weber), páginas 206–231. IGI Global, 2017a.
- CAVALLIN, A., ROSSIT, D. A., ROSSIT, D. G., BROZ, D., FRUTOS, M. y LÓPEZ, N. Estrategias de enseñanza para motivar el aprendizaje de los estudiantes en contenidos de Investigación Operativa. *Revista de la Escuela de Perfeccionamiento en Investigación Operativa*, vol. 25(41), 2017b. ISSN 1929-5812.
- CAVALLIN, A. y ROSSIT, D. G. Relevamiento de Municipios de Argentina con Gestión Integral de RSU, 2017. Manuscrito inédito, Departamento de Ingeniería, Universidad Nacional del Sur, Argentina.
- CAVALLIN, A., ROSSIT, D. G., FRUTOS, M. y VIGIER, H. P. Eficiencia en la gestión de residuos sólidos urbanos: Análisis y evaluación. En *VIX Congreso de Ingeniería Industrial*. Facultad de Ingeniería, Universidad Nacional de Salta, Salta, Argentina, 2016. ISBN 978-987-1896-74-5.
- CAVALLIN, A., VIGIER, H. P. y FRUTOS, M. Aplicación de un modelo CVRP-RB a un caso de logística inversa. En *XXVI EPIO y VIII RED-M*, páginas RE247–RE251. Escuela de Perfeccionamiento en Investigación Operativa y Red Ibero-Americana de Evaluación y Decisión Multicriterio, Bahía Blanca, Argentina, 2015a. ISBN 789872426767.
- CAVALLIN, A., VIGIER, H. P. y FRUTOS, M. Logística inversa y ruteo en el sector de recolección informal de residuos sólidos urbanos. En *Avances en Gestión Integral de Residuos Sólidos Urbanos 2014-15* (editado por N. M. Mazzeo y A. M. M. Muzlera Klappenbach), páginas 37–49. Instituto Nacional de Tecnología Industrial, Buenos Aires, Argentina, 2015b. ISBN 9789505322374.
- CHALKIAS, C. y LASARIDI, K. Optimizing municipal solid waste collection using GIS. En *5th International Conference on Energy, Environment, Ecosystems and Sustainable Development-EEESD '09*, páginas 45–50. World Scientific and Engineering Academy and Society, Atenas, Grecia, 2009.
- CHANG, N.-B. y WEI, Y. Strategic planning of recycling drop-off stations and collection network by multiobjective programming. *Environmental Management*, vol. 24(2), páginas 247–263, 1999.
- CHANG, N.-B. y WEI, Y. Siting recycling drop-off stations in urban area by genetic algorithm-based fuzzy multiobjective nonlinear integer programming modeling. *Fuzzy Sets and Systems*, vol. 114(1), páginas 133–149, 2000.
- CLARKE, G. y WRIGHT, J. W. Scheduling of Vehicles from a Central Depot to a Number of Delivery Points. *Operations Research*, vol. 12(4), páginas 568–581, 1964.
- CONSTANTINO, M., GOUVEIA, L., MOURÃO, M. C. y NUNES, A. C. The mixed capacitated arc routing problem with non-overlapping routes. *European Journal of Operational Research*, vol. 244(2), páginas 445–456, 2015.

- CORNUEJOLS, G., NEMHAUSER, G. L. y WOLSEY, L. A. The uncapacitated facility location problem. Research Report ADA140000, Carnegie-Mellon University, Pittsburgh, Estados Unidos de América, 1983.
- CORNUÉJOLS, G., SRIDHARAN, R. y THIZY, J.-M. A comparison of heuristics and relaxations for the capacitated plant location problem. *European Journal of Operational Research*, vol. 50(3), páginas 280–297, 1991.
- COUTINHO-RODRIGUES, J., TRALHÃO, L. y ALÇADA-ALMEIDA, L. A bi-objective modeling approach applied to an urban semi-desirable facility location problem. *European Journal of Operational Research*, vol. 223(1), páginas 203–213, 2012.
- DANTZIG, G. B. y RAMSER, J. H. The truck dispatching problem. *Management Science*, vol. 6(1), páginas 80–91, 1959.
- DE ASSIS, L. S., FRANCA, P. M. y USBERTI, F. L. A redistricting problem applied to meter reading in power distribution networks. *Computers & Operations Research*, vol. 41, páginas 65–75, 2014.
- DE BRITO, M. P. y DEKKER, R. *A framework for reverse logistics*, capítulo 1, páginas 3–27. Springer, 2004.
- DESAULNIERS, G., MADSEN, O. B. y ROPKE, S. The Vehicle Routing Problem with Time Windows. En *Vehicle Routing: Problems, Methods, and Applications* (editado por P. Toth y D. Vigo), vol. 18, capítulo 5, páginas 119–159. Society for Industrial and Applied Mathematics, segunda edición, 2014.
- DI FELICE, P. Integration of spatial and descriptive information to solve the urban waste accumulation problem. *Procedia-Social and Behavioral Sciences*, vol. 147, páginas 182–188, 2014a.
- DI FELICE, P. Integration of spatial and descriptive information to solve the urban waste accumulation problem: A pilot study. *Procedia-Social and Behavioral Sciences*, vol. 147, páginas 592–597, 2014b.
- DIRECCIÓN PROVINCIAL DE ESTADÍSTICA DE LA PROVINCIA DE BUENOS AIRES, ARGENTINA. Censo 2010 Provincia de Buenos Aires Resultados Definitivos por Partido. Informe técnico, 2010.
- DRY, M., PREISS, K. y WAGEMANS, J. Clustering, Randomness and Regularity: Spatial Distributions and Human Performance on the Traveling Salesperson Problem and Minimum Spanning Tree Problem. *The Journal of Problem Solving*, vol. 4(1), página 2, 2012.
- EHRGOTT, M. y RYAN, D. M. Constructing robust crew schedules with bicriteria optimization. *Journal of Multi-Criteria Decision Analysis*, vol. 11(3), páginas 139–150, 2002.

- EHRGOTT, M. y TENFELDE-PODEHL, D. Computation of ideal and nadir values and implications for their use in mcdm methods. *European Journal of Operational Research*, vol. 151(1), páginas 119–139, 2003.
- EUGSTER, M. J. A. y SCHLESINGER, T. osmar: OpenStreetMap and R. *The R Journal*, vol. 5(1), páginas 53–63, 2013.
- FLAHAUT, B., LAURENT, M.-A. y THOMAS, I. Locating a community recycling center within a residential area: a Belgian case study. *The Professional Geographer*, vol. 54(1), páginas 67–82, 2002.
- FLEISCHMANN, M., BLOEMHOF-RUWAARD, J. M., DEKKER, R., VAN DER LAAN, E., VAN NUNEN, J. A. y VAN WASSENHOVE, L. N. Quantitative models for reverse logistics: A review. *European Journal of Operational Research*, vol. 103(1), páginas 1–17, 1997.
- FLOOD, M. M. The traveling-salesman problem. *Operations Research*, vol. 4(1), páginas 61–75, 1956.
- FRAHI, C., FRUTOS, M. y ROSSIT, D. G. Desarrollo de nuevas tecnologías de gestión para resolver problemas de distribución de bienes o prestación de servicios. En *XXV Jornadas de Jóvenes Investigadores de la Asociación de Universidades Grupo Montevideo*. Asociación de Universidades del Grupo Montevideo e Universidad Nacional de Itapúa, Paraguay, Encarnación, Paraguay, 2017.
- GALLARDO, A., BOVEA, M. D., COLOMER, F. J., PRADES, M. y CARLOS, M. Comparison of different collection systems for sorted household waste in Spain. *Waste Management*, vol. 30(12), páginas 2430–2439, 2010.
- GALLARDO, A., CARLOS, M., PERIS, M. y COLOMER, F. Methodology to design a municipal solid waste pre-collection system. A case study. *Waste management*, vol. 36, páginas 1–11, 2015.
- GANDARA, M. P. y GUERRERO, E. M. Indicadores ambientales para la gestión de los residuos sólidos domiciliarios en Rosario, Argentina. *DELLOS*, vol. 6(16), 2013.
- GAREY, M. R. y JOHNSON, D. S. *Computers and intractability: a guide to the theory of NP-completeness*. Freeman, Nueva York, EEUU, 1979.
- GASS, S. I. y ASSAD, A. A. *An annotated timeline of operations research: An informal history*, vol. 75 de *International series in Operations Research and Management Science*. Springer, Estados Unidos de América, 2005.
- GAUTAM, A. y KUMAR, S. Strategic planning of recycling options by multi-objective programming in a GIS environment. *Clean Technologies and Environmental Policy*, vol. 7(4), páginas 306–316, 2005.

- GEHRELS, B., LALANDE, B., LOSKOT, M., WULKIEWICZ, A. y KARAVELAS, M. Geometry:Algorithms:Convex Hull. En *Boost 1.64.0 Library Documentation*. 2017.
- [DATASET] GEHRING, H. y HOMBERGER, J. Gehring and Homberger '99 VRPTW Benchmarck. En *Vehicle Routing Problem Repository*. 1999.
- GEHRING, H. y HOMBERGER, J. A parallel hybrid evolutionary metaheuristic for the vehicle routing problem with time windows. En *EUROGEN 99-Short course on evolutionary algorithms in engineering and computer science* (editado por K. Miettinen, M. Mäkelä y J. Toivanene), páginas 57–64. University of Jyväskylä, Jyväskylä, Finlandia, 1999.
- GHIANI, G., LAGANÀ, D., MANNI, E., MUSMANNO, R. y VIGO, D. Operations research in solid waste management: A survey of strategic and tactical issues. *Computers & Operations Research*, vol. 44, páginas 22–32, 2014a.
- GHIANI, G., LAGANÀ, D., MANNI, E. y TRIKI, C. Capacitated location of collection sites in an urban waste management system. *Waste Management*, vol. 32(7), páginas 1291–1296, 2012.
- GHIANI, G., MANNI, A., MANNI, E. y TORALDO, M. The impact of an efficient collection sites location on the zoning phase in municipal solid waste management. *Waste Management*, vol. 34(11), páginas 1949–1956, 2014b.
- GIBBONS, J. D. y CHAKRABORTI, S. *One-Sample and Paired-Sample Procedures*, capítulo 5, páginas 156–230. Springer, 2011.
- GLOVER, F. Improved linear integer programming formulations of nonlinear integer problems. *Management Science*, vol. 22(4), páginas 455–460, 1975.
- GLOVER, F. An improved MIP formulation for products of discrete and continuous variables. *Journal of Information and Optimization Sciences*, vol. 5(1), páginas 69–71, 1984.
- GLOVER, F. y WOOLSEY, E. Further reduction of zero-one polynomial programming problems to zero-one linear programming problems. *Operations Research*, vol. 21(1), páginas 156–161, 1973.
- GLOVER, F. y WOOLSEY, E. Converting the 0-1 polynomial programming problem to a 0-1 linear program. *Operations Research*, vol. 22(1), páginas 180–182, 1974.
- GOLDEN, B. L., ASSAD, A. A. y WASIL, E. A. Routing vehicles in the real world: applications in the solid waste, beverage, food, dairy, and newspaper industries. En *The vehicle routing problem* (editado por P. Toth y D. Vigo), páginas 245–286. SIAM, Philadelphia, Estados Unidos de América, 2002.

- GÓMEZ MARTÍN, M. A. y GÓMEZ MARTÍN, P. P. Tesis: Una plantilla de latex para tesis y otros documentos. Informe técnico, Departamento de Ingeniería del Software e Inteligencia Artificial, Facultad de Informática, Universidad Complutense de Madrid, 2009.
- GONZÁLEZ, G. L. Residuos sólidos urbanos. Argentina. Tratamiento y disposición final situación actual y alternativas futuras. Informe técnico, Cámara Argentina de la Construcción, 2010.
- GONZÁLEZ-RAMÍREZ, R. G., SMITH, N. R., ASKIN, R. G., MIRANDA, P. A. y SÁNCHEZ, J. M. A hybrid metaheuristic approach to optimize the districting design of a parcel company. *Journal of Applied Research and Technology*, vol. 9(1), páginas 19–35, 2011.
- GONZÁLEZ-TORRE, P. L., ADENSO-DÍAZ, B. y RUIZ-TORRES, A. Some comparative factors regarding recycling collection systems in regions of the USA and Europe. *Journal of Environmental Management*, vol. 69(2), páginas 129–138, 2003.
- GOOGLE EARTH PRO. Barrio Trouville de Montevideo, Uruguay. 2017a. Versión del software = 7.3.1. Fecha de imagen: 20/ene/2015. Altura de ojo: 1,54 km. Coordenadas aproximadas posición central: 34° 55'06.07" S 56° 09'05.71" O.
- GOOGLE EARTH PRO. Sector céntrico de Bahía Blanca, Argentina. 2017b. Versión del software = 7.3.1 Digital Globe 2017. Fecha de imagen: 12/nov/2017. Altura de ojo: 3,46 km. Coordenadas aproximadas posición central: 38° 42'53.36" S 62° 16'13.97" O.
- GOULART COELHO, L. M., LANGE, L. C. y COELHO, H. M. Multi-criteria decision making to support waste management: A critical review of current practices and methods. *Waste Management & Research*, vol. 35(1), páginas 3–28, 2017.
- GRAHAM, R. L. An efficient algorithm for determining the convex hull of a finite planar set. *Information Processing Letters*, vol. 1(4), páginas 132–133, 1972.
- GRETTON, C. y KILBY, P. A Study of Shape Penalties in Vehicle Routing. En *VIII Triennial Symposium on Transportation Analysis*. San Pedro de Atacama, Chile, 2013.
- GUERRERO, L. A., MAAS, G. y HOGLAND, W. Solid waste management challenges for cities in developing countries. *Waste Management*, vol. 33(1), páginas 220–232, 2013.
- GUILTINAN, J. P. y NWOKOYE, N. G. Developing distribution channels and systems in the emerging recycling industries. *International Journal of Physical Distribution*, vol. 6(1), páginas 28–38, 1975.
- HAIMES, Y. Y., LASDON, L. S. y WISMER, D. A. On a bicriterion formulation of the problems of integrated system identification and system optimization. *IEEE transactions on systems, man, and cybernetics*, vol. 1(3), páginas 296–297, 1971.

- HAN, H. y PONCE CUETO, E. Waste collection vehicle routing problem: literature review. *PROMET-Traffic&Transportation*, vol. 27(4), páginas 345–358, 2015.
- HANNAN, M., AL MAMUN, M. A., HUSSAIN, A., BASRI, H. y BEGUM, R. A. A review on technologies and their usage in solid waste monitoring and management systems: Issues and challenges. *Waste Management*, vol. 43, páginas 509–523, 2015.
- HASLE, G., KLOSTER, O. y SMEDSRUD, M. Aspects of routing problems in media product distribution. En *24th European Conference on Operational Research*. EURO, Lisbon, Portugal, 2010.
- HASLE, G., KLOSTER, O. y SMEDSRUD, M. A Capacitated Clustering-based Method for Newspaper Delivery Routing. En *International Federation of Operational Research Societies 2011*. IFORS, Melbourne, Australia, 2011.
- HELGAUN, K. An effective implementation of the lin–kernighan traveling salesman heuristic. *European Journal of Operational Research*, vol. 126(1), páginas 106–130, 2000.
- HEMMELMAYR, V. C., DOERNER, K. F., HARTL, R. F. y VIGO, D. Models and algorithms for the integrated planning of bin allocation and vehicle routing in solid waste management. *Transportation Science*, vol. 48(1), páginas 103–120, 2013.
- HENRY, J. G. y HEINKE, G. W. *Ingeniería ambiental*, capítulo Residuos Sólidos, páginas 567–619. Pearson Educación, Ciudad de México, México, 1999.
- HILLIER, F. y HILLIER, M. *Introduction to Management Science: A Modeling and Case Studies Approach With Spreadsheets*. McGraw-Hill Higher Education, quinta edición, 2013.
- HOLLIS, B. L. y GREEN, P. J. Real-life vehicle routing with time windows for visual attractiveness and operational robustness. *Asia-Pacific Journal of Operational Research*, vol. 29(04), página 1250017, 2012.
- HONORABLE CONGRESO DE LA NACIÓN ARGENTINA. Ley 25916. Publicada en el Boletín Oficial de la República Argentina del 7-sep-2004, 2004.
- HONORABLE CONSEJO DELIBERANTE DE BAHÍA BLANCA, ARGENTINA. Ordenanza 18101. Publicada en el Digesto Municipal de Bahía Blanca del 10-mar-2015, 2015.
- HOORNWEG, D. y BHADA-TATA, P. What a waste: a Global Review of Solid Waste Management. Urban Development Series Knowledge Papers 15, World Bank, Washington D. C., Estados Unidos de América, 2012.
- HOORNWEG, D., BHADA-TATA, P. y KENNEDY, C. Environment: Waste production must peak this century. *Nature*, vol. 502(7473), páginas 615–617, 2013.
- HOORNWEG, D., BHADA-TATA, P. y KENNEDY, C. Peak waste: When is it likely to occur? *Journal of Industrial Ecology*, vol. 19(1), páginas 117–128, 2015.

- HUA, T. M., NGUYEN, T. K., VAN DINH THI, H. y THI, N. A. N. Towards a decision support system for municipal waste collection by integrating geographical information system map, smart devices and agent-based model. En *7th Symposium on Information and Communication Technology*, páginas 139–146. Association for Computing Machinery, 2016.
- HWANG, C.-L. y MASUD, A. S. M. *Multiple objective decision making—methods and applications: a state-of-the-art survey*, vol. 164. Springer, 2012.
- INSTITUTO NACIONAL DE ESTADÍSTICA DE URUGUAY. Censos 2011. 2011.
- INTENDENCIA DE MONTEVIDEO. Sistema de recolección de residuos domiciliarios con contenedores. ????. <http://www.montevideo.gub.uy/servicios-y-sociedad/limpiezaservicios-y-sociedad/limpieza/sistema-de-recoleccion-de-residuos-domiciliarios-con-contenedores>, Febrero 2018.
- INTERNATIONAL BUSINESS MACHINES CORPORATION. Multithreaded parallel optimizers. En *IBM ILOG CPLEX Optimization Studio User's Manual Version 12 Release 7*, capítulo 28, páginas 371–381. 2016.
- IRNICH, S., TOTH, P. y VIGO, D. The Family of Vehicle Routing Problems. En *Vehicle Routing: Problems, Methods, and Applications* (editado por P. Toth y D. Vigo), vol. 18, capítulo 1, páginas 1–36. Society for Industrial and Applied Mathematics, segunda edición, 2014.
- JANG, W., LIM, H. H., CROWE, T. J., RASKIN, G. y PERKINS, T. E. The Missouri Lottery Optimizes Its Scheduling and Routing to Improve Efficiency and Balance. *Interfaces*, vol. 36(4), páginas 302–313, 2006.
- JARRAH, A. I. y BARD, J. F. Large-scale pickup and delivery work area design. *Computers & Operations Research*, vol. 39(12), páginas 3102–3118, 2012.
- KALCSICS, J. Districting Problems. En *Location Science* (editado por G. Laporte, S. Nickel y F. Saldanha da Gama), capítulo 23, páginas 595–622. Springer, 2015.
- KANT, G., JACKS, M. y AANTJES, C. Coca-Cola Enterprises Optimizes Vehicle Routes for Efficient Product Delivery. *Interfaces*, vol. 38(1), páginas 40–50, 2008.
- KAO, J.-J. y LIN, T.-I. Shortest service location model for planning waste pickup locations. *Journal of the Air & Waste Management Association*, vol. 52(5), páginas 585–592, 2002.
- KARADIMAS, N. V., MAVRANTZA, O. D. y LOUMOS, V. G. GIS integrated waste production modeling. En *EUROCON 2005 - The International Conference on "Computer as a Tool"*, vol. 2, páginas 1279–1282. Institute of Electrical and Electronics Engineers, 2005.

- KARP, R. M. Reducibility among Combinatorial Problems. En *Complexity of Computer Computations*, páginas 85–103. Springer, Boston, Estados Unidos de América, 1972.
- KENDALL, M. G. A new measure of rank correlation. *Biometrika*, vol. 30(1/2), páginas 81–93, 1938.
- KENNEDY, C. A., RAMASWAMI, A., CARNEY, S. y DHAKAL, S. Greenhouse gas emission baselines for global cities and metropolitan regions. En *Cities and climate change: Responding to an Urgent Agenda* (editado por D. Hoornweg, M. Freire, M. J. Lee, P. Bhada-Tata y B. Yuen), páginas 15–54. Washington D. C., Estados Unidos de América, 2011.
- KILBY, P., PROSSER, P. y SHAW, P. Guided Local Search for the Vehicle Routing Problem with Time Windows. En *Meta-Heuristics: Advances and Trends in Local Search Paradigms for Optimization* (editado por S. Voß, S. Martello, I. H. Osman y C. Roucairol), capítulo 32, páginas 473–486. Springer, 1999.
- KILBY, P. y VERDEN, A. Flexible routing combining constraint programming, large neighbourhood search, and feature-based insertion. En *II Workshop on Artificial Intelligence and Logistics-AILOG '11*, páginas 43–49. Barcelona, España, 2011.
- KIM, B. I., KIM, S. y SAHOO, S. Balanced Clustering Algorithms for Improving Shapes on Vehicle Routing Problems. En *Institute of Industrial Engineers Annual Conference 2004*. Institute of Industrial and Systems Engineers, Houston, Estados Unidos de América, 2004.
- KIM, B. I., KIM, S. y SAHOO, S. Waste collection vehicle routing problem with time windows. *Computers & Operations Research*, vol. 33(12), páginas 3624–3642, 2006.
- KINOBE, J. R., GEBRESENBET, G. y VINNERÅS, B. Reverse logistics related to waste management with emphasis on developing countries-a review paper. *Journal of Environmental Science and Engineering. B*, vol. 1(9B), página 1104, 2012.
- KUNG, H.-T., LUCCIO, F. y PREPARATA, F. P. On finding the maxima of a set of vectors. *Journal of the ACM (JACM)*, vol. 22(4), páginas 469–476, 1975.
- LACOMME, P., PRINS, C. y RAMDANE-CHÉRIF, W. Evolutionary algorithms for periodic arc routing problems. *European Journal of Operational Research*, vol. 165(2), páginas 535–553, 2005.
- LARRUMBE, F. *Optimización de la Recolección de Residuos en la Zona Sur de la Ciudad de Buenos Aires*. Tesis de Grado, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires, Buenos Aires, Argentina, 2009.
- LARSEN, K. H. *Synchronization of vehicles in a waste collection network*. Tesis de maestría, Department of Economics and Business, Aarhus University, Aarhus, Denmark, 2015.

- LEBERSORGER, S. y BEIGL, P. Municipal solid waste generation in municipalities: Quantifying impacts of household structure, commercial waste and domestic fuel. *Waste Management*, vol. 31(9), páginas 1907–1915, 2011.
- LEE, M. D. y VICKERS, D. The importance of the convex hull for human performance on the traveling salesman problem: A comment on MacGregor and Ormerod (1996). *Perception & Psychophysics*, vol. 62(1), páginas 226–228, 2000.
- LEGISLATURA DE LA CIUDAD AUTÓNOMA DE BUENOS AIRES, ARGENTINA. Ley 1854. Publicada en el Boletín Oficial de la Ciudad Autónoma de Buenos Aires del 24-nov-2005, 2005.
- LEI, H., LAPORTE, G. y GUO, B. Districting for routing with stochastic customers. *EURO Journal on Transportation and Logistics*, vol. 1(1-2), páginas 67–85, 2012.
- LENSTRA, J. y KAN, A. Complexity of vehicle routing and scheduling problems. *Networks*, vol. 11(2), páginas 221–227, 1981.
- LI, H. y LIM, A. A metaheuristic for the pickup and delivery problem with time windows. En *13th IEEE International Conference on Tools with Artificial Intelligence-ICTAI '01*, páginas 160–167. Institute of Electrical and Electronics Engineers Computer Society, Washington D. C., Estados Unidos de América, 2001. ISBN 0-7695-1417-0.
- LI, J., CHU, F., PRINS, C. y ZHU, Z. Lower and upper bounds for a two-stage capacitated facility location problem with handling costs. *European Journal of Operational Research*, vol. 236(3), páginas 957–967, 2014.
- LIN, H.-Y. y KAO, J.-J. Subregion Districting Analysis for Municipal Solid Waste Collection Privatization. *Journal of the Air & Waste Management Association*, vol. 58(1), páginas 104–111, 2008.
- LIN, H.-Y., TSAI, Z.-P., CHEN, G.-H. y KAO, J.-J. A model for the implementation of a two-shift municipal solid waste and recyclable material collection plan that offers greater convenience to residents. *Journal of the Air & Waste Management Association*, vol. 61(1), páginas 55–62, 2011.
- LIN, S. y KERNIGHAN, B. W. An effective heuristic algorithm for the traveling-salesman problem. *Operations Research*, vol. 21(2), páginas 498–516, 1973.
- LINDELL, M. K. y EARLE, T. C. How close is close enough: Public perceptions of the risks of industrial facilities. *Risk Analysis*, vol. 3(4), páginas 245–253, 1983.
- LÓPEZ-PÉREZ, J. F. y RÍOS-MERCADO, R. Z. Embotelladoras ARCA Uses Operations Research to Improve Territory Design Plans. *Interfaces*, vol. 43(3), páginas 209–220, 2013.
- LU, Q. y DESSOUKY, M. M. A new insertion-based construction heuristic for solving the pickup and delivery problem with time windows. *European Journal of Operational Research*, vol. 175(2), páginas 672–687, 2006.

- MAC EACHREN, A. M. Compactness of Geographic Shape: Comparison and Evaluation of Measures. *Geografiska Annaler. Series B. Human Geography*, páginas 53–67, 1985.
- MAC GREGOR, J. N. Indentations and starting points in traveling sales tour problems: implications for theory. *The Journal of Problem Solving*, vol. 5(1), página 3, 2012.
- MAC GREGOR, J. N. Effects of cluster location and cluster distribution on performance on the traveling salesman problem. *Attention, Perception, & Psychophysics*, vol. 77(7), páginas 2491–2501, 2015.
- MAC GREGOR, J. N., CHRONICLE, E. P. y ORMEROD, T. C. Convex hull or crossing avoidance? Solution heuristics in the traveling salesperson problem. *Memory & Cognition*, vol. 32(2), páginas 260–270, 2004.
- MAC GREGOR, J. N. y CHU, Y. Human performance on the traveling salesman and related problems: A review. *The Journal of Problem Solving*, vol. 3(2), página 2, 2011.
- MAC GREGOR, J. N. y ORMEROD, T. Human performance on the traveling salesman problem. *Perception & Psychophysics*, vol. 58(4), páginas 527–539, 1996.
- MARLER, R. T. y ARORA, J. S. The weighted sum method for multi-objective optimization: new insights. *Structural and Multidisciplinary Optimization*, vol. 41(6), páginas 853–862, 2010.
- MARTIN, M., WILLIAMS, I. D. y CLARK, M. Social, cultural and structural influences on household waste recycling: A case study. *Resources, Conservation and Recycling*, vol. 48(4), páginas 357–395, 2006.
- MATIS, P. Decision support system for solving the street routing problem. *Transport*, vol. 23(3), páginas 230–235, 2008.
- MATIS, P. Creation of New Distribution Network—Distribution of Mail in Slovak Republic. *PROMET - Traffic & Transportation*, vol. 22(6), páginas 413–418, 2010.
- MATIS, P. y KOHÁNI, M. Very large street routing problem with mixed transportation mode. *Central European Journal of Operations Research*, vol. 19(3), páginas 359–369, 2011.
- MAVROTAS, G. Effective implementation of the ε -constraint method in multi-objective mathematical programming problems. *Applied mathematics and computation*, vol. 213(2), páginas 455–465, 2009.
- MAVROTAS, G. y FLORIOS, K. An improved version of the augmented ε -constraint method (AUGMECON2) for finding the exact pareto set in multi-objective integer programming problems. *Applied Mathematics and Computation*, vol. 219(18), páginas 9652–9669, 2013.

- MAVROTAS, G., GAKIS, N., SKOULAXINOY, S., KATSOUROS, V. y GEORGOPOULOU, E. Municipal solid waste management and energy production: Consideration of external cost through multi-objective optimization and its effect on waste-to-energy solutions. *Renewable and Sustainable Energy Reviews*, vol. 51, páginas 1205–1222, 2015.
- MEHROTRA, A., JOHNSON, E. L. y NEMHAUSER, G. L. An Optimization Based Heuristic for Political Districting. *Management Science*, vol. 44(8), páginas 1100–1114, 1998.
- MÉNDEZ, A., PALUMBO, D., CARNERO, M. y HERNÁNDEZ, J. Algoritmos meméticos aplicados a la resolución de un problema de ruteo de vehículos periódico. *Mecánica Computacional*, vol. 28, páginas 2675–2685, 2009.
- MÉNDEZ, A., PONTIN, M., ZILETTI, M., CARNERO, M. y HERNÁNDEZ, J. Recolección de residuos patógenos. un enfoque evolutivo híbrido. *Mecánica Computacional*, vol. 23, páginas 3079–3089, 2004.
- MÉNDEZ, A., SIMÓN, S., PALUMBO, D., CHIACHERA, E. y CARNERO, M. Dos enfoques para la solución del problema de ruteo de vehículos (CVRP): aplicación a un caso real de recolección de residuos. *Mecánica Computacional*, vol. 29, páginas 9367–9377, 2010.
- MÉNDEZ, M., ÁLAMO, A. L., FRUTOS, M. y AGUASCA, R. Fundamentos de Ayuda Multicriterio a la Decisión. páginas 10–23, 2014.
- MINISTERIO DE MEDIO AMBIENTE Y DESARROLLO SUSTENTABLE, ARGENTINA. Mapas críticos gestión de residuos. 2016.
- MINISTERIO DE VIVIENDA, ORDENAMIENTO TERRITORIAL Y MEDIO AMBIENTE. *Plan de gestión de Montevideo para la recuperación de residuos de envases no retornables*. Gobierno de Uruguay, Montevideo, Uruguay, 2012. Disponible en http://www.ciu.com.uy/innovaportal/file/49856/1/pge_montevideo_plan_2012-08-24_definitivo.pdf (último acceso, Diciembre,2017).
- MONGE, E. C. El estudio de casos como metodología de investigación y su importancia en la dirección y administración de empresas. *Revista Nacional de administración*, vol. 1(2), páginas 31–54, 2010.
- MOURÃO, M. C., NUNES, A. C. y PRINS, C. Heuristic methods for the sectoring arc routing problem. *European Journal of Operational Research*, vol. 196(3), páginas 856–868, 2009.
- MOURGAYA, M. y VANDERBECK, F. Column generation based heuristic for tactical planning in multi-period vehicle routing. *European Journal of Operational Research*, vol. 183(3), páginas 1028–1041, 2007.
- MUYLDERMANS, L., CATTRYSE, D. y VAN OUDHEUSDEN, D. District design for arc-routing applications. *Journal of the Operational Research Society*, vol. 54, páginas 1209–1221, 2003.

- NESMACHNOW, S., ROSSIT, D. G. y TOUTOUH, J. Comparison of Multiobjective Evolutionary Algorithms for Prioritized Urban Waste Collection in Montevideo, Uruguay. *Electronic Notes in Discrete Mathematics*, vol. 69, páginas 93–100, 2018.
- NIEMI, R. G., GROFMAN, B., CARLUCCI, C. y HOFELLER, T. Measuring Compactness and the Role of a Compactness Standard in a Test for Partisan and Racial Gerrymandering. *The Journal of Politics*, vol. 52(4), páginas 1155–1181, 1990.
- ORMEROD, T. C. y CHRONICLE, E. P. Global perceptual processing in problem solving: The case of the traveling salesperson. *Perception & Psychophysics*, vol. 61(6), páginas 1227–1238, 1999.
- PARROT, L., SOTAMENOU, J. y DIA, B. K. Municipal solid waste management in Africa: Strategies and livelihoods in Yaoundé, Cameroon. *Waste Management*, vol. 29(2), páginas 986–995, 2009.
- PEARSON, K. Mathematical contributions to the theory of evolution. III. Regression, heredity, and panmixia. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 187, páginas 253–318, 1896.
- PERRIER, N., LANGEVIN, A. y CAMPBELL, J. F. The sector design and assignment problem for snow disposal operations. *European Journal of Operational Research*, vol. 189(2), páginas 508–525, 2008.
- PLANTA PILOTO DE INGENIERÍA QUÍMICA, UNIVERSIDAD NACIONAL DEL SUR (UNS)-CONICET. *Análisis Estadístico de los Residuos Sólidos Domiciliarios de Bahía Blanca*. Bahía Blanca, Argentina, 2013.
- PODER LEGISLATIVO DE LA PROVINCIA DE BUENOS AIRES, ARGENTINA. Ley 13592. Publicada en el Boletín Oficial de la Provincia de Buenos Aires 26-jul-2010, 2010.
- POOT, A., KANT, G. y WAGELMANS, A. P. M. A savings based method for real-life vehicle routing problems. *Journal of the Operational Research Society*, vol. 53, páginas 57–68, 2002.
- PRADHAN, P. K., MOHANTY, C. R., SWAR, A. K. y MOHAPATRA, P. Urban solid waste management of Guwahati city in north-east India. *Journal of Urban and Environmental Engineering*, vol. 6(2), páginas 67–73, 2012.
- PURKAYASTHA, D., MAJUMDER, M. y CHAKRABARTI, S. Collection and recycle bin location-allocation problem in solid waste management: A review. *Pollution*, vol. 1(2), páginas 175–191, 2015.
- REEVES, G. R. y REID, R. C. Minimum values over the efficient set in multiple objective decision making. *European Journal of Operational Research*, vol. 36(3), páginas 334–338, 1988.

- REINELT, G. TSPLIB-A Traveling Salesman Problem Library. *ORSA Journal on Computing*, vol. 3(4), páginas 376–384, 1991.
- RICCA, F. y SIMEONE, B. Local search algorithms for political districting. *European Journal of Operational Research*, vol. 189(3), páginas 1409–1426, 2008.
- RÍOS-MERCADO, R. Z. y ESCALANTE, H. J. GRASP with path relinking for commercial districting. *Expert Systems with Applications*, vol. 44, páginas 102–113, 2016.
- RÍOS-MERCADO, R. Z. y LÓPEZ-PÉREZ, J. F. Commercial territory design planning with realignment and disjoint assignment requirements. *Omega*, vol. 41(3), páginas 525–535, 2013.
- ROPKE, S. y PISINGER, D. An adaptive large neighborhood search heuristic for the pickup and delivery problem with time windows. *Transportation Science*, vol. 40(4), páginas 455–472, 2006.
- ROSSIT, D. A., BROZ, D., CAVALLIN, A., ROSSIT, D. G. y FRUTOS, M. Importancia de la investigación operativa en la formación del ingeniero industrial como agente de mejora de las cadenas de suministro. En *VIII Congreso de Ingeniería Industrial*. Asociación Argentina de Carreras de Ingeniería Industrial, Córdoba, Argentina, 2015a. ISBN 9789871896509.
- ROSSIT, D. G., BROZ, D., ROSSIT, D. A., CAVALLIN, A., FRUTOS, M. y TOHMÉ, F. Diseño de una red de recolección alternativa de residuos plásticos en un área urbana densamente poblada en base a optimización multiobjetivo. En *XXVI Reunión Argentina de Ecología*. Asociación Argentina de Ecología, Comodoro Rivadavia, Argentina, 2014. ISBN 9789871937.
- ROSSIT, D. G., BROZ, D., ROSSIT, D. A., FRUTOS, M. y TOHMÉ, F. Modelado de una red urbana de recolección de residuos plásticos en base a optimización multi-objetivo. En *XXVI EPIO y VIII RED-M*, páginas TC96–TC110. Escuela de Perfeccionamiento en Investigación Operativa y Red Ibero-Americana de Evaluación y Decisión Multicriterio, Bahía Blanca, Argentina, 2015b. ISBN 789872426767.
- ROSSIT, D. G., BROZ, D., ROSSIT, D. A., FRUTOS, M. y TOHMÉ, F. Una herramienta logística para la localización de contenedores de residuos separados en origen. En *Avances en Gestión Integral de Residuos Sólidos Urbanos 2014-15* (editado por N. M. Mazzeo y A. M. M. Muzlera Klappenbach), páginas 50–69. Instituto Nacional de Tecnología Industrial, Buenos Aires, Argentina, 2015c. ISBN 9789505322374.
- ROSSIT, D. G., NESMACHNOW, S., MASSOBRIO, R., TOUTOUH, J. y TOHMÉ, F. A multiobjective model to optimize the location of garbage accumulation points in a real-world case. En *Escuela de Computación de Alto Rendimiento ECAR 2017*. Centro de Simulación Computacional para Aplicaciones Tecnológicas CSC-CONICET, Universidad de Buenos Aires y Universidad de Tres de Febrero, Buenos Aires, Argentina, 2017a.

- ROSSIT, D. G., TOHMÉ, F., FRUTOS, M. y BROZ, D. An application of the augmented ε -constraint method to design a municipal sorted waste collection system. *Decision Science Letters*, vol. 6(4), páginas 323–336, 2017b.
- ROSSIT, D. G., VIGO, D., TOHMÉ, F. y FRUTOS, M. Improving Visual Attractiveness in Capacitated Vehicle Routing Problems: a Heuristic Algorithm. En *XVIII Latin-Iberoamerican Conference on Operations Research-CLAIO'2016*, páginas 749–756. Asociación Latino-Iberoamericana de Investigación Operativa, Santiago de Chile, Chile, 2016.
- SÁEZ, A. y URDANETA, J. A. Manejo de residuos sólidos en América Latina y el Caribe. *Omnia*, vol. 20(3), páginas 121–135, 2014.
- SAHOO, S., KIM, S., KIM, B. I., KRAAS, B. y POPOV JR, A. Routing Optimization for Waste Management. *Interfaces*, vol. 35(1), páginas 24–36, 2005.
- SALAZAR-AGUILAR, M. A., RÍOS-MERCADO, R. Z., GONZÁLEZ-VELARDE, J. L. y MOLINA, J. Multiobjective scatter search for a commercial territory design problem. *Annals of Operations Research*, vol. 199(1), páginas 343–360, 2012.
- SAVELSBERGH, M. W. P. A parallel insertion heuristic for vehicle routing with side constraints. *Statistica Neerlandica*, vol. 44(3), páginas 139–148, 1990.
- SCHEJTMAN, L. y CELLUCCI, M. Gestión integral de residuos sólidos urbanos: Políticas municipales que promueven la sustentabilidad. Serie Buenas Prácticas Municipales 3, Fundación Centro de Implementación de Políticas Públicas para la Equidad y el Crecimiento CIPPEC, 2014.
- SCHIVELY, C. Understanding the NIMBY and LULU phenomena: Reassessing our knowledge base and informing future research. *CPL bibliography*, vol. 21(3), páginas 255–266, 2007.
- SCHNEIDER, M., STENGER, A., SCHWAHN, F. y VIGO, D. Territory-Based Vehicle Routing in the Presence of Time-Window Constraints. *Transportation Science*, vol. 49(4), páginas 732–751, 2014.
- SECRETARÍA DE AMBIENTE Y DESARROLLO SUSTENTABLE. Estrategia Nacional para la Gestión Integral de Residuos Sólidos Urbanos. Informe técnico, Gobierno de Argentina, Ciudad Autónoma de Buenos Aires, Argentina, 2005.
- SECRETARÍA DE AMBIENTE Y DESARROLLO SUSTENTABLE. Sistema de Indicadores de Desarrollo Sostenible. Informe técnico, Gobierno de Argentina, Ciudad Autónoma de Buenos Aires, Argentina, 2015.
- SERVICIO DE GEOMÁTICA, INTENDENCIA DE MONTEVIDEO, URUGUAY. Sistema de Información Geográfica. 2017. Disponible en <http://sig.montevideo.gub.uy/> (último acceso, Diciembre, 2017).

- SIMÓN, S., DEMALDÉ, J., HERNÁNDEZ, J. y CARNERO, M. Optimización de recorridos para la recolección de residuos infecciosos. *Información tecnológica*, vol. 23(4), páginas 125–132, 2012.
- SOLOMON, M. M. Algorithms for the Vehicle Routing and Scheduling Problems with Time Window Constraints. *Operations Research*, vol. 35(2), páginas 254–265, 1987.
- SOLTANI, A., HEWAGE, K., REZA, B. y SADIQ, R. Multiple stakeholders in multi-criteria decision-making in the context of municipal solid waste management: a review. *Waste Management*, vol. 35, páginas 318–328, 2015.
- SPEARMAN, C. The proof and measurement of association between two things. *The American Journal of Psychology*, vol. 15(1), páginas 72–101, 1904.
- TAHA, H. A. A Balasian-based algorithm for zero-one polynomial programming. *Management Science*, vol. 18(6), páginas B–328, 1972.
- TAI, J., ZHANG, W., CHE, Y. y FENG, D. Municipal solid waste source-separated collection in china: A comparative analysis. *Waste Management*, vol. 31(8), páginas 1673–1682, 2011.
- TAILLARD, É., BADEAU, P., GENDREAU, M., GUERTIN, F. y POTVIN, J.-Y. A tabu search heuristic for the vehicle routing problem with soft time windows. *Transportation Science*, vol. 31(2), páginas 170–186, 1997.
- TANG, H. y HU, M. Dynamic vehicle routing problem with multiple objectives: Solution framework and computational experiments. *Transportation Research Record: Journal of the Transportation Research Board*, (1923), páginas 199–207, 2005.
- TANG, H. y MILLER-HOOKS, E. Interactive Heuristic for Practical Vehicle Routing Problem with Solution Shape Constraints. *Transportation Research Record: Journal of the Transportation Research Board*, vol. 1964, páginas 9–18, 2006.
- TCHOBANOGLIOUS, G., KREITH, F. y WILLIAMS, M. E. Introduction. En *Handbook of solid waste management* (editado por G. Tchobanoglous y F. Kreith), capítulo 1. McGraw-Hill, Estados Unidos de América, segunda edición, 2002.
- TOTH, P. y VIGO, D. *The vehicle routing problem*. Society for Industrial and Applied Mathematics, Philadelphia, Estados Unidos de América, 2002.
- TOTH, P. y VIGO, D. *Vehicle Routing: Problems, Methods, and Applications*, vol. 18. Society for Industrial and Applied Mathematics, Philadelphia, Estados Unidos de América, segunda edición, 2014.
- TOUTOUH, J., ROSSIT, D. G. y NESMACHNOW, S. Computational intelligence for locating garbage accumulation points in urban scenarios. *Lecture Notes in Computer Science*, 2018. Estado: aceptado, pendiente publicación.

- TRALHÃO, L., COUTINHO-RODRIGUES, J. y ALÇADA-ALMEIDA, L. A multiobjective modeling approach to locate multi-compartment containers for urban-sorted waste. *Waste Management*, vol. 30(12), páginas 2418–2429, 2010.
- TRANSPORTATION OPTIMIZATION PORTAL OF THE NORWEGIAN FOUNDATION FOR SCIENTIFIC AND INDUSTRIAL RESEARCH (SINTEF, *Stiftelsen for industriell og teknisk forskning*). Best Known Solutions of Gehring and Homberger VRPTW benchmark. 2017. Disponible en <http://www.sintef.no/projectweb/top/vrptw/homberger-benchmark/> (último acceso, Diciembre, 2017).
- TROSCHINETZ, A. M. y MIHELICIC, J. R. Sustainable recycling of municipal solid waste in developing countries. *Waste management*, vol. 29(2), páginas 915–923, 2009.
- TUFRÓ, V., CHALDE, J. I., CAMPOS, R. I. y PÉREZ TOSCANI, M. A local model for a global problem. The case of the city of Salta, Argentina. En *International Solid Waste Association Congress ISWA 2012*. Florencia, Italia, 2012.
- [DATASET] UCHOA, E., PECIN, D., PESSOA, A., POGGI, M., VIDAL, T. y SUBRAMANIAN, A. Uchoa et al. 2014 CVRP Benchmark. En *Capacitated Vehicle Routing Problem Library*. 2014.
- UCHOA, E., PECIN, D., PESSOA, A., POGGI, M., VIDAL, T. y SUBRAMANIAN, A. New benchmark instances for the capacitated vehicle routing problem. *European Journal of Operational Research*, vol. 257(3), páginas 845–858, 2017.
- VALEO, C., BAETZ, B. W. y TSANIS, I. K. Location of recycling depots with GIS. *Journal of Urban Planning and Development*, vol. 124(2), páginas 93–99, 1998.
- VAN ROOIJ, I., STEGE, U. y SCHAETMAN, A. Convex hull and tour crossings in the Euclidean traveling salesperson problem: Implications for human performance studies. *Memory & Cognition*, vol. 31(2), páginas 215–220, 2003.
- VICKERS, D., BUTAVICIUS, M., LEE, M. y MEDVEDEV, A. Human performance on visually presented Traveling Salesman problems. *Psychological Research*, vol. 65(1), páginas 34–45, 2001.
- VICKERS, D., LEE, M. D., DRY, M. y HUGHES, P. The roles of the convex hull and the number of potential intersections in performance on visually presented traveling salesperson problems. *Memory & Cognition*, vol. 31(7), páginas 1094–1104, 2003.
- VICKERS, D., LEE, M. D., DRY, M., HUGHES, P. y MCMAHON, J. A. The aesthetic appeal of minimal structures: Judging the attractiveness of solutions to traveling salesperson problems. *Perception & Psychophysics*, vol. 68(1), páginas 32–42, 2006.
- VIJAY, R., GAUTAM, A., KALAMDHAD, A., GUPTA, A. y DEVOTTA, S. GIS-based locational analysis of collection bins in municipal solid waste management systems. *Journal of Environmental Engineering and Science*, vol. 7(1), páginas 39–43, 2008.

- VIJAY, R., GUPTA, A., KALAMDHAD, A. S. y DEVOTTA, S. Estimation and allocation of solid waste to bin through Geographical Information Systems. *Waste Management & Research*, vol. 23(5), páginas 479–484, 2005.
- VIVES, H. F., JAROMEZUK, A., RISSETTO, M. A., ROBUSTELLI, G. R., VILLALBA, M. E. y DA SILVA, P. M. Ergonomía comparativa entre la tarea de recolector de residuos tradicional y el recolector de contenedores. En *V Congreso de Ingeniería Industrial*. Asociación Argentina de Carreras de Ingeniería Industrial, Lomas de Zamora, Argentina, 2012. ISBN 9789874549037.
- WILSON, D. C., VELIS, C. y CHEESEMAN, C. Role of informal sector recycling in waste management in developing countries. *Habitat international*, vol. 30(4), páginas 797–808, 2006.
- WONG, K. y BEASLEY, J. Vehicle routing using fixed delivery areas. *Omega*, vol. 12(6), páginas 591–600, 1984.
- YANIK, S., SÜRER, Ö. y ÖZTAYŞI, B. Designing sustainable energy regions using genetic algorithms and location-allocation approach. *Energy*, vol. 97, páginas 161–172, 2016.
- YOUNG, H. P. Measuring the compactness of legislative districts. *Legislative Studies Quarterly*, vol. 13(1), páginas 105–115, 1988.
- YOUNG, I. T., WALKER, J. E. y BOWIE, J. E. An analysis technique for biological shape. I. *Information and Control*, vol. 25(4), páginas 357–370, 1974.
- ZADEH, L. Optimality and non-scalar-valued performance criteria. *IEEE Transactions on Automatic Control*, vol. 8(1), páginas 59–60, 1963.
- ZAMORANO, M., MOLERO, E., GRINDLAY, A., RODRÍGUEZ, M., HURTADO, A. y CALVO, F. A planning scenario for the application of geographical information systems in municipal waste collection: A case of Churriana de la Vega (Granada, Spain). *Resources, Conservation and Recycling*, vol. 54(2), páginas 123–133, 2009.
- ZELENY, M. A concept of compromise solutions and the method of the displaced ideal. *Computers & Operations Research*, vol. 1(3-4), páginas 479–496, 1974.
- ZHANG, W. y REIMANN, M. A simple augmented ε -constraint method for multi-objective mathematical integer programming problems. *European Journal of Operational Research*, vol. 234(1), páginas 15–24, 2014.
- ZHOU, C., TAN, Y., LIAO, L. y LIU, Y. Solving the Multi-vehicle Pick-up and Delivery Problem with Time Windows by New Construction Heuristic. En *Sixth International Conference on Intelligent Systems Design and Applications*, vol. 2, páginas 1035–1042. Institute of Electrical and Electronics Engineers, Jinan, China, 2006.
- ZHUANG, Y., WU, S.-W., WANG, Y.-L., WU, W.-X. y CHEN, Y.-X. Source separation of household waste: a case study in China. *Waste Management*, vol. 28(10), páginas 2022–2030, 2008.