

Recolección de Residuos Tecnológicos aplicando Metaheurísticas

Technological Waste Collection applying Metaheuristics

Diana Pérez, Daniel Pandolfi, Andrea Villagra

{dperez, dpandolfi, avillagra}@uaco.unpa.edu.ar

Laboratorio de Tecnologías Emergentes (LabTEM)

Instituto de Tecnología Aplicada (ITA) - Unidad Académica Caleta Olivia

Universidad Nacional de la Patagonia Austral

Recibido: 27/11/2020. Aceptado: 25/06/2021

RESUMEN

La creciente demanda en el uso de las tecnologías de la información y comunicación (TIC) han revolucionado nuestra vida cotidiana, sin embargo, han contribuido a aumentar las preocupaciones ambientales y sociales. La aceleración de factores como el agotamiento y escasez de recursos, daños ambientales, uso de agua y energía y un incremento insostenible de desechos tecnológicos principalmente en zonas urbanas, se ha convertido en una preocupación para la industria y el gobierno. La recuperación de residuos tecnológicos requiere de estrategias inteligentes de recolección que minimicen los costos asociados, maximicen el reúso de materias primas y la reparabilidad de los bienes para la prolongación de su vida útil. Uno de los factores que inciden fuertemente, es el costo de recorrido para la recolección.

Este trabajo consiste en generar rutas de recolección dado una cantidad de clientes por atender, un conjunto de vehículos de recolección, permitiendo minimizar ciertos factores que ayuden a la empresa a obtener beneficios. Los objetivos pueden ser: minimizar el tiempo de reparto, maximizar el ahorro de combustible en los vehículos, minimizar la cantidad de vehículos de reparto, todo lo cual llevaría a obtener menores costos y por lo tanto obtener beneficios y una mejor calidad de servicio e imagen. Particularmente, el propósito de este trabajo es mostrar como la aplicación de un algoritmo basado en inteligencia colectiva (metaheurística) mejora la planificación de recolección de residuos tecnológicos para un caso de estudio en la localidad de Comodoro Rivadavia sobre con diferentes escenarios e instancias de recolección con 75, 105, 150 y 200 contenedores de residuos y vehículos con diferentes capacidades. Se realiza además un análisis de la reducción de gases emitidos.

Palabras clave: Problema de Ruteo de Vehículos; Inteligencia Colectiva; Residuos Tecnológicos; Metaheurísticas.

ABSTRACT

The growing demand in the use of information and communication technologies (ICT) has revolutionized our daily lives, however, they have contributed to increasing environmental and social concerns. The acceleration of factors such as the depletion and scarcity of resources, environmental damage, use of water and energy, and an unsustainable increase in technological waste, mainly in urban areas, has become a concern for industry and the government. The recovery of technological waste requires intelligent collection strategies that



minimize associated costs, maximize the reuse of raw materials, and the reparability of goods to extend their useful life. One of the factors that have a strong influence is the cost of travel for the collection.

This work consists of generating collection routes given several clients to attend, a set of collection vehicles, allowing to minimize certain factors that help the company to obtain benefits. The objectives can be minimize delivery time, maximize fuel savings in vehicles, minimize the number of delivery vehicles, all of which would lead to lower costs and therefore obtain benefits and a better quality of service and image. In particular, the purpose of this work is to show how the application of an algorithm based on collective intelligence (metaheuristics) improves the planning of technological waste collection for a case study in the town of Comodoro Rivadavia with different scenarios and instances of the collection with 75, 105, 150 and 200 waste containers and vehicles with different capacities. An analysis of the reduction of gases emitted is also carried out.

Keywords: Vehicle Routing Problem; Swarm Intelligent; Technological Waste; Metaheuristics.

1. INTRODUCCIÓN

El desarrollo de ciudades más inteligentes y sostenibles fue introducido para superar los grandes desafíos que enfrenta el constante crecimiento urbano. Sin embargo, el crecimiento demográfico y el cambio climático representan nuevos retos para las administraciones gubernamentales. Sabemos que cada ciudad es única y diferente de otra, todas tienen sus problemáticas y necesidades; sin embargo, el cuidado del medio ambiente puede considerarse como un elemento transversal a todas las ciudades con claros objetivos de sostenibilidad. En este marco de acción, el paradigma de la economía circular plantea que los residuos al final del ciclo de vida útil de un producto pueden ser materias primas para unos nuevos productos. Un ejemplo de esto es *Great Recovery*, un proyecto de *Innovate UK* (Reino Unido) que busca reciclar la basura y los residuos que se generan a diario, para generar nuevos procesos de economía circular.

Los equipos eléctricos y electrónicos (EEE, *Electrical and Electronic Equipment*) se convierten en uno de los grupos más importantes de residuos que contienen materiales fáciles de reciclar. Sin embargo, contienen muchas sustancias que son tóxicas y potencialmente peligrosas para el medio ambiente y la salud humana (Oguchi et al., 2012). Los desechos electrónicos son conocidos como RAEE (en español, Residuos de Aparatos Eléctricos y Electrónicos) o bien *e-waste* o WEEE (en inglés, *Waste Electrical and Electronic Equipment*). La tasa de *e-waste* está creciendo a un ritmo alarmante, especialmente en los países desarrollados, donde los mercados están saturados con grandes cantidades de nuevos productos electrónicos (Widmer et al., 2005). En 2013, el informe de StEPI (*Solving the e-waste Problem Initiative*), una iniciativa financiada por Naciones Unidas alertó que la cifra de *e-waste* se había elevado hasta cerca de los 49 millones de toneladas, un promedio de 7 kilos por cada uno de los 7.000 millones de habitantes del planeta Tierra. Según Grossman (2005) la producción y desecho de EEE conducirá a más minería, más extracción de combustibles fósiles y más refinación, con todos los impactos ambientales y sanitarios directos y secundarios que vienen con estos procesos. A la luz de estos datos, no resulta muy difícil hacerse una idea de la importancia que adquiere el reciclaje de este tipo de residuos.

Nuestro país ocupa el tercer puesto en la generación de desechos electrónicos con casi 500 kilotoneladas, según el reporte “Tecnología para la acción climática en América Latina” de la Asociación GSMA (asociación global del ecosistema móvil) y el Banco Interamericano de Desarrollo (BID), publicado en junio de 2018. El ranking lo encabeza Brasil, con más de 1500 kilotoneladas y lo sigue México que supera los 1000 kt. Los fabricantes de aparatos eléctricos y electrónicos son los responsables directos de la contaminación que producen pilas, baterías, teléfonos celulares, impresoras, lámparas de bajo consumo y computadoras, entre otros dispositivos, una vez que dejan de funcionar. Por eso, es imprescindible que las empresas que obtienen ganancias al venderlos se encarguen de los equipos al final de su vida útil.

Según las estadísticas de la Unión Europea (UE, *Europe Union*) riesgos al ambiente y a la salud pública y al juntarlos con los demás desechos y llevarlos a los mismos vertederos o basurales, éstos son altamente contaminantes por el tipo de materiales con los que están hechos como plomo, arsénico, mercurio, cobre, cromo, etc. Estos desechos afectan a la salud del ser humano y al ambiente. Ejemplo de ello, las pantallas de plasma que usan un gas que es el trifluoruro de carbono son 17.000 veces más contaminante que el dióxido de carbono, que es el principal contaminante. Otro ejemplo son las computadoras, donde algunos de las componentes con que están hechas son: cromo, cadmio mercurio, berilio, níquel y zinc. Menikpura et al. (2014) realizaron un estudio para evaluar los beneficios del reciclaje de desechos electrónicos de lavadoras, refrigeradores, acondicionadores de aire y televisores en Japón con respecto a la reducción de Gases de Efecto Invernadero (GEI).

Los residuos tecnológicos, poseen una amplia gama de materiales de composición generalizada para todos los residuos. La mayoría de los estudios examinan cinco categorías de materiales reciclables: metales ferrosos, metales no ferrosos, vidrio, plásticos y otros materiales. El hierro y el acero son los materiales más comunes que se encuentran en EEE (en peso) y representan casi la mitad del peso total de los *e-waste*. Los plásticos son el segundo mayor componente en peso, representando, 21% de los *e-waste*. Los metales no ferrosos, incluidos los metales preciosos, representan aproximadamente el 13% del peso total de los *e-waste* (el cobre representa el 7%).

Según Widmer et al. (2005), la fracción que incluye hierro, cobre, aluminio, oro y otros metales en los desechos electrónicos supera el 60%, mientras que los contaminantes representan el 2.70%. Ikhlayel (2018) valuó los impactos ambientales y los beneficios asociados con la recuperación de metales en *e-waste* de seis dispositivos electrónicos utilizando Jordania como un estudio de caso. Se diseñaron cinco escenarios de gestión de desechos electrónicos que representan sistemas de procesamiento de desechos electrónicos de última generación basados en el concepto de IWM (*Integrated Waste Management*), en el que se pueden emplear diversas tecnologías de tratamiento.

Otro factor importante a considerar es la emisión que producen los vehículos encargados de la recolección de *e-waste*. Calendarios ineficientes de recolección y asignación no convenientemente de vehículos conllevan a un aumento de las emisiones de gases contaminantes y de efecto invernadero (Salhofer et al., 2007). Así entonces, la optimización de las *rutas de la casa al vertedero* para la recolección de residuos tecnológicos, producen beneficios tanto económicos como ambientales.

En particular, en este artículo, aplicamos dos metaheurísticas poblacionales, denominadas algoritmo genético celular (en inglés *Cellular Genetic Algorithm*, cGA) (Alba y Dorronsoro, 2009) y Optimización de colonias de hormigas (en inglés *Ant Colony Optimization*, ACO)



(Dorigo et al., 1996), y una metaheurística de trayectoria denominada Reconido Simulado (en inglés Simulated Annealing, SA) todas ellas han sido utilizadas con éxito para resolver problemas de optimización complejos. Comparamos los resultados obtenidos por ambos algoritmos en diferentes escenarios e instancias de recolección con 75, 105, 150 y 200 contenedores de residuos y vehículos con diferentes capacidades, en términos de kilómetros recorridos. Además, analizamos algunos gases emitidos.

El artículo está organizado de la siguiente manera: la Sección 2 especifica nociones de recolección inteligente de residuos tecnológicos, la Sección 3 presenta conceptos de la base metodológica para la evaluación de recolección de *e-waste*. La Sección 4 los algoritmos metaheurísticos utilizados, la Sección 5 detalla las instancias de problema analizadas, la caracterización de los vehículos de recolección y discusión sobre los resultados. Finalmente, se presentan las conclusiones obtenidas y trabajos futuros.

2. RUTAS INTELIGENTES PARA RECOLECCION DE E-WASTE

Las empresas de recolección de residuos aplican diversos métodos de recolección, y en general pueden dividirse en estacionarios y móviles por demanda (Baxter et al., 2016). El objetivo tradicional de la gestión de distribución o recolección de productos consiste en minimizar los costos de todo el sistema. La logística verde (GL, *Green Logistics*) se ha convertido en una tendencia en la gestión de la distribución de bienes y la recolección de productos al final de su vida útil. Este enfoque tiene como objetivo maximizar el valor económico y ambiental mediante el reciclaje y el control de emisiones, GL contribuye al desarrollo sostenible de la industria, pero también requiere un esquema de transporte más completo cuando se realizan servicios de logística (Lin et al. 2014 (a) (b)).

El problema de recolección de *e-waste* estacionaria se lleva a cabo en puntos de recolección específicos. Dichos puntos, están ubicados en lugares populares o en donde se hace mínima la distancia es entre cada residencia y el punto limpio de recolección. La elección de la ubicación de dichos centros y la elección de un recorrido óptimo representan distintos problemas de decisión.

Por otro lado, un método de recolección móvil de *e-waste*, propone un sistema de recolección a pedido o demanda (Nowakowski et al., 2017). Este método de recolección consiste en una notificación previa por parte de un residente o una compañía para recolección de equipos de desecho. Un sistema de soporte de recolección móvil puede ofrecer grandes posibilidades para la reducción de costos de la recolección con una secuencia de recolección de equipos adecuadamente preparada. Para respaldar tal método de recolección, se debe aplicar un algoritmo con capacidades de planificación inteligente y un sistema de información eficiente para la eliminación de desechos (Nowakowski et al., 2018).

2.1. CVRP – Problema de ruteo de vehículos con capacidad limitada

Las distintas estrategias de recolección de *e-waste* pueden asociarse al conocido problema de enrutamiento de vehículos (VRP, *Vehicle Routing Problem*). Dantzig y Ramser (1959), formalizaron el VRP junto con sus numerosas variantes, y posteriormente Lenstra y Kan (1981) demostraron que dicho problema combinatorio es NP-Hard. En general, VRP consiste en asignar una cantidad de vehículos homogéneos a varios clientes, donde cada cliente tiene una cierta ubicación y demanda de productos (homogéneos). El objetivo de la optimización

es entregar los bienes demandados a todos los clientes al tiempo que minimiza la suma de los costos (longitudes) de las rutas de los vehículos.

Existen diferentes variantes del VRP, que incluyen restricciones adicionales y la incorporación de múltiples variables. Algunas restricciones más importantes son: a) cada vehículo tiene capacidad limitada (CVRP), b) todos los clientes deben ser atendidos dentro de una cierta ventana de tiempo (VRPTW), c) el proveedor utiliza muchos depósitos para suministrar a los clientes (*Multiple Depot* MDVRP) d) los clientes pueden devolver algunos productos (VRPPD) e) los clientes pueden recibir servicio por diferentes vehículos (SDVRP) f) algunos valores (como el número de clientes, sus demandas, el tiempo de servicio o el tiempo de viaje) son arbitrarios (VRP estocástico - SVRP) g) las entregas se pueden realizar en algunos días (VRP periódico - PVRP).

En la actualidad el problema de recolección o distribución de productos a partir de un depósito original (punto de origen) y una cantidad de clientes con una demanda por atender, juega un papel importante en empresas logísticas ya que deben planificar inteligentemente las rutas de manera tal que signifiquen considerables ahorros en costos tales como: el consumo de combustible, horas hombre, entre otros; que ayudarán a una mejor rentabilidad para los negocios hoy en día. En relación con una creciente sensibilidad ambiental los problemas de enrutamiento de vehículos presentan una extensa disponibilidad bibliográfica de los problemas de enrutamiento verde de vehículos (GVRP). Los diferentes tipos de problemas de enrutamiento de VRP en logística inversa, describen perfectamente la complejidad en los casos del mundo real.

En este artículo trabajamos la variante de VRP con capacidad limitada (CVRP), en el que cada vehículo tiene una capacidad uniforme de un único artículo. Definimos el CVRP sobre un grafo no dirigido $G = (V, E)$ donde $V = \{v_0, v_1, \dots, v_n\}$ es un conjunto de vértices y $E = \{(v_i, v_j) / v_i, v_j \in V, i < j\}$ es un conjunto de ejes.

El vértice v_0 es el depósito, y es desde donde m vehículos de capacidad Q deben abastecer a todas las ciudades o clientes, representados por un conjunto de n vértices $\{v_1, \dots, v_n\}$.

Definimos en E una matriz $C = (c_{ij})$ de costo, distancia o tiempo de viaje no negativos entre los clientes v_i y v_j . Cada cliente v_i tiene una demanda no negativa de artículos q_i y tiempos de entrega δ_i (tiempo necesario para descargar todos los artículos). Siendo v_1, \dots, v_m una partición de V , una ruta R_i es una permutación de los clientes en V_i especificando el orden en el que se visitan, comenzando y terminado en el depósito v_0 . El costo de una ruta dada $R_i = \{v_0, v_1, \dots, v_{k+1}\}$, donde $v_j \in V$ y $v_0 = v_{k+1} = 0$ (0 indican el depósito), viene dada por la ecuación (1):

$$Cost(R_i) = \sum_{j=0}^k c_{i,j+1} + \sum_{j=0}^k \delta_j \quad (1)$$

y el costo de la solución al problema (S) es:

$$FCVRP(S) = \sum_{i=1}^m Cost(R_i) \quad (2)$$

El CVRP consiste en determinar un conjunto de m rutas (i) de costo total mínimo - como especifica la ecuación (2); (ii) empezando y terminando en el depósito v_0 ; de forma que (iii) cada cliente es visitado una sola vez por un sólo vehículo, sujeto a las restricciones (iv) de que la demanda total de cualquier ruta no exceda $Q (\sum_{v_j \in R_i} q_j \leq Q)$; y (v) la duración total de cualquier ruta no supera el límite preseleccionado $D (Cost(R_i) \leq D)$. Todos los vehículos

tienen la misma capacidad y transportan el mismo tipo de artículo. El número de vehículos puede ser un valor de entrada o una variable de decisión. En este estudio, la longitud de las rutas se minimiza independientemente del número de vehículos utilizados.

2.2. Inteligencia colectiva vía optimización

La complejidad de muchos problemas optimización discreta del mundo real está asociada con grandes espacios de búsqueda, demandas de rendimiento de tiempo real y ambientes dinámicos que no pueden ser resueltos por métodos exactos en tiempo razonable. Esto ha promovido al desarrollo de nuevos enfoques conocidos como metaheurísticas. Estas, son métodos que integran de diversas maneras, procedimientos de mejora local y estrategias de alto nivel para crear un proceso capaz de escapar de óptimos locales y realizar una búsqueda robusta en el espacio del problema. En particular, las soluciones a problemas de planificación de rutas reales requieren enfoques específicos que puedan manejar tanto la complejidad intrínseca como la incertidumbre de configuración. Las principales ventajas de las metaheurísticas son su adaptabilidad a las características del problema y su conocimiento del mismo problema para encontrar una solución. Los procedimientos de resolución de problemas son capaces de abordar problemas complejos de optimización, incluidos aquellos con información imprecisa, evaluar posibles alternativas y determinar de manera eficiente la solución preferida.

Boussaïd et al. (2013), realizaron un estudio de un grupo de metaheurísticas de optimización. En particular, detallamos aquella inspiradas en las metáforas del comportamiento de enjambre en la naturaleza, este enfoque es conocido como Inteligencia Colectiva, (SI, *Swarm Intelligent*). Ejemplos de SI son Optimización de Colonias de Hormigas (ACO, *Ant Colony Optimization*), la Optimización de Cúmulo de Partículas (PSO, *Particle Swarm Optimization*), la Optimización de Forrajeo Bacteriano (BFOA, *Bacterial Foraging Optimization Algorithm*), Optimización de Colonias de Abejas (BCO, *Bee Colony Optimization*), Sistemas Inmunes Artificiales (AIS, *Artificial Immune Systems*) y Optimización Basada en Biogeografía (BBO, *Biogeography-Based Optimization*). Los algoritmos basados en SI se han aplicado con éxito a la resolución de problemas de VRP y sus variantes. Una de las características más importantes de estos métodos se ve en su capacidad para adaptarse a la instancia y la consistencia resultante observada al aplicar cambios leves en el modelo y los parámetros del problema. Por lo tanto, es común adaptar enfoques a diferentes contextos en los problemas del mundo real, con relativamente pocos cambios mientras se adaptan perfectamente a las características encontradas en los problemas de planificación de rutas.

Distintos autores han estudiado y aplicado diferentes metaheurísticas en general y en particular aquellos basados en SI para resolver variados tipos de problema relacionados con el enrutamiento vehicular. Ezzatneshan (2010), propone un algoritmo ACO híbrido para resolver el problema de VRP, donde una flota de vehículos con capacidades idénticas suministra a los clientes geográficamente dispersos de demanda conocida desde un solo depósito, al final de cada iteración, ACO intenta mejorar la calidad de las soluciones mediante el uso de un algoritmo de búsqueda local y actualizar los pesos asociados de los arcos de grafos. Gendreau (2008) analiza la aplicación del algoritmo de recocido simulado y otras metaheurísticas, para resolver los VRP. Akpinar (2016), presenta un algoritmo híbrido entre un algoritmo de búsqueda de vecindario en combinación con el mecanismo de construcción de la solución del algoritmo de optimización de la colonia de hormigas (LNS-ACO) para el problema de enrutamiento de vehículos capacitados (CVRP). Alzaqebah et al. presentan un

algoritmo de colonia de abejas artificiales (ABC) para el problema de enrutamiento del vehículo con ventanas de tiempo (VRPTW) y Szeto et al. (2011) presentan un ABC para resolver el CVRP. Byrski et al. presentan un enfoque denominado ACO socio-cognitivo, para evaluar diferentes problemas TSP (*Travelling Salesman Problem*) de la biblioteca TSPLIB. Kao et al. (2012) proponen un algoritmo híbrido basado en dos enfoques principales de inteligencia de enjambre (SI), optimización de colonias de hormigas y optimización de enjambre de partículas, para resolver problemas de enrutamiento de vehículos capacitados (CVRP). Niazy y Badr (2012) estudiaron la utilización del algoritmo Genético Celular (cGA) para resolver el problema de CVRP con el objetivo de minimizar las distancias totales. Tasan y Gen (2012) proponen un enfoque basado en algoritmos genéticos aplicado al problema del enrutamiento del vehículo con recolección y entregas simultáneas. Tuba, y Jovanovic (2013) proponen un algoritmo ACS mejorado con estrategia de corrección de feromonas para el TSP. Yousefikhoshbakht et al. (2014) presentan una versión modificada del algoritmo *Elite Ant System* (EAS) para resolver el VRP esta versión combina los algoritmos de inserción e intercambio utiliza un criterio efectivo para escapar de los puntos óptimos locales. Zhang X., Tang (2009) presentan un algoritmo híbrido donde su característica principal es hibridar el mecanismo de construcción de la solución de la optimización de colonias de hormigas con la búsqueda de dispersión (SS) para resolver VRP. En particular para el problema de recolección de residuos tecnológicos (Nowakowski et al., 2020) proponen un algoritmo con inteligencia artificial que obtiene resultados muy promisorios.

Si bien existen muchos trabajos en la literatura en este artículo se muestra la mejora que presenta un algoritmo ACO que se enfoca en maximizar el número de puntos de recolección, de los ciudadanos que deseen eliminar los desechos o equipos no deseados de los hogares. Como resultado, las emisiones de escape de los vehículos de recolección de desechos pueden reducirse utilizando un menor número de vehículos por la compañía de recolección y recolectando una mayor masa de las materias primas del equipo de desechos.

3. DE LA CASA AL VERTEDERO: ANÁLISIS DE LA FASE DE RECOLECCION DE RESIDUOS TECNOLOGICOS

La metodología de evaluación del proceso de reciclaje proporciona una base sistemática para estimar las posibles opciones de mitigación disponibles a través de la recuperación de residuos tecnológicos (Menikpura et al., 2013). El enfoque propuesto por el autor identifica las entradas/salidas del ciclo de vida del sistema de reciclaje en relación con todas las fases del ciclo de vida propuestos para la prefectura de Fukuoka (Japón). Estos incluyen procesos tales como recolección, transporte, desmontaje, y fundición de materiales.

La primera tarea, antes de analizar el proceso, consiste en la determinación de los desechos, el método de recolección, y los vehículos utilizados para la tarea de recolección. Según, la directiva del parlamento Europeo sobre residuos de *e-waste* (2012/19/UE) se pueden clasificar en (a) grandes electrodomésticos, (b) pequeños electrodomésticos, (c) equipos de informática y telecomunicaciones, (d) aparatos electrónicos de consumo y paneles fotovoltaicos, (e) aparatos de alumbrado, (f) herramientas eléctricas y electrónicas (con excepción de las herramientas industriales fijas de gran envergadura), (g) juguetes o equipos deportivos y de ocio, (h) productos sanitarios (con excepción de todos los productos implantados e infectados), (i) instrumentos de vigilancia y control, (j) máquinas expendedoras. En función de los materiales de los residuos se emplea diferentes sistemas de recolección y procesado. En general, vamos a definir, de manera arbitraria, entre los

siguientes procesos de recolección (1) pequeños *e-waste* recolectados desde sitios preestablecidos (tipo1), (2) grandes *e-waste* recolectados por demanda y restringidos por ventana de tiempo (tipo2), (3) residuos especiales por demanda (tipo3).

El proceso de reciclaje de *e-waste* (Fig.1), se inicia con la selección de las locaciones (sitios) donde se dispondrá la ubicación de los contenedores, también denominados puntos limpios. La localización geográfica de estos puntos es a menudo una combinación entre la disponibilidad en centros municipales y su mejor distribución geográfica. Luego, se planifica la ruta de recolección con el objetivo de minimización del costo (camino más corto). En la planta de tratamiento se realiza la clasificación de los residuos, el desmontaje y las operaciones de tratamiento final de los residuos tecnológicos (reutilización, reciclaje, valoración energética, y eliminación).

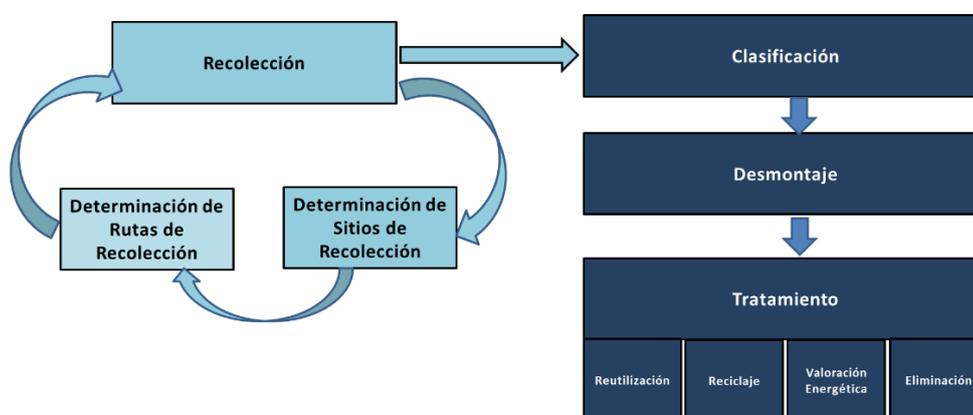


Fig. 1: Proceso de tratamiento de residuos tecnológicos

En las siguientes secciones describiremos las diferentes variables obtenidas de un plan de recolección, así como también de evaluación de gases efecto invernadero.

3.1. Evaluación del proceso de recolección de *e-waste*

El plan de recolección establece el orden de recolección de cada contenedor. Como resultado de cada plan, el algoritmo de ruteo brinda la estimación de los kilómetros recorridos ($TkmR$, total de km recorridos) a igual que la cantidad de viajes que debe realizar el vehículo (nR , número de viajes). Además, estos resultados permiten estimar el coste de recolección de cada vehículo (CTV , coste total de vehículo), la cantidad de combustible (TCL , en litros) y el tiempo total de trabajo (TTT). El tiempo de recorrido se estima en base a la distancia y los procesos de carga y descarga en función a la automatización de los vehículos y la cantidad de lugares a visitar. Cada vehículo posee capacidades y consumo de combustible diferentes (detalles de estos se describen en la Sección 5).

El CTV , expresa el costo específico de utilizar un vehículo en particular y se calcula en base los km recorridos. No se analizan los costes de combustible y coste de trabajo relacionado al personal afectado a las actividades específicas. La ecuación (3) establece:

$$CTV = TkmR * Co_j \quad (3)$$

donde $TkmR$ es el total de km recorridos y Co es el costo para vehículo j por km .

El TCl , se calcula en base estimación de $TkmR$ y el consumo de combustible. La ecuación (4) establece TCl :

$$TCl = TkmR * C_j \quad (4)$$

donde $TkmR$ es el total de km recorridos y Co es el costo para vehículo j por km .

El TTT , se calcula a partir de la planificación de recorrido realizada, la automatización de los vehículos, y las estimaciones de velocidad y tiempos en las actividades involucradas. El TTT para un proceso de recolección de *e-waste*, contempla cuatro componentes, TTR (tiempo total de recorrido), TTC y TTD tiempos de carga y descarga de los contenedores respectivamente y TTA tiempo de trabajo administrativo. Todos los tiempos calculados y estimados son expresados en minutos. La ecuación básica de TTT es como se muestra en (5):

$$TTT = TTR + TTC + TTD + TTA \quad (5)$$

donde el tiempo total de recorrido (TTR) es expresado en minutos, TTR es igual a la suma entre el Tr (tiempo de recorrido estimado) y TtP (tiempo de transporte a planta) según la ecuación (6). La velocidad de traslado para los vehículos de recolección es estimada en 100 metros en 10 segundos (aproximadamente, una velocidad de tránsito menor a 40 km por hora). Las ecuaciones de tiempo derivadas de la ecuación (5) son:

$$TTR = Tr + TtP \quad (6)$$

$$Tr = TkmR * 6 \quad (7)$$

$$TtP = Nv * 132 \quad (8)$$

En la ecuación (7), el valor 6 (seis) es el tiempo (en minutos) por cada kilómetro recorrido.

En la ecuación (8), el valor 132 (ciento treinta y dos) es el tiempo (en minutos) de recorrido desde el centro de recolección hasta la planta de tratamiento.

El tiempo total de carga (TTC) y el tiempo total de descarga (TTD) de la ecuación (5) son calculados en función de la cantidad de contenedores (Nc) a recoger y los tiempos de carga y descarga que dependen de la automatización de cada vehículo j (Tc_j) para cada proceso (establecidos en la Sección 5). Las ecuaciones generales se formulan en las ecuaciones (9) y (10):

$$TTC = Nc * Tc_j \quad (9)$$

$$TTD = Nc * Tc_j \quad (10)$$

Finalmente, el tiempo total administrativo TTA , es calculado como el tiempo utilizado en actividades administrativas (estimado en 30 minutos) multiplicado por el número de viajes (Nr) que se realiza. La ecuación (11) describe su cálculo:

$$TTA = Nr * 30 \quad (11)$$

3.2. Evaluación de gases de efecto invernadero

Las fuentes móviles producen emisiones de gases directos de efecto invernadero de dióxido de carbono (CO_2), metano (CH_4) y óxido nitroso (N_2O) procedentes de la quema de diversos tipos de combustible, así como varios otros contaminantes como el monóxido de carbono (CO), los compuestos orgánicos volátiles diferentes del metano ($COVDM$), el dióxido de azufre (SO_2), la materia particulada (PM) y los óxidos de nitrato (NO_x), que causan o contribuyen a la contaminación del aire.

Las emisiones de gases de efecto invernadero procedentes de la combustión móvil se estiman más fácilmente por la actividad principal de transporte. El CO_2 , es el principal gas causante del efecto invernadero y la ecuación (12) describe su cálculo:

$$CO_2 = TCL * FeGI_j \quad (12)$$

donde, $FeGI_j$ es el factor de emisión de gas invernadero CO_2 por combustible consumido (litros). El factor de emisión fue obtenido de la Agencia Internacional de Energía (AIE) y son expresados en terajulios.

La ecuación (12) implica la determinación de CO_2 , en base a la cantidad de combustible consumido por tipo de combustible para el transporte terrestre ajustado por el factor de emisión de gas invernadero.

Las emisiones de CH_4 y N_2O son más difíciles de estimar con exactitud que las del CO_2 porque los factores de emisión dependen de la tecnología del vehículo, del combustible y de las condiciones de uso. Tanto los datos de la actividad basados en la distancia (p. ej., vehículo-kilómetros recorridos) como el consumo de combustible desagregado pueden ser considerablemente menos seguros que todo el combustible vendido. Las emisiones de CH_4 y N_2O se ven significativamente afectadas por la distribución de los controles de emisión de la flota. De esta forma, los niveles superiores utilizan un método que toma en cuenta las poblaciones de diferentes tipos de vehículos y sus distintas tecnologías de control de la contaminación. Por esta razón en este artículo solamente se analiza CO_2 .

4. ALGORITMOS PROPUESTOS

En esta sección se describen los tres algoritmos utilizados para resolver el problema de recolección de residuos tecnológicos. Primero se describe la metaheurística de inteligencia colectiva ACO, segundo la metaheurística de trayectoria SA y en tercer lugar la metaheurística poblacional cGA.

4.1. Algoritmo ACO

El algoritmo ACO fue propuesto por Dorigo et al. (1996) como metaheurística inspirada en el comportamiento de una colonia de hormigas en el proceso de forrajeo y aplicado principalmente para resolver problemas de optimización combinatoria. Este enfoque fue propuesto inicialmente como método para resolver el clásico problema del viajante de comercio (*Traveling Salesman Problem*).

En general en ACO, hay una colonia de m hormigas (artificiales) que se mueven concurrente y asincrónicamente, a través de los estados adyacentes del problema. Se utiliza una regla de

transición para realizar este movimiento, la que se basa en la información local disponible en los arcos del grafo que representa el problema (los nodos representan las ciudades y los arcos los caminos que unen las ciudades). Se utiliza una regla de transición para realizar este movimiento, la que se basa en la información local disponible en los arcos del grafo que representa el problema. Para guiar la búsqueda, esta información contiene tanto la información heurística (η_{ij}) y los rastros de feromona (τ_{ij}) asociados a cada arco (i, j). Las hormigas depositan feromona al transitar por un arco mientras construyen una solución (actualización en línea paso a paso de los rastros de feromona). Después que las m hormigas generan una solución, se deposita una cantidad de feromona en los arcos de la mejor solución conocida (actualización en línea a posteriori de los rastros de feromona), de esta forma se guía la búsqueda de soluciones en el siguiente ciclo.

El pseudocódigo de ACO se muestra en el Algoritmo 1. El primer paso consiste en la inicialización de los parámetros como los rastros de feromonas, factor de evaporación, número de hormigas y factores de información heurística (línea 1). Durante la construcción de la solución, cada hormiga debe decidir, a través de la regla de transición probabilística, ya sea para explorar nuevas conexiones o explotar las que ya han sido visitadas por otras hormigas (línea 4). Cada solución generada es una secuencia de nodos que ha sido visitado por una hormiga. Por tanto, las hormigas deben iniciar su recorrido desde algún nodo del grafo. Este nodo inicial se elige al azar para todas las hormigas en la colonia (línea 6). El camino de cada hormiga comienza desde un nodo aleatorio del grafo y termina cuando todos los nodos del grafo han sido visitados solo una vez. El orden de las visitas de los nodos en camino depende de las decisiones del algoritmo (líneas 7 y 8). Cuando todas las hormigas terminan su recorrido, se ejecuta una rutina global (fuera de línea), que se encarga de actualizar los rastros de feromonas de hormigas que el algoritmo considera las mejores soluciones. Esta actualización de la feromona se realiza primero evaporando los rastros de feromonas en todas las conexiones utilizadas por la mejor hormiga global y luego en la misma ruta que se depositaron las nuevas feromonas (líneas 11).

Algoritmo 1 ACO

```

1: inicializacion_de_parametros ();
2:  mientras (criterio no satisfecho)
3:     mientras (población de hormigas)
4:         crear_soluciones ();
5:         para (cada solución)
6:             Preparar hormigas
7:             Inicializar los recorridos de las hormigas
8:             Evaluar solución
9:         fin para
10:    fin mientras (población de hormigas)
11:    actualizar_feromonas ();
12: fin mientras (criterio no satisfecho)

```

4.2. Algoritmo SA

El algoritmo SA es una generalización de un método de Monte Carlo para la evaluación de las ecuaciones de estados y estados congelados de sistemas de n -cuerpos (Metropolis et al., 1953). SA se basa en una analogía de la termodinámica que se ocupa de la manera en que los metales se enfrían. Si se enfría un metal líquido lentamente, sus átomos forman un cristal puro

correspondiente al estado de energía mínima para el metal. El metal llega a un estado de menor energía si se enfría rápidamente. El algoritmo SA es una técnica compacta y robusta, que proporciona soluciones para problemas de optimización en general y en particular para problemas de ruteo de vehículos (VRP). Kirkpatrick et al. (1983) demostraron que un modelo para simular el recocido de sólidos, propuesto por Metropolis et al. (1953), podría usarse para la optimización de problemas, donde la función objetivo que se debe minimizar corresponde a la energía de estados del metal.

Algoritmo 2 SA

```

1:  $\tau \leftarrow t$  /*Temperatura inicial*/
2:  $s \leftarrow s_0$  /*Solución inicial candidata*/
3: Repetir
4:   Para  $i \leftarrow t$  a l hacer
5:      $s' \leftarrow \text{Perturbar}(s)$   $s' \in \text{vecindario}(s)$ 
6:     Si  $f(s') < f(s)$  entonces
7:        $s \leftarrow s'$  /*  $s'$  reemplaza  $s$  */
8:     Sino aceptar  $s'$  como nueva solución con probabilidad  $e^{-\frac{f(s')-f(s)}{\tau}}$ 
10:    FinSi
11:  EndPara
12:  Actualizar  $\tau$ 
13: FinRepetir hasta condición de parada (criterio satisfecho)
14: fin procedimiento

```

Como toda metaheurística basada en trayectoria, SA trabaja con una sola solución candidata. El pseudocódigo de SA se muestra en el Algoritmo 2. Se inicializa la temperatura y la solución tentativa inicial se crea al azar (líneas 1 y 2). Entonces, para obtener una vecindad de la solución, se aplica una perturbación de esa solución (línea 5). Si la nueva solución es mejor que la solución anterior (es decir, tiene una función de aptitud inferior) se convierte en la solución actual (línea 7). Si no, puede ser utilizada de todos modos, pero con una probabilidad regulada por un parámetro de temperatura decreciente llamado probabilidad de Boltzmann (línea 8) definida a continuación (Ecuación (13)):

$$e^{-\left(\frac{f(s')-f(s)}{\tau}\right)} \quad (13)$$

donde $f(s')$ es el valor de aptitud de la solución actual, $f(s)$ es el valor de aptitud anterior, τ es el parámetro temperatura. Después de eso, la temperatura se decrementa en cada iteración (línea 12). El proceso iterativo termina cuando se alcanza el criterio de parada (por ejemplo, número máximo de iteraciones) y se devuelve la solución encontrada.

4.3. Algoritmo Genético Celular

El cGA es una clase particular de metaheurística y una subclase de los Algoritmos Genéticos. Tienen una población estructurada espacialmente, es decir, los individuos de la población pueden aparearse solo con sus vecinos. Los cGAs, se diseñaron inicialmente para trabajar en máquinas paralelas, formadas por muchos procesadores que ejecutaban simultáneamente las mismas instrucciones sobre diferentes datos (máquinas SIMD - El primer modelo de cGA fue propuesto por Robertson (1987) y fueron inicialmente desarrollados para trabajar en máquinas

paralelas, y más tarde se fueron adaptando para funcionar también en máquinas de procesamiento secuencial.

Algoritmo 3 cGA

```

1: Para  $i \leftarrow 1$  a  $MAX\_PASOS$  hacer
2:   Para  $x \leftarrow 1$  a  $ANCHO$  hacer
3:     Para  $y \leftarrow 1$  a  $ALTO$  hacer
4:       vecinos  $\leftarrow$  CalculaVecinos (rejilla_cGA, individuo(x,y));
5:       padre1  $\leftarrow$  individuo(x,y);
6:       padre2  $\leftarrow$  selección(vecinos);
7:       hijo  $\leftarrow$  Recombinacion (rejilla_cGA,  $P_c$ , padre1, padre2);
8:       hijo  $\leftarrow$  Mutacion (rejilla_cGA,  $P_m$ , hijo);
9:       Evaluación(hijo)
10:      Añadir (rejilla_cGA, individuo(x,y), hijo);
11:     FinPara
12:   FinPara
13: FinPara
14: fin procedimiento

```

En el Algoritmo 3, se presenta el pseudocódigo de un cGA estándar. Comienza con una poblacional inicial generada aleatoriamente. Luego se aplican iterativamente los operadores genéticos (selección, recombinación, mutación y reemplazo) a cada individuo hasta que se alcance la condición de finalización. La población se estructura en una rejilla toroidal de dos dimensiones (*rejilla_cGA*) y el vecindario definido contiene cinco individuos (línea 4). El individuo que se está considerando (*individuo(x,y)*) siempre es seleccionado como primer padre (línea 5). El segundo padre se selecciona con Selección por Torneo (línea 6). Se aplican los operadores genéticos (recombinación y mutación) a los individuos (líneas 7 y 8). Se utiliza aquí un operador de cruce de dos puntos (DPX1) es cual produce un solo individuo (que contiene la porción más grande del mejor padre) y el operador tradicional de mutación binaria (intercambio de un bit). Luego, el algoritmo calcula el valor de calidad del nuevo individuo, es decir del hijo (línea 9) y lo inserta en la población, reemplazando al individuo actual (línea 10) siguiendo la política de reemplazo definida.

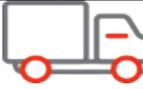
5. INSTANCIAS DEL PROBLEMA Y RESULTADOS EXPERIMENTALES

En esta sección se presentan características de las instancias utilizadas, la parametrización de los algoritmos, el diseño de los experimentos y análisis de los resultados obtenidos el proceso de optimización de recolección de *e-waste* para instancias de la ciudad de Comodoro Rivadavia.

5.1. Instancias propuestas para la recolección de residuos tecnológicos

El estudio desarrollado corresponde a la de recolección en puntos fijos de pequeños *e-waste*. Para la recolección estacionaria se establecieron cuatro escenarios distintos de 75, 105, 150 y 200 puntos de recolección de *e-waste*, ubicados en lugares con disponibilidad para su gestión. La elección de la ubicación de dichos centros fue establecida de forma aleatoria, en distintos centros educativos o gubernamentales de la localidad de Comodoro Rivadavia.

Tabla 1: Vehículos de recolección de e-waste

Tipo de Vehículo	Peso de la carga	Cubicaje Máximo	Coste x Km	Consumo Medio	Capacidad en Contenedores	Tipo de Automatización Carga y Descarga
	Hasta 1,5 Toneladas	16 m ³	1,1526 51,10	0,30 litros/km	71	Manual 6 min – 2 min
	Hasta 2,5 Toneladas	22 m ³	1,2368 54,84	0,385 litros/km	97	Semi-automatico 4 min – 2 min
	Hasta 4.5 Toneladas	32 m ³	2,2262 98,71	0,48 litros/km	142	Automático 4 min – 1 min

Los contenedores son todos de igual tamaño con un volumen de 0,225 m³. Los vehículos de recolección poseen distintas capacidades y características. El primero de los vehículos soporta una carga de hasta 1,5 toneladas y cubicaje de 16 m³, el coste promedio por km recorrido es de 1,1526 euros, tiene un consumo de 0,30 litros de gasoil por km recorrido, tiene una capacidad de carga máxima de 71 contenedores y su carga y descarga es de tipo manual requiriendo 6 y 2 minutos respectivamente. De igual manera se detallan todos los vehículos en la Tabla 1.

Los algoritmos seleccionados y la parametrización de los tres algoritmos utilizados para la optimización son establecidos en la Tabla 2 y se han definido en base a experimentos anteriores. Se realizaron 30 ejecuciones independientes de los tres algoritmos aplicados a resolver el problema de recolección de *e-waste*.

Tabla 2: Parámetro de algoritmos

Algoritmo	Población de soluciones	Máximo de Iteraciones	Parámetros
ACO	50	10.000	Evaporación global p(ro) 0,1 Evaporación local (fi) 0,1 Valor inicial de feromona T (tau) 0,0335
cGA	100	5.000	Crossover DPX1 (100%) Mutación (100%)
SA	40	12.500	

Todos los algoritmos se implementaron en Java y se ejecutan en el clúster que consta de 16 nodos (64 núcleos) equipados con una CPU IntelCore2 Quad (Q9400) @ 2.66 GHz y 4 GB de RAM, 14 nodos (28 núcleos) equipados con Intel Pentium D a 2,8 GHz y 1 GB de RAM, un nodo (ocho núcleos) equipado con dos Intel Xeon (E5405) a 2.00 GHz y 8 GB de RAM, y un nodo (ocho núcleos) equipado con un Intel Core i7 (920) a 2.67 GHz y 4 GB de RAM. El software responsable de la gestión de estos recursos heterogéneos es HTCondor Versión 7.8.4. En este trabajo, los mejores valores están marcados en negrita. En todos los experimentos se han analizado las condiciones que deben cumplirse para utilizar pruebas paramétricas y pruebas

no paramétricas para el análisis estadístico con un error de probabilidad de $p = 0,05$ utilizando RStudio Versión 1.1.463.

5.2. Análisis de Resultados

En este trabajo, se analizarán los resultados obtenidos con el objeto de contestar a tres cuestiones fundamentales de este problema, la primera es ¿existe un algoritmo mejor que otro?, la segunda pregunta es ¿puedo determinar la mejor opción de transporte?, y tercero ¿qué cantidad de contenedores debo seleccionar para la recepción de *e-waste*? Para responder la primera de las cuestiones, se analizarán los distintos enfoques propuestos (algoritmos) con el objetivo de establecer si existe entre ellos un comportamiento que tenga diferencias significativas respecto a la variable km recorridos. En la segunda pregunta analizaremos la cantidad de km recorridos, el consumo de gasoil, el tiempo de trabajo, la emisión de gases CO₂, el coste vehicular para las tres opciones de vehículo de transporte. Finalmente, analizaremos los tres escenarios de contenedores para determinar que opción es la mejor.

5.3. Análisis comparativo entre ACO, SA y cGA

En esta sección se muestra la comparación de los algoritmos propuestos para determinar si algunos de ellos muestran mejor calidad en los resultados (función de optimización) para cada uno de los escenarios propuestos. Para ello, se analizarán la mediana obtenida de las 30 ejecuciones para los 9 escenarios propuestos que resultan de la combinación de 3 tipos de transportes diferentes y 3 (tres) cantidades distintas de contenedores. Además, se realizarán los análisis de normalidad, homocedasticidad, y si existen diferencias significativas entre los algoritmos. Finalmente se muestran gráficos de caja y bigote (*boxplot*) para analizar el comportamiento de estos.

Tabla 3: Mediana de km recorridos para los algoritmos cGA, ACO y SA

N	cGA			ACO			SA		
	C16	C22	C32	C16	C22	C32	C16	C22	C32
75	267,86	236,46	227,70	258,27	225,10	207,41	485,59	563,90	451,02
105	357,35	336,23	299,43	331,86	305,76	267,26	647,61	779,47	600,25
150	493,84	442,21	428,61	419,63	365,00	344,73	1012,01	1200,73	961,28
200	653,54	623,73	582,63	518,21	471,32	425,95	1382,35	1676,26	1321,03
Prom	443,15	409,66	384,59	381,99	341,79	311,34	881,89	1055,09	833,39

La Tabla 3 muestra la mediana de los kilómetros recorridos para las 30 ejecuciones para los tres algoritmos (cGA, ACO, y SA) en los tres escenarios propuestos. La columna de **N** identifica cada escenario donde se indica la cantidad de locaciones a recorrer (75, 105, 150 y 200). Los acrónimos C16, C22 y C32 representan la capacidad del transporte en metros cúbicos (16, 22, 32 m³). El cuadro central de la tabla detalla la cantidad de km recorridos por cada vehículo con distinta capacidad y escenario en cuanto a la cantidad de locaciones a visitar. Finalmente, en la última fila se observa los promedios de los km recorridos (no incluye al transporte al depósito final) obtenidos por cada algoritmo.

Para todas las instancias el algoritmo ACO obtiene los mejores valores (medianas de 30 ejecuciones) para cada escenario, en el siguiente análisis comprobaremos si existen diferencias estadísticamente significativas entre los resultados obtenidos por los algoritmos.

La Tabla 4 muestra los resultados las medianas de los kilómetros recorridos para las 30 ejecuciones de los algoritmos para los tres algoritmos (cGA, ACO, y SA). La columna **N** identifica cada escenario donde indica la cantidad de locaciones a recorrer (75, 105, 150 y 200) y la capacidad del transporte (16, 22, 32 m³). Las columnas cGA ACO, SA identifican la mediana de km recorridos para cada escenario, donde el algoritmo ACO obtiene el menor valor para todos los casos con un promedio de 363,75. La columna **Nor** establece (con sí o no) si las muestras tienen una distribución normal través de aplicar el test de normalidad (*Shapiro-Wilk normality test*) donde con 95% de confianza alguna de sub-muestras de cada algoritmo no son normales. La columna **Hom** establece (con sí o no) las muestras que poseen una distribución homogénea sobre la varianza través de aplicar la prueba de homoscedasticidad (*Levene's Test for Homogeneity of Variance*) donde con 95% de confianza todas cumplen con la hipótesis de homocedasticidad. La columna **K-W** compara las muestras cuyas distribuciones no son normales o no poseen homocedasticidad aplicando la prueba de Kruskal-Wallis (*Kruskal-Wallis rank sum test*) e indican que existen diferencias significativas entre las medianas de los algoritmos propuestos.

Tabla 4: Análisis estadísticos de cGA, ACO y SA para los 12 escenarios

N	cGA	ACO	SA	Nor	Hom	K-W
75x16	267,86	258,27	485,59	si	no	si
75x22	236,46	225,10	455,94	si	no	si
75x32	227,70	207,41	451,02	si	no	si
105x16	493,84	419,63	1012,01	si	no	si
105x22	442,21	365,00	970,84	si	no	si
105x32	428,61	344,73	961,28	si	no	si
150x16	493,84	419,63	1012,01	si	no	si
150x22	442,21	365,00	970,84	si	no	si
150x32	428,61	344,73	961,28	si	no	si
200x16	653,54	518,21	1382,35	si	no	si
200x22	623,73	471,32	1355,32	si	no	si
200x32	582,63	425,95	1321,03	si	no	si
Prom	443,44	363,75	944,96			

Las Figuras 2, 3, 4 y 5 muestran los boxplot de las medianas de los escenarios analizados para los tres algoritmos (ACO, cGA y SA). En el análisis del comportamiento se puede observar que el algoritmo ACO tiene diferencias significativas sobre los algoritmos cGA y SA, lo que muestra un mejor comportamiento para las instancias analizadas. Las figuras de *boxplot* confirman las diferencias estadísticamente significativas para los escenarios de 75, 105, 150 y 200 contenedores.

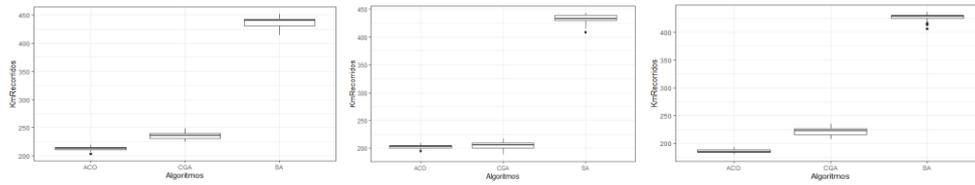


Fig. 2. Boxplot medianas instancias 75x16, 75x22, 75x32

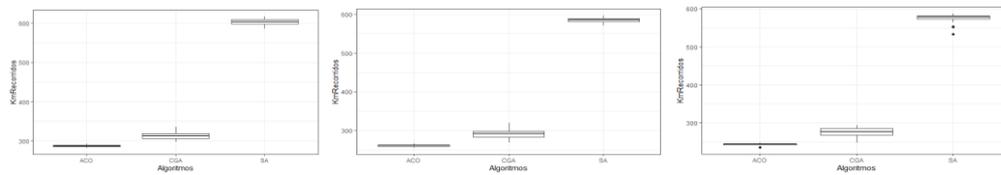


Fig. 3. Boxplot medianas instancias 105x16, 105x22, 105x32

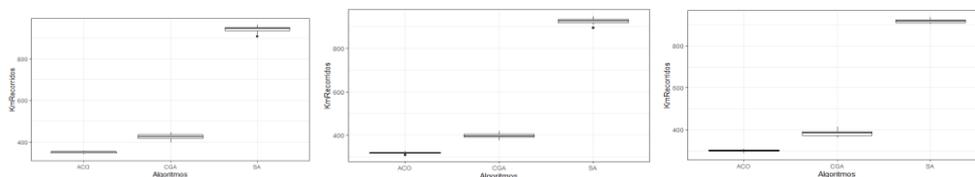


Fig. 4. Boxplot medianas instancias 150x16, 150x22, 150x32

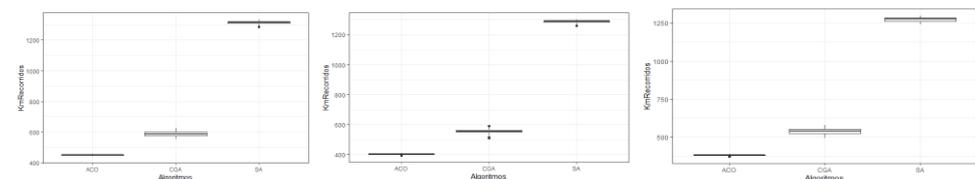


Fig. 5. Boxplot medianas instancias 200x16, 200x22, 200x32

En resumen, el algoritmo ACO muestra un mejor comportamiento (menor cantidad de km recorridos) tanto para las medianas, y valores promedios que son confirmados por las pruebas estadísticas realizadas y visualizados en los gráficos de *boxplot*.

5.4. Análisis comparativo entre los distintos tipos de transportes

Del análisis realizado en la sección anterior surge ACO como el algoritmo de mejor comportamiento en cuanto a la función de optimización seleccionada (km recorridos). En esta Sección, evaluaremos que tipo de transporte tiene un mejor comportamiento promedio para todos los escenarios para transportes con capacidades de 16, 22 y 32 m³ respectivamente (Figura 6). El vehículo con capacidad de 32 m³ (C32), es el que realiza la menor cantidad de km recorridos (273 km) y menor cantidad de horas de trabajo consumidas (1222 min). El vehículo con capacidad de 22 m³ (C22) es el de menor coste vehicular (369 €), y finalmente el vehículo con capacidad de 16 m³ (C16) es aquel que tiene menor consumo de diésel (40 litros), y la menor cantidad de emisiones de gases CO₂ (105 kg).

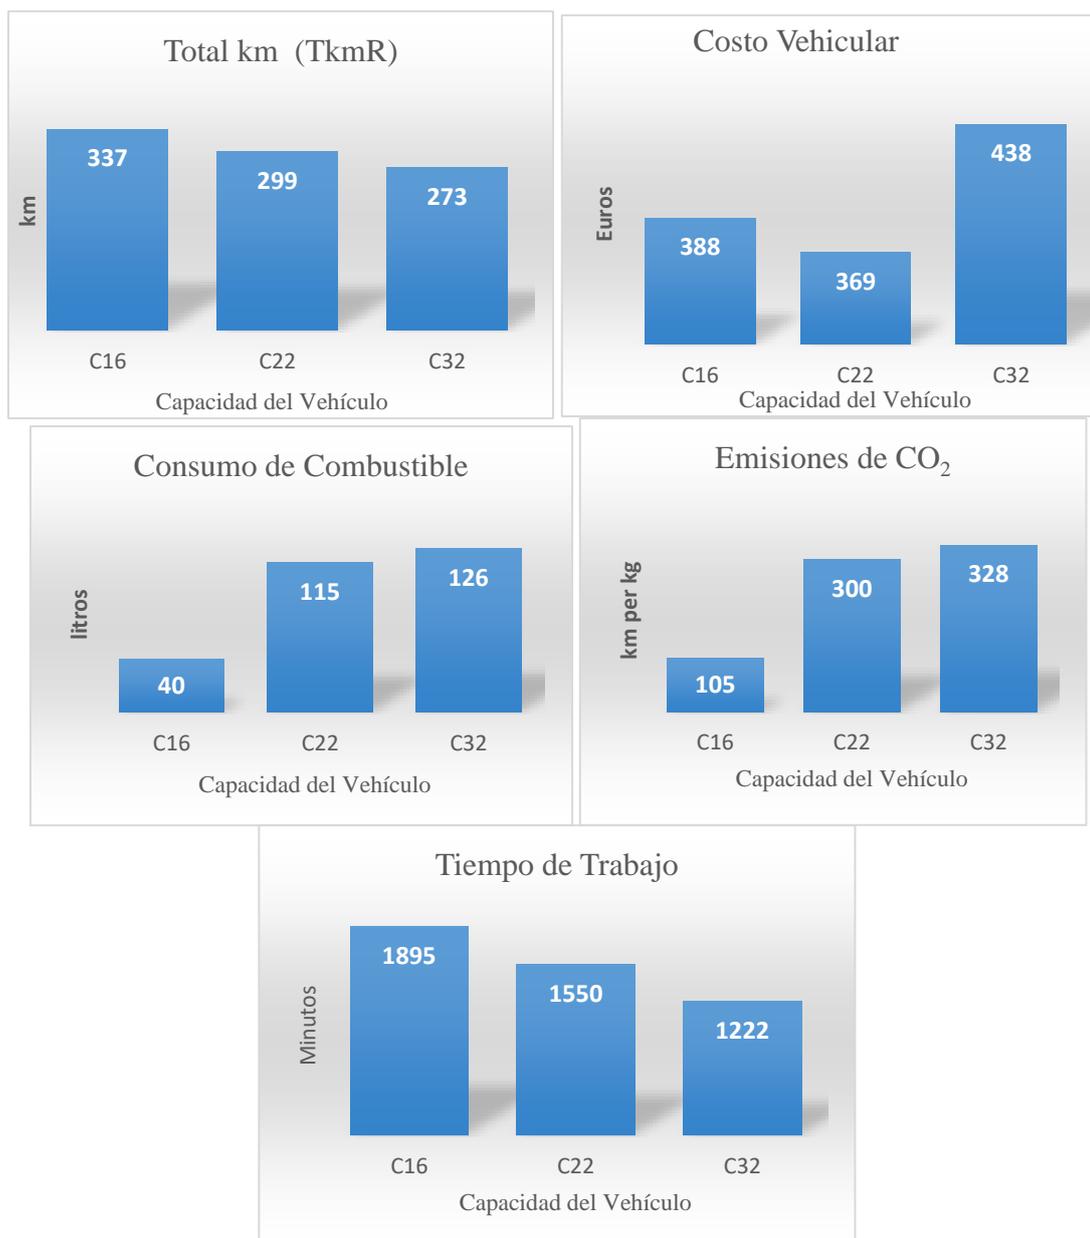


Fig. 6. Análisis de los diferentes tipos de transporte

5.5. Análisis comparativo entre los distintos tipos de contenedores

En esta Sección, evaluaremos que cantidad de locaciones debemos seleccionar para mejorar las condiciones de recolección (75, 105, 150 y 200 contenedores) para los escenarios de transportes con capacidades de 16, 22 y 32 m³ respectivamente (Figura 7).

El escenario de 105 contenedores tiene un mejor comportamiento para las variables de decisión km recorridos por contenedor (1,99) y tiempo de trabajo por contenedor (4,83 minutos). Finalmente, el escenario de 200 contenedores tiene un mejor comportamiento para coste (en €) vehicular por contenedor (2,96), consumo de diésel por contenedor (0,73 litros) y emisión de gas efecto invernadero CO₂ (1,91 Kg).

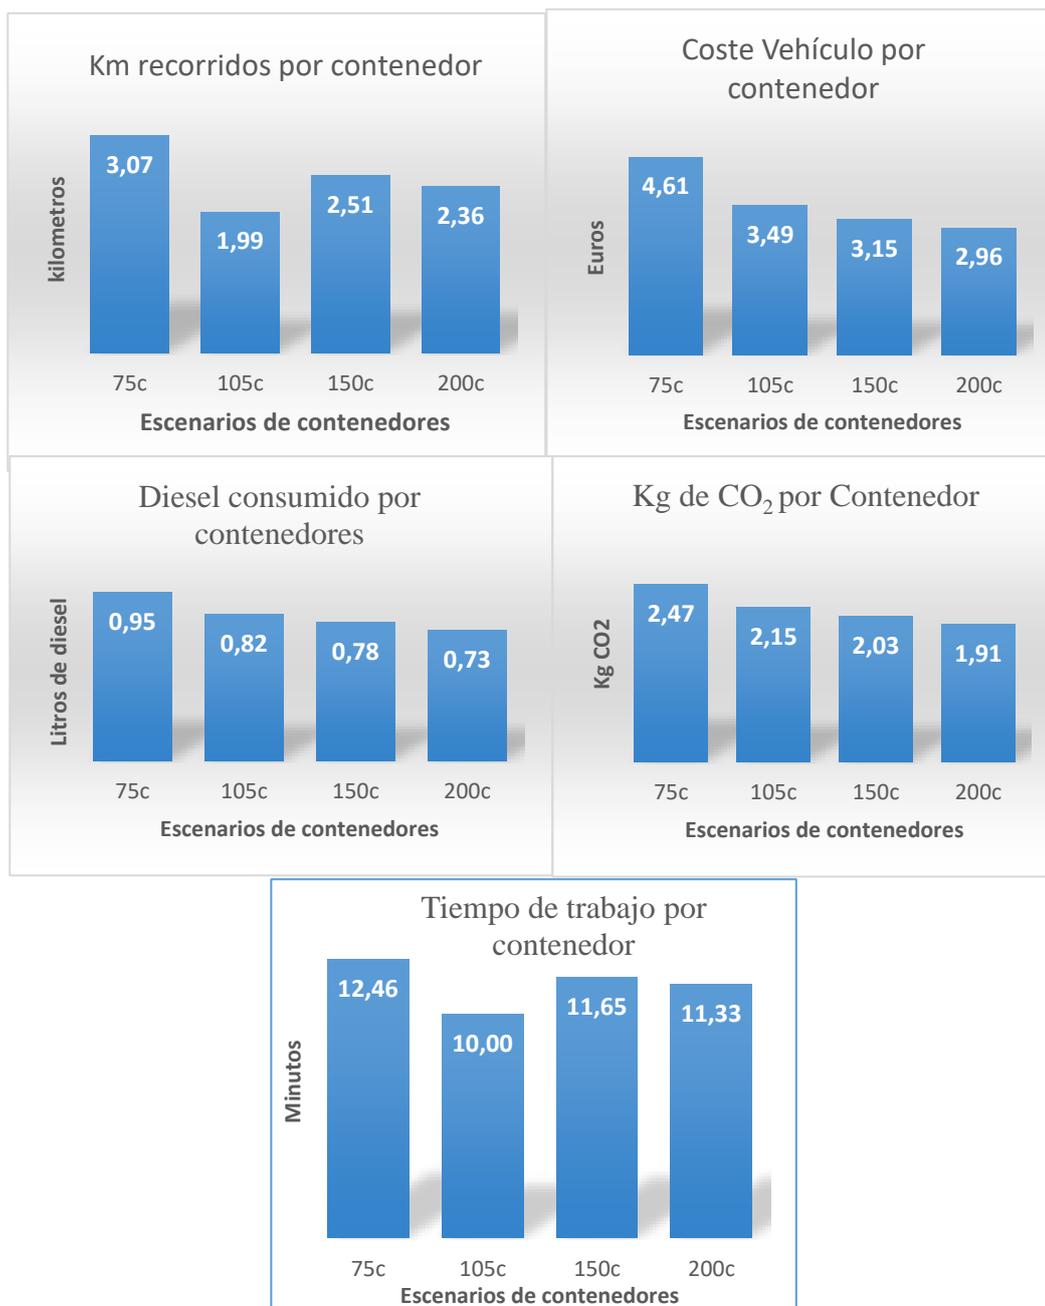


Fig. 7. Análisis de los diferentes tipos de escenarios de contenedores

6. CONCLUSIONES

El sostenimiento del ritmo de consumo a mediano y largo plazo depende de estrategias que permitan el reciclaje de los desechos y el fortalecimiento de una economía circular que realice un cambio sistémico, en la investigación y la innovación, tanto tecnológica como logística. La reducción, reciclaje y eliminación de los desechos finales de *e-waste* se ha convertido uno de los principales objetivos para el desarrollo sostenible de la creciente industria tecnológica.

Procesos de recolección ineficientes y asignación no convenientemente de vehículos conllevan a un aumento de las emisiones de gases contaminantes y de efecto invernadero, y mayores costos de proceso. Así entonces, la optimización de las rutas de la casa al vertedero para la

recolección de residuos tecnológicos, producen beneficios tanto económicos como ambientales. El problema de recolección de residuos tecnológicos es un problema derivado del VRP cuyo objetivo principal es la minimización de los *km* recorridos para los distintos escenarios de recolección con locaciones predeterminadas y distintos tipos de vehículos. También, se establecieron funciones derivadas para decidir el tipo de vehículo y cantidad de locaciones. El coste vehicular, la emisión de gases efecto invernadero (CO₂), horas trabajadas, y consumo de combustible (diésel).

Las metaheurísticas son técnicas algorítmicas cuyo propósito general es ofrecer una estrategia de búsqueda global para explorar un espacio de soluciones. En particular, hemos presentado tres tipos de metaheurísticas, una que especializa la búsqueda de soluciones a través de una estrategia basada en la búsqueda inteligente en proceso cooperativo y basado en el comportamiento exitoso de las colonias de hormigas conocido como ACO. La segunda, propuesta se basa en una metaheurística poblacional basada en el proceso de la evolución conocida cGA, y finalmente un enfoque altamente conocido y basado en algoritmos de trayectoria denominado SA.

El algoritmo ACO, ha obtenido la mejor performance para la minimización de las cantidades de kilómetros recorridos para todos los escenarios con una confianza estadística del 95%, respecto a los algoritmos cGA y SA. En este caso y para las instancias analizadas ACO confirma su óptimo desempeño para problemas derivados del TSP.

Para la elección de la cantidad de locaciones óptimas para mejorar las condiciones de recolección el análisis de las variables, cantidad de *km* recorrido, coste vehicular, consumo de combustible y emisión de CO₂ indican que las mejores opciones son con 105 y 200 contenedores.

Para la elección del tipo de vehículo con el objeto de mejorar las condiciones de recolección, se puede inferir que la opción los vehículos de alta carga y mayor automatización del proceso (**C32**) tienen un mejor desempeño cuando se tomó como base de análisis las variables, cantidad de *km* recorrido y cantidad de horas de trabajo. Para las variables consumo de combustible y emisión de CO₂ los vehículos de menor porte y sin automatización (**C16**) tienen mejores resultados. Solo para el coste vehicular la opción de vehículo con capacidad de 22 m³ (**C22**) es la mejor decisión.

Como trabajo futuro se analizarán diferentes escenarios, escalando la cantidad de contenedores, así como también variando su nivel de llenado.

7. AGRADECIMIENTOS

Los autores, agradecen al equipo de trabajo del Laboratorio de Tecnologías Emergentes (LabTEm) del Instituto de Tecnología Aplicada (ITA) y a la Universidad Nacional de la Patagonia Austral (UNPA), por la colaboración y por todo el financiamiento realizado en el desarrollo de este trabajo.



REFERENCIAS

- AKPINAR, S. (2016), Hybrid large neighbourhood search algorithm for capacitated vehicle routing problem, *Expert Systems with Applications*, Volume 61, 2016, Pages 28-38, ISSN 0957-4174.
- ALBA, E., DORRONSORO, B. (2009). Cellular genetic algorithms (Vol. 42). Springer Science & Business Media.
- ALZAQEBAH, M., ABDULLAH, S., JAWARNEH, S. (2016), Modified artificial bee colony for the vehicle routing problems with time windows, *SpringerPlus* 5 (1) (2016) 1298. DOI 10.1186/s40064-016-2940-8.
- BAXTER, J., LYNNG, K.A., ASKHAM, C., HANSSSEN, O.J. (2016). “High-quality collection and disposal of e-waste: environmental impacts and resultant” issues. *Waste Manage.* 57, 17–26.
- BYRSKI, A., ŚWIDERSKA, E., ŁASISZ, J., KISIEL-DOROHINICKI, M., LEANAERTS, T., SAMSON, D., INDURKYHYA, B., NOWÉ, A. (2017) Socio-cognitively inspired ant colony optimization, *Journal of Computational Science*, Volume 21, 2017, Pages 397-406, ISSN 1877-7503, <https://doi.org/10.1016/j.jocs.2016.10.010>.
- BOUSSAÏD, I., LEPAGNOT, J., SIARRY, P. (2013). A survey on optimization metaheuristics, *Information Sciences*, Volume 237, 2013, Pages 82-117, ISSN 0020-0255, <https://doi.org/10.1016/j.ins.2013.02.041>.
- DANTZIG, G.B., RAMSER, J. (1959). The truck dispatching problem, *Manage. Sci.* 6 (1) (1959) 80–91.
- DORIGO, M., MANIEZZO, V., COLORNI, A. (1996). The ant system: optimization by a colony of cooperating agents, *IEEE Transactions on Systems, Man, and Cybernetics Part B* 26 29–41.
- EZZATNESHAN, A. (2010). An Algorithm for the Vehicle Problem, *International Journal of Advanced Robotic Systems*, Vol. 7, No. 2, 2010, pp. 125-132.
- GENDREAU, M., POTVIN, J.Y., BRAUMLAYSY, O., HASLE, G., LOKKETANGEN, A. (2008) Metaheuristics for the vehicle routing problem and its extensions: a categorized bibliography, in: *The Vehicle Routing Problem: Latest Advances and New Challenges*, Springer, US, 2008, pp. 143–169.
- GROSSMAN, E. (2005) *High Tech Trash: Digital Devices, Hidden Toxics, and Human Health*. Island Press, Washington, pp. 133e134.
- IKHLAYEL, M. (2018). Development of management systems for sustainable municipal solid waste in developing countries: a systematic life cycle thinking approach, *Journal of Cleaner Production*, Volume 180, 2018, Pages 571-586, ISSN 0959-6526. <https://doi.org/10.1016/j.jclepro.2018.01.057>.
- KAO, Y., CHEN, M-H, HUANG, Y-T. (2012) A hybrid algorithm based on ACS and PSO for capacitated vehicle routing problems, *Mathematical Problems in Engineering*, Volume 2012, Article ID 726564, pages 1-17, <http://dx.doi.org/10.1155/2012/726564>.
- LENSTRA, J.K., KAN, A.R. (1981). Complexity of vehicle routing and scheduling problems, *Networks* 11 (1981) 221–227.

- LIN, C., CHOY, K.L., HO, G.T.S., Ng, T.W. (a), (2014). A Genetic Algorithm-based optimization model for supporting green transportation operations, *Expert Systems with Applications*, Volume 41, Issue 7, 2014, Pages 3284-3296, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2013.11.032>.
- LIN, C., CHOY, K.L., HO, G.T.S., CHUNG, S.H., LAM, H.Y. (b), (2014). Survey of Green Vehicle Routing Problem: Past and future trends, *Expert Systems with Applications*, Volume 41, Issue 4, Part 1, 2014, Pages 1118-1138, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2013.07.107>.
- MENIKPURA, S.N., SANG-ARUN, J., BENGTSSON, M. (2013). Integrated solid waste management: an approach for enhancing climate co-benefits through resource recovery. *Journal of Cleaner Production*, Volume 58, 2013, Pages 34-42, ISSN 0959-6526, <https://doi.org/10.1016/j.jclepro.2013.03.012>.
- MENIKPURA, S.N., SANTO, A., HOTTA, Y. (2014). Assessing the climate co-benefits from Waste Electrical and Electronic Equipment (WEEE) recycling in Japan. *Journal of Cleaner Production*, Volume 74, 2014, Pages 183-190, ISSN 0959-6526, <https://doi.org/10.1016/j.jclepro.2014.03.040>.
- NIAZY, S. N., BADR, A. (2012). Complexity of capacitated vehicles routing problem using cellular genetic algorithms, *International Journal of Computer Science Network Security*. 12 (2) (2012) 5.
- NOWAKOWSKI, P., KRÓL, A., MRÓWCZYNSKA, B. (2017), Supporting mobile WEEE collection on demand: A method for multi-criteria vehicle routing, loading and cost optimisation, *Waste Management*, Volume 69, 2017, Pages 377-392, ISSN 0956-053X, <https://doi.org/10.1016/j.wasman.2017.07.045>.
- NOWAKOWSKI, P., SZWARC, K. & BORYCZKA, U. (2018). Vehicle route planning in e-waste mobile collection on demand supported by artificial intelligence algorithms, *Transportation Research Part D: Transport and Environment*, Volume 63, 2018, Pages 1-22, ISSN 1361-9209.
- NOWAKOWSKI, P., SZWARC, K. & BORYCZKA, U. (2020). Combining an artificial intelligence algorithm and a novel vehicle for sustainable e-waste collection. *Science of The Total Environment*, 138726.
- METROPOLIS, N., ROSENBLUTH, A., ROSENBLUTH, M., TELLER, A. AND TELLER, E. (1953). Equations of state calculations by fast computing machines. *J Chem Phys* 21(6): 1087–1092.
- OGUCHI, M., SAKANAKURA, H., TERAZONO, A. (2012). Toxic metals in WEEE: characterization and substance flow analysis in waste treatment processes. *Science of The Total Environment*, Volumes 463–464, 2013, Pages 1124-1132, ISSN 0048-9697.
- ROBERTSON, G. (1987). Parallel implementation of genetic algorithms in a classifier system. In *Second International Conference on Genetic Algorithms (ICGA)*, pages 140{147, 1987.
- SALHOFER, S., SCHNEIDER, F., OBERSTEINER, G. (2007). The ecological relevance of transport in waste disposal systems in Western Europe. *Waste Manage.* 27, S47–S57. <http://dx.doi.org/10.1016/j.wasman.2007.02.025>.

- SZETO, W.Y., WU, Y., Ho, S. C. (2011) An artificial bee colony algorithm for the capacitated vehicle routing problem, *European Journal of Operational Research*, Volume 215, Issue 1, 2011, Pages 126-135, ISSN 0377-2217, <https://doi.org/10.1016/j.ejor.2011.06.006>.
- TASAN, S. A., GEN, M. (2012) A genetic algorithm based approach to vehicle routing problem with simultaneous pick-up and deliveries, *Computers & Industrial Engineering*, Volume 62, Issue 3, 2012, Pages 755-761, ISSN 0360-8352, <https://doi.org/10.1016/j.cie.2011.11.025>.
- TUBA, M., JOVANOVIC, R. (2013), Improved ACS algorithm with pheromone correction strategy for the traveling salesman problem, *Int. J. Comput. Commun. Control* 8 (3) 477–485.
- ZHANG, X., TANG, L. (2009), A new hybrid ant colony optimization algorithm for the vehicle routing problem, *Pattern Recognition Letters*, Volume 30, Issue 9, 2009, Pages 848-855, ISSN 0167-8655.