



# Medida de calidad de la planificación de recogida de residuos a partir del conocimiento del experto utilizando aprendizaje de preferencias

Laura Fdez-Díaz      Miriam Fdez-Díaz      José Ramón Quevedo Pérez      Elena Montañés Rocés  
Global R&D,      Global R&D,      Centro de Inteligencia Artificial      Centro de Inteligencia Artificial  
ArcelorMittal (España)      ArcelorMittal (España)      Universidad de Oviedo (España)      Universidad de Oviedo (España)

**Resumen**—La investigación incluida en este trabajo surge a raíz de la necesidad de optimizar globalmente el proceso de recogida de residuos de la empresa *Consortio para la Gestión de los Residuos Sólidos de Asturias (COGERSA)*. Hasta ahora, el diseño de la planificación se iba realizando progresivamente bajo demanda, por lo que su optimización no es global. Los expertos crearon la planificación de forma manual construyendo localmente las nuevas rutas de los concejos en cuanto estos solicitaban el servicio de recogida. Un diseño global teniendo en cuenta todas las características de este proceso excede la capacidad de un experto humano debido, principalmente, a la gran cantidad de recursos humanos y materiales disponibles, al alto número de contenedores que se deben recolectar, a las diferentes limitaciones de tiempo y a la dependencia del trazado de la carretera. Normalmente, este tipo de problemas se resuelve utilizando algoritmos de optimización de planificación, para los cuales uno de los requisitos es diseñar una función objetivo que evalúe la calidad de la planificación. En este sentido, el objetivo de este trabajo es diseñar una función objetivo a partir del conocimiento de los expertos que sea capaz de evaluar la calidad de una planificación global de recogida de residuos, como paso previo a una posterior optimización de la planificación. Nuestra propuesta se enmarca dentro del aprendizaje de preferencias, donde además, se propone simplificar las decisiones de los expertos, ya que deberán decidir no entre dos planificaciones completas de la ruta, sino entre dos pares de rutas, que supone una tarea bastante más asequible, incluso abordable. El resultado será una función de ranking de planificación de rutas, donde dada una planificación candidata, se le asignará una puntuación que la coloque dentro del ranking.

**Palabras clave**—Aprendizaje de preferencias, Caracterización de rutas, Función objetivo

## I. INTRODUCCIÓN

Los expertos de la empresa *Consortio para la Gestión de los Residuos Sólidos de Asturias (COGERSA)* planifican rutas de recogida de residuos según la demanda de los ayuntamientos y sin alterar las rutas ya existentes. Con el fin de optimizar en mayor medida los recursos disponibles, la empresa ha decidido realizar una única planificación conjunta. Optimizar los recursos tanto humanos como materiales, el tiempo de recogida o el consumo de combustible, entre otros, no es tarea sencilla ya que hay que tener en cuenta una serie de factores. Por ejemplo, el número de contenedores es fijo y las frecuencias de recogida vienen impuestas por el gobierno, al igual que varias restricciones en la planificación. No se deben recoger contenedores donde no se pueda llevar a cabo

la recogida de residuos, como, por ejemplo, si hay un mercado callejero o en contenedores ubicados en la entrada de colegios o institutos durante el comienzo o finalización del horario escolar. Otro factor a tener en cuenta es el tiempo de trabajo del personal o el uso de los camiones debido a que no se debe sobrepasar un cierto número de horas. También, se tendrá que controlar la distancia que recorre un camión cargado, puesto que para recorrer menos distancia cargado es mejor que el camión recoja los contenedores en el camino de regreso. Además, se debe considerar la lateralidad<sup>1</sup> de los contenedores debido a que en algunas áreas el camión tendrá que dar la vuelta para recoger un contenedor ubicado a la izquierda o derecha de la carretera.

Normalmente este tipo de problema, conocido generalmente como Problema de Enrutamiento de Vehículos (VPR, *Vehicle Routing Problem*) [1], se resuelve utilizando algoritmos de optimización de planificación, los cuales usan una función objetivo para evaluar la calidad de una determinada planificación. Sin embargo, obtener una función objetivo de este calibre teniendo en cuenta todos los factores que involucra no es una tarea trivial, aunque aprendible, como se puede ver en un clásico trabajo en el ámbito del juego de ajedrez [2]. Es por ello por lo que surge esta investigación, la cuál se centra en diseñar una función objetivo que recoja información de los expertos, quedando fuera del alcance de este trabajo la aplicación de esta función en un algoritmo de optimización. La solución que proponemos se enmarca dentro del aprendizaje de preferencias, donde los expertos deben decidir entre pares de planificaciones de rutas cuál es, a su juicio, la mejor planificación dentro de cada par. Sin embargo, esta tarea aún sobrepasa la capacidad humana, incluso la de los expertos, por lo que nuestra propuesta convierte el problema en decidir entre pares de rutas qué miembro de cada par es el mejor, en vez de entre planificaciones de rutas completas. Posteriormente, estas decisiones se utilizarán para diseñar una función objetivo, que, aunque se utilicen decisiones a nivel de ruta, será válida para evaluar planificaciones de ruta. La idea es diseñar una serie de indicadores clave (KPIs) que describan una ruta, teniendo en cuenta, en la medida de lo posible, tanto la información

<sup>1</sup>Lateralidad es la propiedad que tiene un contenedor que indica el lado de la carretera por el que se tiene que recoger.

proporcionada por los expertos como los factores involucrados en todo el proceso de recogida.

Este trabajo se organiza de la siguiente manera. La Sección II describe algunos trabajos relacionados con el tema que nos ocupa. En la Sección III se detalla el proceso de construcción de una función objetivo para evaluar una planificación de recogida de residuos. En la Sección IV se muestran los resultados de los experimentos llevados a cabo, así como la discusión de los mismos. Finalmente, la Sección V esboza algunas conclusiones y propone varias líneas de investigación de trabajo futuro.

## II. TRABAJOS RELACIONADOS

En inteligencia artificial, existen dos formas principales de obtener conocimiento de los expertos. Por un lado, si los expertos pueden describir su conocimiento, este conocimiento puede recogerse en forma de reglas, generando un sistema experto. Por otro lado, y siendo el caso que nos ocupa, si las acciones de los expertos están disponibles pero no son capaces de explicarlas, entonces, es posible utilizar técnicas de aprendizaje automático para extraer su conocimiento.

Existen en la literatura numerosos trabajos cuyas soluciones se obtienen a partir de información de los expertos. Por ejemplo, el trabajo [3] propone un modelo para detectar vertidos de petróleo a partir de información experta. Los expertos debían observar imágenes para detectar regiones sospechosas. En [4] se presenta una estrategia para optimizar la calidad de recuperación de un motor de búsqueda. Un usuario al hacer clic sobre un documento relacionado con una consulta proporciona al motor de búsqueda la información del ranking de los resultados para ese usuario, puesto que el usuario manifiesta que prefiere el documento sobre el que hace clic con respecto al resto de documentos. Esta información alimenta el sistema que genera un modelo capaz de clasificar documentos según las preferencias del usuario. En [5], se genera un modelo que ordena ganado vacuno según su calidad como productores de carne. El ganado se describe mediante medidas de su cuerpo relevantes para los expertos. Las preferencias de los expertos se capturaron y unificaron en una función de ordenación. También, [6] desarrolla una estrategia similar para analizar la información sensorial de un panel de consumidores con el fin de ordenar sus preferencias sobre ciertos productos. De la misma forma, [7] propone un método de aprendizaje automático para obtener los factores más relevantes que afectan a la empleabilidad y el empleo. Para ello, algunos académicos de diferentes campos definieron las competencias que podrían ser importantes para el empleo utilizando los datos de las universidades españolas y cuestionarios de los estudiantes. Los objetivos de este estudio fueron predecir si una persona tendría un empleo o no y extraer los factores más relevantes para conocer la forma más efectiva de preparar a los estudiantes para el mercado laboral. En otro estudio relacionado con la educación [8] se ajusta una rúbrica de una actividad académica a partir de las respuestas de los estudiantes y de las preferencias de los profesores en las respuestas. El objetivo es determinar el peso de cada elemento a partir de rankings parciales generados

por las lecturas de varias respuestas de los estudiantes a la actividad.

## III. CAPTURA DEL CONOCIMIENTO EXPERTO EN LA PLANIFICACIÓN DE LA RECOGIDA DE RESIDUOS

Antes de profundizar en la obtención de una función objetivo que capte el conocimiento experto, hay que mencionar algunos aspectos para comprender mejor el proceso de recogida de residuos que actualmente se está llevando a cabo en la empresa. Los expertos han ido planificando una serie de rutas bajo demanda, optimizadas de forma local para el área demandada en cada momento. Cada ruta comienza y finaliza en el mismo punto, un garaje. Además, cada ruta tiene un grupo de puntos geográficos de recogida que pueden incluir más de un contenedor de la misma capacidad o diferente (si hay más de un contenedor en el mismo punto de recogida, la capacidad de ese punto de recogida es la suma de las capacidades de los contenedores de ese punto). Cada ruta tiene asignado un camión y un equipo humano. Cada equipo humano está formado por recolectores y conductores y ninguno de ellos puede superar las 38 horas de trabajo semanales. Las rutas tienen forma de ramillete porque suelen constar de un área central con una alta frecuencia de recogida (el núcleo del ramillete) y otras con una frecuencia de recogida más baja (las ramas). Esto quiere decir que las rutas, aunque suelen tener la misma periodicidad, cada una tiene sus propios días de ejecución, de forma que los puntos con alta frecuencia de recogida son puntos de intersección de varias rutas y forman el núcleo del ramillete, siendo los puntos de baja frecuencia los que no forman intersección de varias rutas.

Uno de los principales problemas de la planificación actual es que las rutas tienen en general diferente duración, debido básicamente a la forma en que han sido diseñadas, por concejos y bajo demanda (aunque algunas rutas cubren más de un concejo si las áreas son pequeñas). La consecuencia inmediata de ello es que existen diferencias de uso de los camiones y diferencias en las horas de trabajo de los recolectores y conductores. Además, otros factores que dificultan el proceso de recogida son las condiciones climáticas adversas o las posibles demoras en la recogida en empresas privadas por el tiempo empleado en el acceso a los contenedores que tengan en su recinto privado. Otras dificultades son el rango de horas de recogida permitidas, la existencia de vehículos que excedan el peso permitido así como las limitaciones de altura o la dimensión del contenedor en las pequeñas poblaciones. Por otro lado, los trabajadores tienen sus propias preferencias cuando trabajan en pendiente. Por ejemplo, los conductores prefieren subir por una carretera en peores condiciones a cambio de bajar por otra que esté en mejores condiciones y los recolectores prefieren recoger los contenedores cuesta abajo. Otro tema a tener en cuenta es el tiempo de recogida ya que, dependiendo del tipo de camión, éste puede cambiar o el tiempo de descarga en las estaciones de transferencia o el tiempo que tarda el conductor en ir desde el garaje hasta el primer contenedor en la ruta y desde el último contenedor hasta el garaje. También sucede que, por ejemplo, en las



áreas rurales no hay límites de tiempo para la recogida y que en algunos lugares la lateralidad del contenedor no es una característica esencial ya que a veces los contenedores pueden haber sido cambiados. Así mismo, son los gobiernos locales quienes determinan la cantidad de contenedores y la frecuencia de recogida por superficie y población de cada área. Debido a eso, cada contenedor podría tener diferente frecuencia dependiendo del área y podrá variar según la temporada del año (por ejemplo, en verano en las zonas de playa se generan más residuos).

El objetivo de este trabajo es obtener una medida que evalúe la calidad de una planificación teniendo en cuenta, en la medida de lo posible, las restricciones y características del proceso de recogida que se acaba de describir y sirviéndose también del conocimiento de los expertos, para lo cual, nuestra propuesta consiste en utilizar aprendizaje de preferencias. En este marco, el proceso ideal sería disponer de varios pares de planificaciones de recogida de residuos sobre los cuales los expertos indicasen qué miembro de cada par sería, a su juicio, el mejor. Sin embargo, debido a la alta complejidad que presenta la planificación, ni siquiera los expertos serían capaces de decidirse entre los miembros de cada par de planificaciones. Por esta razón, se propone simplificar el problema al nivel de ruta, en lugar de considerar planificaciones completas. Por tanto, se establecerán KPIs que evalúen la calidad de una ruta en vez de la calidad de una planificación, aunque se verá más adelante que también permitirán evaluar una planificación. La descripción y el diseño de estos KPIs se detalla en la sección III-A. Una dificultad acaecida de este planteamiento es la necesidad de disponer de un número suficiente de pares de rutas sobre los cuales los expertos puedan decantarse por un miembro de cada par. Sin embargo, las únicas rutas disponibles son precisamente las que forman la planificación actual, que no son suficientes y, por tanto, surge la necesidad de crear rutas alternativas. Esta tarea se explica en la sección III-B.

#### A. Diseño de evaluación de indicadores de calidad (KPIs) para una ruta de recogida

En esta sección se proponen varios KPIs que permiten evaluar la calidad de una ruta recogiendo, en la medida de lo posible, los factores más relevantes para los expertos en recogida cuando estos diseñan una ruta. La mayoría de los KPIs por los que los expertos se inclinan están relacionados con las propiedades geográficas y se detallan y discuten a continuación.

1) *Distancia recorrida*: Uno de los KPIs más básicos que proponen los expertos es la distancia recorrida. Para obtener su valor, se considera  $\{p_1, p_2, \dots, p_n\}$  un conjunto de puntos de recogida de una ruta cuyo garaje inicial y final sea  $g$  y se obtiene a partir de otras distancias ( $D$ ) más pequeñas en el mapa, a saber:

- i) Distancia desde el garaje  $g$  al primer punto de recogida  $p_1$ ,  $D(g, p_1)$ , y desde el último punto de recogida  $p_n$  al garaje  $g$ ,  $D(p_n, g)$ .
- ii) Distancia entre puntos de recogida calculada como la suma de cada distancia entre el punto de recogida actual

$p_i$  y el siguiente punto de recogida  $p_{i+1}$ , es decir,  $D(p_1, p_n) = \sum_{i=1}^{n-1} D(p_i, p_{i+1})$

Por lo tanto, la distancia total de viaje de una ruta es la suma de dichas distancias.

$$D(g, g) = D(g, p_1) + D(p_1, p_n) + D(p_n, g) \quad (1)$$

2) *Tiempo empleado*: El tiempo empleado es uno de los KPIs más importantes que tenemos que tener en cuenta, debido al tiempo máximo de trabajo de los trabajadores y de uso de los camiones, así como a las restricciones existentes en los horarios de recogida. Debido a que solamente se dispone del tiempo empleado en las rutas diseñadas localmente por los expertos, la obtención de dicho KPI es más compleja de lo que parece, de hecho, no es posible calcularlo con la información facilitada. Por lo tanto, a partir de la información local disponible, se propone obtener un modelo de regresión que sea capaz de estimar este tiempo. En esta línea, y para facilitar el proceso de aprendizaje, se propone dividir el tiempo en dos partes:

- i) Tiempo transcurrido desde el garaje  $g$  al primer punto de recogida  $p_1$  y desde el último punto de recogida  $p_n$  al garaje  $g$ . El sistema de regresión se alimenta con la distancia y el tiempo de cada uno de estos trayectos. El resultado es una función de regresión  $T_g$  que estima el tiempo transcurrido en los tramos de la ruta que involucran el garaje.
- ii) Tiempo transcurrido entre los puntos de recogida (distancia entre el primer punto  $p_1$  y el último punto  $p_n$ ). En este caso se usa el número de puntos de recogida y el tiempo para alimentar el sistema de regresión y así obtener otra función de regresión  $T_p$ .

Una vez que están disponibles las dos funciones de regresión  $T_g$  y  $T_p$ , el tiempo de predicción utilizado en una determinada ruta será la suma de tres partes: i) del garaje  $g$  hasta el primer punto de recogida  $p_1$  que utiliza  $T_g$ , ii) del primer punto de recogida  $p_1$  hasta el último punto de recogida  $p_n$  usando  $T_p$  y finalmente iii) del último punto de recogida  $p_n$  al garaje  $g$  utilizando  $T_g$  nuevamente. Por lo tanto, el tiempo total del trayecto de una ruta es la suma de los tiempos anteriores:

$$T(g, g) = T_g(g, p_1) + T_p(p_1, p_n) + T_g(p_n, g) \quad (2)$$

Una casuística que puede darse es que el tiempo predicho sea menor que el real, en cuyo caso se superaría el tiempo de turno de trabajo. Para poder evitar este comportamiento, se propone aplicar un factor de corrección, el cuál solo podrá calcularse a partir de las rutas disponibles, que son las rutas de la planificación actual diseñadas localmente por el experto. Con este propósito, se evalúa la diferencia entre los valores reales y predichos y se supone que la muestra resultante debe seguir una distribución normal. El valor de corrección será el valor para el cual la diferencia es positiva a cierto nivel significativo. Por contra, si el tiempo predicho es mayor, no presenta ningún problema, ya que el tiempo de turno de trabajo se respetaría.

3) *Altitud acumulada*: Otro factor que los expertos consideran relevante es el relieve del terreno. Esto es así porque, por ejemplo, un terreno escarpado complica el acceso de los camiones a los contenedores. Además, no es igual de costoso que un camión vaya cuesta arriba con una mayor carga que vaya cuesta abajo, no solo por mantener el buen estado de los camiones, sino por el consumo de combustible. Por ello, el KPI que se propone para considerar el relieve del terreno es la altitud acumulada. Se puede pensar en utilizar el porcentaje de pendiente como un KPI, sin embargo, los expertos descartaron esta opción debido a que no contempla la distinción entre subir un tramo largo con pendiente más baja o subir un tramo corto con pendiente más alta.

A partir de un conjunto de puntos de la ruta <sup>2</sup>,  $t_1, \dots, t_m$  se obtienen sus respectivas altitudes  $A(t_1), \dots, A(t_m)$ . El KPI de altitud acumulada para una ruta que comienza en un garaje  $g$  y termina en el mismo garaje se evalúa de la siguiente manera.

$$A(g, g) = \sum_{i=1}^{m-1} \max(0; A(t_{i+1}) - A(t_i)) \quad (3)$$

Este KPI solo contempla la diferencia de altura en los tramos de subida, pues al tratarse de rutas circulares, la diferencia de altura en los tramos de bajada es idéntico al correspondiente a los tramos de subida.

4) *Tipo de carretera*: El tipo de carretera es también un KPI relevante para los expertos, ya que conducir por una autopista difiere considerablemente con respecto a conducir por carreteras locales. Por ejemplo, el consumo de combustible, la comodidad o el tiempo que dura el trayecto son aspectos que cambian según el tipo de la carretera. Los tipos de carreteras se clasifican según su relevancia (de mayor a menor) como autopista, autovía, carreteras regionales, carreteras locales y otras (avenida, calle, camino, plaza...).

Para tener en cuenta estos tipos de carretera, se consideran dos KPIs adicionales, a nombrar, la distancia por carreteras menos importantes ( $D_b$ ), que incluye plazas, calles, caminos, avenidas y carreteras locales, entre otros y la distancia por carreteras menos importantes y de importancia intermedia ( $D_i$ ), que incluye, además de las anteriores, carreteras regionales. Por lo tanto,  $D_b(g, g)$  y  $D_i(g, g)$  se calculan para una ruta.

5) *Carga del camión*: La carga del camión es otro aspecto por el cual los expertos mostraron gran interés ya que probaron estadísticamente que conducir muchos kilómetros con una carga pesada afecta en gran medida al consumo de combustible y al desgaste del camión. Por ello, si la recogida de residuos se realiza en el trayecto de ida y luego se regresa al garaje se estaría cargando con la carga durante todo el trayecto de vuelta. Por este motivo, parece preferible ir en primer lugar al punto de recogida más alejado de la ruta sin carga en el camión y regresar recogiendo los residuos.

No es fácil indicar de forma directa en un KPI la carga del camión, ya que el consumo de combustible o el desgaste del camión son prácticamente imposibles de estimar. Por esta

<sup>2</sup>Estos puntos incluyen los puntos de recogida y otros puntos del recorrido del camión para conseguir una mejor estimación de la altitud.

TABLE I  
RESUMEN DE KPIs CONSIDERADOS PARA EVALUAR UNA RUTA

Tramo/KPI	Distancia	Tiempo	Altitud	Distancia carr. poco importantes	Distancia carr. poco imp. + imp intermedia	Carga
Primer tramo.	$D(g, p_1)$	$T_g(g, p_1)$	$A(g, p_1)$	$D_b(g, p_1)$	$D_i(g, p_1)$	-
Segundo tramo.	$D(p_1, p_n)$	$T_p(p_1, p_n)$	$A(p_1, p_n)$	$D_b(p_1, p_n)$	$D_i(p_1, p_n)$	-
Tercer tramo.	$D(p_n, g)$	$T_g(p_n, g)$	$A(p_n, g)$	$D_b(p_n, g)$	$D_i(p_n, g)$	-
Ruta completa.	$D(g, g)$	$T(g, g)$	$A(g, g)$	$D_b(g, g)$	$D_i(g, g)$	$C(g, g)$

razón, este factor se tendrá en cuenta no a través de la propia carga del camión, sino con una medida relacionada con el consumo de combustible (ni siquiera el propio consumo de combustible). Nuestra propuesta para considerar este factor  $C$  consiste en suponer que el punto de recogida actual es el último punto de recogida de la ruta. Por lo tanto, si  $D_g$  es la distancia desde el punto de recogida actual  $p_i$  hasta el garaje final  $g$  y  $L$  es la carga del camión de los residuos recogidos desde el garaje origen  $g$  hasta el punto de recogida actual  $p_i$ , el KPI para el punto de recogida actual  $p_i$  será el producto de la carga de residuos y la distancia restante que lleva la carga hasta el final de la ruta, es decir,  $C(p_i) = L(p_i) \cdot D_g(p_i)$ . La principal dificultad llegado este punto es que no se dispone ni del volumen ni del peso de los residuos que se recogen, por lo que podría parecer que la solución más directa consistiría en estimarlo. Sin embargo, los expertos descartaron esta opción, ya que argumentaron que el ruido que puede conllevar la estimación no compensaría la posible mejora del KPI. En consecuencia, el experto recomendó establecer  $L(p_i) = 1$  para todos los puntos de recogida, dando lugar a una versión más simplificada del KPI,  $C(p_i) = D_g(p_i)$ . Finalmente, la carga del camión de toda la ruta se considera a través de la media de todos los puntos de recogida.

$$C(g, g) = \frac{\sum_{i=1}^n C(p_i)}{n} \quad (4)$$

El numerador está relacionado proporcionalmente con el consumo de combustible. Sin embargo, debido a que en general las rutas tienen un número diferente de puntos de recogida, se propone promediar precisamente por el número de puntos de recogida con el fin de hacer las rutas comparables.

*Consideraciones finales*: Dada la existencia de tres tramos claramente diferentes en cada ruta (garaje-primer punto de recogida, primer-último punto de recogida y último punto de recogida-garaje), se obtuvieron los KPIs tanto para la ruta completa (21 KPIs) como para cada uno de los tres tramos (el KPI relativo a la carga del camión únicamente se obtiene para la ruta completa). La Tabla I muestra un resumen de los KPIs que se han obtenido. Finalmente, mencionar que los KPIs diseñados, no solo permiten describir una ruta, si no también una planificación.

#### B. Creación de pares de preferencias

Como se mencionó anteriormente, solamente se dispone de rutas diseñadas de forma local de un determinado área. Sin embargo, con el fin de poder aplicar un algoritmo de aprendizaje de preferencias, es necesario construir rutas alternativas



que sirvan de comparación con las existentes. En esta línea, para cada ruta existente, se obtienen otras rutas con pequeñas variaciones aleatorias y se calculan los KPIs para todas ellas, tanto para la existente como para las obtenidas a partir de ella. Si los valores de todos los KPIs de la ruta original son mejores que los de una de las rutas obtenidas a partir de ella, entonces se tomará automáticamente como mejor ruta la ruta original. En caso contrario, se tomará como mejor ruta la obtenida a partir de ella. Por tanto, los pares de rutas (para cada ruta, se generó una única ruta con variaciones aleatorias) se dividen en tres conjuntos:

- i) Los pares de rutas donde todos los KPIs de la ruta existente son mejores que los de la ruta obtenida a partir de ella.
- ii) Los pares de rutas donde todos los KPIs de la ruta existente son peores que los de la ruta obtenida a partir de ella.
- iii) Los pares de rutas con algunos KPIs mejores en la ruta existente y el resto de KPIs mejores para la ruta obtenida a partir de ella.

De las 64 rutas ya existentes, solo hubo un par de rutas que cumplió la condición i) y otro par que cumplió la condición ii), siendo los 62 pares restantes del grupo de pares de rutas los que cumplen la condición iii). La decisión para los pares de rutas del grupo i) y ii) es obvia. Sin embargo, los pares de rutas que cumplen iii) se mostraron al experto para que manifestase sus preferencias.

Una vez que están disponibles los pares de rutas y establecida la preferencia por parte del experto, se lleva a cabo el proceso de aprendizaje. A este respecto, se prefiere una ruta con KPIs  $x$  a una ruta con KPIs  $y$  si la función de evaluación es mayor para  $x$  que para  $y$ .

$$x \succ y \Rightarrow f(x) > f(y) \Rightarrow f(x) - f(y) > 0 \quad (5)$$

En nuestro caso, se necesitaría que  $f$  sea lineal, es decir, que se cumpla que  $f(x) - f(y) = f(x - y)$ . Y por lo tanto:

$$x \succ y \Rightarrow f(x - y) > 0 \quad (6)$$

En nuestro caso, la función  $f$  sería la función objetivo que pondere los KPIs y sirva para evaluar una ruta, que como se comentó anteriormente, dado el diseño que se ha hecho de los KPIs, también servirá para evaluar una planificación. Cada par de rutas se transforma en un par de ejemplos que alimentará el sistema que genere dicha función. Los atributos  $x_i$  e  $y_i$  serían el  $i$ -ésimo KPI para las rutas  $x$  e  $y$  respectivamente y las clases serían +1 y -1, dependiendo de si se prefiere la primera ruta del par o la segunda. Si  $x \succ y$ , el par de ejemplos generados serían  $(x_1 - y_1) \dots (x_n - y_n) \rightarrow +1$  (positivo) y  $(y_1 - x_1) \dots (y_n - x_n) \rightarrow -1$  (negativo). A partir de este conjunto de ejemplos, se generará un modelo de clasificación lineal, que permitirá inducir la función objetivo  $f$ . Particularmente, el valor numérico obtenido por el modelo lineal aplicado a una ruta o planificación nos proporcionará la posición en el ranking de dicha ruta o planificación.

## IV. EXPERIMENTOS

En esta sección se describen los experimentos realizados para obtener sendos modelos i) de regresión que estime el tiempo empleado en una ruta y ii) de ranking para evaluar la calidad de la ruta. Sin embargo, previamente, se discute sobre los sistemas de información geográfica empleados para el cálculo de los KPIs.

### A. Sistemas de información geográfica para obtener los KPIs

Los KPIs se calcularon mediante un sistema de información geográfica (GIS) llamado *Open Source Routing Machine* (OSRM) (<https://map.project-osrm.org/>) y basado en *OpenStreetMap* ([www.openstreetmap.org](http://www.openstreetmap.org)). Hay una variedad de proyectos que han utilizado OSRM<sup>3</sup> y OSM<sup>4</sup>.

A pesar de que OSRM no incluye datos de altitud y ofrece información bastante incompleta en algunas áreas de baja densidad de población porque son los usuarios los que incorporan los datos, es una buena opción ya que además de no tener coste alguno, su documentación y su comunidad es muy extensa.

Otras alternativas a OSRM son *Google Maps* (<https://www.google.com/maps>) que incorpora datos de elevación e información geográfica muy completa, *Mapbox* (<https://www.mapbox.com/>) que está equipado con un módulo de enrutamiento orientado al tráfico, *GraphHopper* (<https://www.graphhopper.com/>) que dispone de una API de optimización de rutas y también de datos de elevación, *Mapzen Valhalla* (<https://mapzen.com/>) que además de permitir diferentes tipos de vehículos, también calcula la forma más eficiente de visitar múltiples destinos y tiene datos de elevación. Sin embargo, todos presentan la desventaja de no ser libres para una elevada cantidad de solicitudes a sus servidores.

Por otro lado, para paliar la carencia de OSRM de proporcionar datos de altitud, proponemos utilizar el modelo de elevación global denominado GMTED2010 (<https://lta.cr.usgs.gov/GMTED2010>), debido a que el número de solicitudes no está limitado. Este sistema fue desarrollado por el Servicio Geológico de los EE. UU. (USGS) y la Agencia Nacional de Inteligencia Geoespacial (NGA). Así, OSRM proporciona un conjunto de puntos de un tramo que alimentan al sistema GMTED2010 para obtener la altitud de los mismos.

### B. Regresión

Los modelos  $T_g$  y  $T_p$  se crearon utilizando la librería Caret4 (*classification and regression training*) en R. Se compararon los métodos *Linear Regression* (LiR), *Bagged CART* (BC), *Bayesian Generalized* (BG), *Boosted Tree* (BT), *Random Forest* (RF) y *Bayesian Ridge Regression* (BRR). Los valores de los parámetros fueron  $maxdepth=2$  y  $mstop=50$  para BT y  $mtry=1$  para RF. La Tabla II muestra el error cuadrático medio (RMSE, *Root Mean Square Error*) y su desviación estándar (RMSE SD) obtenidos en validación cruzada con 10

<sup>3</sup> *I Bike Cph* (<https://www.ibikecph.dk/en>), *Cycle.Travel* (<http://cycle.travel/>) y *MAPS.ME* (<https://maps.me/>)

<sup>4</sup> *Waymarked Trails* (<http://www.waymarkedtrails.org/>), *Open Topo Map* (<https://opentopomap.org/>), *MTBmap* (<https://openmtbmap.org/es/>) o *Thunderforest* (<http://www.thunderforest.com/>)

TABLE II  
 RMSE Y RMSE SD PARA LOS MODELOS DE REGRESIÓN  $T_g$  Y  $T_p$ 

Algoritmo	Modelo $T_g$		Modelo $T_p$	
	RMSE	RMSE SD	RMSE	RMSE SD
LiR	489,65	82,18	525,72	163,41
BC	530,91	83,69	693,10	285,93
BG	489,65	82,18	525,72	163,41
BT	498,67	75,34	665,98	273,68
RF	542,87	78,55	521,35	156,71
BRR	<b>489,50</b>	83,00	<b>520,70</b>	167,14

 TABLE III  
 C-INDEX DE LOS ATRIBUTOS

Algoritmo	5KPIs	6KPIs	15KPIs	16KPIs	21KPIs
SVM	0,4857	0,7429	0,7714	0,8000	0,7714
LoR	0,7714	<b>0,8857</b>	0,7714	0,8000	0,8000

*folds* y 3 repeticiones, siendo BRR el método que mejores resultados ofrece para ambos modelos  $T_g$  y  $T_p$ .

### C. Preferencias

En el aprendizaje de preferencias se utilizó regresión logística (LoR, *Logistic Regression*) y máquinas de vectores soporte (SVM, *Support Vector Machines*) [9] con *kernel lineal*. Se trata de sendos sistemas de clasificación que proporcionan una puntuación que sirve como valor de ordenación y que han sido aplicados con anterioridad en otros ámbitos [5], [6] o [8]. En el ámbito que nos ocupa, se varió el número de atributos (KPIs): 5 KPIs (KPIs de la ruta completa sin la carga del camión), 6 KPIs (KPIs de la ruta completa), 15 KPIs (5 KPIs por cada uno de los tres tramos), 16 KPIs (KPIs por tramos junto con la carga del camión) y 21 KPIs (todos los KPIs, los 5 KPIs de cada tramo junto con los 6 KPIs de la ruta completa).

Como medida de evaluación del modelo se utilizó el C-index, que se estimó mediante validación cruzada por bloques. Cada bloque está formado por una ruta y su variante modificada aleatoriamente. Para cada bloque se calculó el C-Index y finalmente se promediaron los C-Index de todos los bloques. C-index es la probabilidad de concordancia entre los valores predichos y los valores reales, es decir,  $C\text{-Index} = \frac{1}{|\epsilon|} \sum_{\epsilon_{ij}} 1_{f(x_i) < f(x_j)}$ .

La tabla III muestra el C-Index de todas las variantes, siendo LoR mejor o igual que SVM. El mejor resultado se obtiene cuando se considera la carga del camión, resultado, en cierta medida, esperable, ya que los expertos auguraban la relevancia de este factor. Sin embargo, la separación en tramos con recogida de contenedores y tramos de salida y llegada al garaje no resulta adecuada, puesto que el mejor resultado se obtiene cuando no se realiza dicha separación. Es, por tanto, el uso de 6 KPIs la elección preferible.

### V. CONCLUSIONES Y TRABAJO FUTURO

En este artículo se propone una medida que evalúe la calidad de una ruta o planificación de recogida de residuos de la empresa COGERSA. Para ello se ha tenido en cuenta, en la medida de lo posible, las restricciones y características del

proceso que los expertos nos han proporcionado. Se diseñó una serie de KPIs que describen las rutas y se aplicó un sistema de aprendizaje de preferencias para obtener una función objetivo que capturase el conocimiento de los expertos. Para ello, fue necesario crear rutas con pequeñas variaciones aleatorias para que los expertos pudiesen decidir qué ruta preferían (su ruta o la variada aleatoriamente). También fue necesario inducir dos modelos de regresión para poder estimar uno de los principales KPIs de gran interés para los expertos, el tiempo de recorrido de una ruta. Las rutas fueron divididas en tres tramos claramente diferenciados (garaje a primer punto de recogida, primer a último punto de recogida y último punto de recogida a garaje) y los KPIs también fueron obtenidos para dichos tramos. Sin embargo, la mejor función objetivo se obtuvo cuando se consideran exclusivamente los KPIs de la ruta completa. Además se puede concluir que la carga del camión es uno de los factores relevantes en la recogida, algo que los expertos ya intuían. Como trabajo futuro se podrían incorporar nuevos KPIs utilizando un sistema de red vial o establecer cambios en las rutas si las carreteras estuvieran cerca de áreas con problemas de tráfico.

### AGRADECIMIENTOS

Esta investigación ha sido parcialmente financiada por el Ministerio de Economía y Competitividad español a través del proyecto TIN2015-65069 y por el Instituto de Desarrollo Económico del Principado de Asturias (IDEPA) a través del proyecto RDI *Smart Waste Collection* (SWC), desarrollado por el consorcio COGERSA, SADIM S.A., S.M.E-grupo HUNOSA y ABAMobile (IDE/2015/000863, IDE/2015/000864 e IDE/2015/000865).

### REFERENCIAS

- [1] P. Toth and D. Vigo, "The vehicle routing problem, ser. *siam monographs on discrete mathematics and applications*," *Society for Industrial and Applied Mathematics*, 2002.
- [2] A. L. Samuel, "Some studies in machine learning using the game of checkers," *IBM Journal of Research and Development*, vol. 3, no. 3, pp. 210–229, July 1959.
- [3] M. Kubat, R. C. Holte, and S. Matwin, "Machine learning for the detection of oil spills in satellite radar images," *Machine learning*, vol. 30, no. 2-3, pp. 195–215, 1998.
- [4] T. Joachims, "Optimizing search engines using clickthrough data," in *Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining*. ACM, 2002, pp. 133–142.
- [5] A. Bahamonde, G. F. Bayón, J. Díez, J. R. Quevedo, O. Luaces, J. J. Del Coz, J. Alonso, and F. Goyache, "Feature subset selection for learning preferences: a case study," in *Proceedings of the twenty-first international conference on Machine learning*. ACM, 2004, p. 7.
- [6] A. Bahamonde, J. Díez, J. R. Quevedo, O. Luaces, and J. J. del Coz, "How to learn consumer preferences from the analysis of sensory data by means of support vector machines (svm)," *Trends in food science & technology*, vol. 18, no. 1, pp. 20–28, 2007.
- [7] F. J. García-Peñalvo, J. Cruz-Benito, M. Martín-González, A. Vázquez-Ingelmo, J. C. Sánchez-Prieto, and R. Therón, "Proposing a machine learning approach to analyze and predict employment and its factors," *International Journal of Interactive Multimedia and Artificial Intelligence*, no. In Press, 2018.
- [8] J. Quevedo and E. Montañés, "Obtaining rubric weights for assessments by more than one lecturer using a pairwise learning model," *International Working Group on Educational Data Mining*, 2009.
- [9] D. Fradkin and I. Muchnik, "Support vector machines for classification," *DIMACS Series in Discrete Mathematics and Theoretical Computer Science*, vol. 70, pp. 13–20, 2006.