
CONTROL PREDICTIVO HÍBRIDO PARA EL PROBLEMA DE RUTEO DINÁMICO DE VEHÍCULOS BASADO EN OPTIMIZACIÓN MULTIOBJETIVO EVOLUCIONARIA (EMO)

Alfredo Núñez V., Marcela Riquelme H., Doris Sáez H.
Departamento de Ingeniería Eléctrica, Universidad de Chile, Santiago, Chile
Fono: (56 2) 978 49 22, Fax: (56 2) 695 38 81
E-mail: alfnunez@ing.uchile.cl, marrique@ing.uchile.cl, dsaez@ing.uchile.cl
Cristián E. Cortés
Departamento de Ingeniería Civil, Universidad de Chile, Santiago, Chile.
Fono: (56 2) 978 43 80, Fax: (56 2) 689 42 06, E-mail: ccortes@ing.uchile.cl

RESUMEN

Presentamos un enfoque de control predictivo adaptivo híbrido (HAPC) para resolver el problema dinámico de recoger y dejar pasajeros (DPDP), comandado por una función objetivo dinámica que incluye dos dimensiones: costo de usuarios y costo de operador. Dado que se imponen estas dos componentes contrapuestas en la función objetivo, el problema se enfrenta bajo una óptica de Optimización Multiobjetivo Evolucionaria (EMO). En este caso, se busca minimizar el costo operador y el costo usuario. Así, usando EMO, para el despachador será transparente el compromiso entre ambos costos en cada decisión dinámica de ruteo. Se propone para cada instante usar un algoritmo genético convencional para encontrar el frente de Pareto Óptimo del problema de DPDP, cuyo conjunto de Pareto Optimal asociado es un conjunto de soluciones del problema. Dado que sólo una de las secuencias solución debe ser aplicada al sistema de vehículos y usuarios, se usan distintos criterios para explorar diversas formas de ocupar la información que entrega el frente de Pareto Óptimo dinámico. Experimentos ilustrativos ocupando simuladores del proceso son utilizados para mostrar los beneficios del nuevo enfoque.

Palabras claves: ruteo dinámico de vehículos, Optimización Multiobjetivo Evolucionaria, Control Predictivo Híbrido

ABSTRACT

In this paper a hybrid adaptive predictive control approach (HAPC) to solve the dynamic pickup and delivery problem (DPDP) is presented, written in terms of a dynamic objective function that includes two dimensions: users and operator costs. Provided these two apparent opposite objective function components, the problem is solved by using an Evolutionary Multiobjective Optimization (EMO) technique. In this case, the idea is to minimize both, users and operator costs. Thus, by using EMO, the trade off between these two costs will become clear for the dispatcher when taking dynamic routing decisions. At every instant, we propose the use of a traditional genetic algorithm to find the Optimal Pareto front associated with the DPDP, whose Pareto associated Optimal set is in fact, a set of solutions of the problem. Since only one solution has to be applied to the system of vehicles and users every time a new requirement appears, several criteria are utilized in order to properly use the information provided by the Dynamic Optimal Pareto front. Illustrative experiments through simulation of the process are presented to show the potential benefits of the new approach.

Keywords: Dynamic vehicle routing, EMO (Evolutionary multiobjective optimization), Hybrid Predictive Control

1. INTRODUCCIÓN

El problema dinámico de recoger y dejar pasajeros (*dynamic pick-up and delivery problem* DPDP) se formula como un conjunto de requerimientos de traslado de personas desde un origen (*pick up*) a un destino (*delivery*) servido por una flota de vehículos localizada inicialmente en varias bodegas (Desrosiers, Soumis, Dumas, 1986; Savelsbergh y Sol, 1995). La dimensión dinámica del problema aparece cuando un subconjunto de requerimientos no es conocido con anticipación y se deben tomar decisiones de despacho en tiempo real. El DPDP ha generado gran interés en el último tiempo, debido a que con el alto avance de las tecnologías de comunicación e información es posible abordar este tipo de problemas de alta complejidad computacional.

La formulación del problema debe considerar una función objetivo a optimizar para tomar decisiones apropiadas de despacho en tiempo real. Cuando el problema es dinámico, una función objetivo bien definida debiera considerar la predicción de la demanda futura y en consecuencia, de los tiempos de espera y viaje de pasajeros en el sistema debido a potenciales decisiones de reruteo, aspectos normalmente desestimados en la literatura especializada. Por otra parte, una buena especificación debiera también incluir predicción de las condiciones de tráfico del sistema para hacer estimaciones más realistas de los tiempos de viaje de los vehículos en el espacio y en el tiempo. Esta fuente de incerteza adicional no ha sido tratada extensivamente en la literatura en el caso de problemas de ruteo dinámico, principalmente debido a la complejidad computacional.

Respecto de modelos de decisión predictivos, existe información en la literatura reciente en el campo de ruteo de vehículos y despacho que intenta aprovechar información sobre eventos futuros para mejorar la toma de decisiones (Ichoua et al., 2005; Topaloglu y Powell, 2005). Sáez et al (2007) y Cortés et al. (2007) desarrollaron una formulación analítica para el problema DPDP como un problema de Control Adaptivo Predictivo Híbrido (HAPC) mediante modelos basados en variables de estado, resuelto con algoritmos provenientes de la inteligencia computacional (GA y Clustering Difuso).

Desde una óptica de sistema (operador y usuarios), la correcta definición de una función objetivo predictiva debe incorporar tanto el costo del operador como el costo de usuarios a través del nivel de servicio, lo que se traduce en una función de los tiempos de viaje y espera estimados. Además, considerando el ambiente dinámico de la toma de decisiones, la función objetivo debe incluir el efecto de potenciales reruteos en decisiones de despacho actuales, cuantificando apropiadamente su impacto en los niveles de servicio de los usuarios afectados por tales decisiones, así como en los costos de operación adicionales asociados, todo lo anterior en un ambiente de condiciones de tráfico inesperadas, las que podrían interferir la operación de los vehículos bajo reglas de despacho.

Estas dos dimensiones que se incorporan en la función objetivo del sistema (por un lado interés del operador por minimizar los costos de operación, y por otro de los usuarios por obtener un buen nivel de servicio) son objetivos contrapuestos. De hecho, ofrecer un mejor nivel de servicio implica viajes más directos, es decir, menores tasas de ocupación de los vehículos y por ende mayores costos de operación para atender la misma demanda con la misma flota. Por otra parte, políticas de ruteo más eficientes desde una óptica de operación necesariamente se traducen en mayores tasas de ocupación de los vehículos, rutas más largas y por consiguiente, mayores tiempos de espera y viaje de los usuarios. La pregunta entonces es como pesar apropiadamente

ambas componentes de la función objetivo para tomar decisiones adecuadas de planificación y despacho de flota. La verdad es que la respuesta a esta interrogante no es clara y depende de quién tome las decisiones y en qué contexto. Para orientar la respuesta a esta incógnita, en este trabajo se plantea un enfoque multiobjetivo para darle un tratamiento más general al DPDP formulado como un problema HAPC por Cortés et al. (2007). Particularmente, se utilizará Optimización Multiobjetivo Evolucionaria (EMO) para resolver la formulación dinámica del DPDP, considerando las dos dimensiones contrapuestas (operador y usuarios) en la función objetivo.

En la literatura de Optimización Multiobjetivo Evolucionaria (EMO), se encuentra más que nada resolución de problemas estáticos (Hajri-Gabouj, 2003). La literatura en problemas EMO dinámicos es escasa y sin metodologías claras de evaluación (M. Farina et. al, 2004). Un ejemplo de optimización multiobjetivo aplicada a sistemas de transporte, corresponde un modelo para la negociación en la tarificación de servicios Metro-Bus (S. Jara y A. Tudela, 1991). En este artículo se diseñan servicios con tarifa integrada que logran, simultáneamente, beneficios para los usuarios mediante menores tarifas y tiempos de viaje, ganancias para los operadores de buses y mantención del nivel de ingresos netos del Metro.

En este trabajo, reformulamos el DPDP de Cortés et al. (2007), que fue resuelto usando una función objetivo convencional (mono-objetivo) de control predictivo, bajo una óptica EMO dinámico. El problema de optimización no lineal es NP-Hard, por lo que será resuelto eficientemente en términos de precisión y tiempo computacional ocupando algoritmos genéticos (GA). Utilizar EMO permitirá obtener soluciones que no son exploradas con el típico HAPC para resolver el problema DPDP, lo cual es un apoyo crucial para el tomador de decisiones en buscar opciones razonables de políticas de servicio. A continuación se describe el problema y se establece la formulación de la función objetivo predictiva propuesta en su versión mono-objetivo. En la Sección 3 se propone la contraparte EMO de la formulación. En la Sección 4 se muestra y analiza resultados por simulación, y finalmente algunas conclusiones y líneas de trabajo futuras.

2. FORMULACIÓN DEL PROBLEMA

2.1. Enfoque HAPC para DPDP y formulación de modelo dinámico

El modelo predictivo es formulado considerando tres variables de estado: tiempo estimado de llegada a una parada, carga del vehículo entre paradas y la posición del vehículo. Para el cálculo de estas variables se considera dos fuentes de estocasticidad. La primera con respecto a la demanda futura desconocida entrando al sistema en tiempo real, y la segunda proveniente de las condiciones de tráfico de la red, en sus dimensiones espacial y temporal. El tamaño de la flota se asume conocido. La ubicación específica de un requerimiento (que incluye tanto su recogida como entrega) es conocida solamente después que la correspondiente llamada en tiempo real es recibida por el despachador. Un vehículo seleccionado es entonces re-ruteado en tiempo real para insertar el nuevo requerimiento dentro de su ruta predefinida (secuencia) mientras los vehículos están en movimiento. La asignación del vehículo y de la ubicación dentro de la secuencia anterior para la nueva llamada es decidida por el despachador (controlador) basado en la función objetivo que depende de las variables de estado asociadas al estado en tiempo real de los vehículos (ver Sección 2.2).

Considere un área de influencia y un conjunto de F vehículos. La flota se encuentra en operación viajando dentro del área según rutas predefinidas. La demanda por servicio η es desconocida, aparece en tiempo real y se caracteriza por dos posiciones, recogida (*pickup*) y entrega (*delivery*), y por el instante en que ocurre la llamada. El enfoque de modelación es en tiempo discreto y donde los pasos se activan cuando ocurre un evento relevante, por ejemplo cuando aparece una llamada que solicita servicio en tiempo real. Se denota por k al índice que representa el k -ésimo instante en la secuencia discreta de eventos. En cualquier instante k , a cada vehículo j se le asigna una secuencia de tareas que incluyen recogidas y entregas. Esas secuencias se pueden representar por una función $S_j(k) = [s_j^0(k) \ s_j^1(k) \ \dots \ s_j^i(k) \ \dots \ s_j^{w_j(k)}(k)]^T$, en donde el i -ésimo elemento de la secuencia representa a la i -ésima parada del vehículo j dentro de su ruta, y $w_j(k)$ es el número de paradas. Una parada está definida por una coordenada y un usuario que pide el servicio. La condición inicial ($s_j^0(k)$) corresponde al último requerimiento satisfecho. El conjunto de secuencias $S(k) = \{S_1(k), \dots, S_j(k), \dots, S_F(k)\}$ asociadas a los vehículos de la flota corresponden a la variable de control o variable manipulada $u(k)$. El despachador HAPC propuesto selecciona las secuencias óptimas basándose en la minimización de una función objetivo ad-hoc. De este modo, una secuencia de paradas asignadas al vehículo j en el instante k , $S_j(k)$, está dada por:

$$S_j(k) = \begin{bmatrix} z_j^0(k) & 1 - z_j^0(k) & P_j^0(k) & r_j^0(k) & \Omega_j^0(k) \\ z_j^1(k) & 1 - z_j^1(k) & P_j^1(k) & r_j^1(k) & \Omega_j^1(k) \\ z_j^2(k) & 1 - z_j^2(k) & P_j^2(k) & r_j^2(k) & \Omega_j^2(k) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ z_j^{w_j(k)}(k) & 1 - z_j^{w_j(k)}(k) & P_j^{w_j(k)}(k) & r_j^{w_j(k)}(k) & \Omega_j^{w_j(k)}(k) \end{bmatrix} \quad (1)$$

donde $z_j^i(k)$ es igual a 1 si la parada i es una recogida y toma el valor 0 si es una entrega. $P_j^i(k) \in R^2$ es la posición geográfica en coordenadas espaciales de la parada i asignada al vehículo j , $r_j^i(k)$ identifica al pasajero que está realizando la llamada y $\Omega_j^i(k)$ es el número de pasajeros asociados al requerimiento $r_j^i(k)$. La Figura 1a) muestra una secuencia asignada al vehículo j en el instante k ($S_j(k)$), lo cual corresponde a una imagen de las tareas asignadas a un vehículo. $\hat{T}_j^i(k)$ representa el tiempo de salida esperado del vehículo j desde la parada i , $\hat{L}_j(k)$ es la carga esperada del vehículo j al salir de la parada i , y $X_j(k)$ denota la posición actual del vehículo en el instante k , que debe estar entre las posiciones $P_j^0(k)$ y $P_j^1(k)$. En este trabajo, las condiciones de tráfico se modelan a través de una distribución comercial de velocidades asociadas a los vehículos. Esta distribución considera dos dimensiones: espacial y temporal. La distribución real de velocidades se asume desconocida y se denota por $v(t, p, \varphi)$, que depende de una fuente estocástica $\varphi(t)$ que representa las condiciones de tráfico de la red variantes en el tiempo, y de una función p definida por la recta que une dos paradas consecutivas. Además, se asume conocida una distribución de velocidades para la zona urbana durante un periodo típico de congestión recurrente y ésta se obtiene a partir de registros históricos de velocidades y se representa por un modelo de velocidad $\hat{v}(t, p)$.

El lazo cerrado del sistema de ruteo se muestra en la Figura 1b). El HAPC representado por el despachador toma las decisiones de ruteo en tiempo real basado en la información que tiene del sistema (proceso) y en los valores de los atributos de la flota de vehículos que le permiten evaluar el modelo bajo distintos escenarios. La demanda (η) y las condiciones de tráfico (φ) son perturbaciones en este sistema. Un mecanismo adaptativo para el control propuesto es agregado en la Figura 1, para adaptar la dimensión del modelo y modificar la función objetivo adecuándola a predicciones de demanda y tráfico que varían en el tiempo.




Figura 1: Enfoque HAPC para resolver DPDP. a) Representación de una secuencia del vehículo j y sus paradas. b) Diagrama lazo cerrado del Control Híbrido Adoptivo para DPDP.

Para aplicar el enfoque de control predictivo híbrido HAPC se plantea el siguiente modelo dinámico para representar el proceso de ruteo de vehículos. Para el vehículo j , se tiene:

$$\begin{bmatrix} \hat{X}_j(k+1) \\ \hat{T}_j(k+1) \\ \hat{L}_j(k+1) \end{bmatrix} = \begin{bmatrix} f_x(S_j(k), \hat{v}(t, p)) \\ f_t(X_j(k), \hat{T}_j(k), S_j(k), \hat{v}(t, p)) \\ f_L(\hat{L}_j(k), S_j(k)) \end{bmatrix} \quad (2)$$

donde $X_j(k) \in \mathbb{R}^2$, $\hat{T}_j(k) = [T_j^0(k) \quad \hat{T}_j^1(k) \quad \dots \quad \hat{T}_j^{w_j(k)}(k)]^T$, $\hat{L}_j(k) = [L_j^0(k) \quad \hat{L}_j^1(k) \quad \dots \quad \hat{L}_j^{w_j(k)}(k)]^T$

El modelo dinámico para la posición del vehículo j está dado por:

$$\hat{X}_j(k+1) = f_x(S_j(k), \hat{v}(t, p)) = P_j^0(k) + \int_{t_k}^{t_k + \tau} \hat{v}(t, p(t)) \frac{(P_j^0(k) - P_j^1(k))}{\|P_j^0(k) - P_j^1(k)\|_2} dt \quad (3)$$

donde $t_k \leq t \leq t_k + \tau$. t_k es una variable que conecta el tiempo continuo con el tiempo discreto (k) asociado a la modelación. El tamaño de paso variable τ se define por el intervalo entre la ocurrencia de la llamada futura probable en el instante $t_k + \tau$ y la ocurrencia de la llamada previa

en $t_k \cdot \tau$ es calculado como un parámetro de sintonía para el HAPC que se ajusta con un análisis de sensibilidad que fue descrito en Sáez et al. (2007).

El vector de tiempo de salida depende de la velocidad y está dada por el siguiente modelo dinámico:

$$\hat{T}_j(k+1) = f_T(X_j(k), \hat{v}(t, p), \hat{T}_j(k), S_j(k)) = \begin{bmatrix} T_j^0(k) & t_k + \kappa_j^1(k) & t_k + \sum_{s=1}^2 \kappa_j^s(k) & \cdots & t_k + \sum_{s=1}^{w_j(k)} \kappa_j^s(k) \end{bmatrix}^T \quad (4)$$

$$\kappa_j^1(k) = \int_{x_j(k)}^{p_j^1(k)} \frac{1}{\hat{v}(t_j(\omega), \omega)} d\omega, \quad \kappa_j^i(k) = \int_{p_j^{i-1}(k)}^{p_j^i(k)} \frac{1}{\hat{v}(t_j(\omega), \omega)} d\omega \quad i = 2..w_j(k) \quad (5)$$

$\kappa_j^i(k)$ es una estimación del intervalo de tiempo entre la parada $i-1$ y la parada i para la secuencia del vehículo j en el instante k . $t_j(\omega)$ es el tiempo en el cual el vehículo j alcanza la posición ω .

El modelo dinámico para el vector de carga del vehículo depende exclusivamente de la secuencia actual y de su carga previa. Analíticamente, se tiene:

$$\hat{L}_j(k+1) = f_L(\hat{L}_j(k), S_j(k)) = \begin{bmatrix} L_j^0(k) & L_j^0(k) + (2z_j^1(k) - 1)\Omega_j^1 & L_j^0(k) + \sum_{s=1}^2 (2z_j^s(k) - 1)\Omega_j^s & \cdots & L_j^0(k) + \sum_{s=1}^{w_j(k)} (2z_j^s(k) - 1)\Omega_j^s \end{bmatrix}^T \quad (6)$$

donde z_j^s y Ω_j^s fueron definidos en la ecuación (1).

Las secuencias de los vehículos y las variables de estado propuestas satisfacen un conjunto de restricciones dadas por las condiciones reales del problema DPDP. Específicamente, se deben considerar las restricciones de precedencia, capacidad y consistencia en la resolución de problema HAPC para generar sólo secuencias factibles.

2.2. Función objetivo.

El objetivo del controlador predictivo híbrido será minimizar una función objetivo a partir de la cual se seleccionarán las mejores rutas para los vehículos. La función objetivo escogida cuantifica los costos sobre el sistema de aceptar una inserción de un nuevo requerimiento. Tal función incorpora dos dimensiones de decisión, las que normalmente se mueven en sentido opuesto. Como primera componente se incorpora el costo de los usuarios del sistema, incluyendo tanto el tiempo de espera como el tiempo de viaje experimentado por cada pasajero que solicita servicio. Como segunda componente, se agrega el costo de operación de la flota, asumiendo tamaño de flota fijo. Esta última componente incorpora tanto un costo por unidad de distancia recorrida así como el costo incurrido por unidad de tiempo de operación de cada vehículo. En futuras aplicaciones se estudiará expresiones más complejas pero más realistas de estas componentes, tanto de nivel de servicio (costo usuario) como de operación (costo operador).

Se define un horizonte de predicción razonable N , el cual depende del problema en estudio y de la intensidad de eventos desconocidos que ocurran en el sistema en tiempo real. Si el horizonte de predicción es mayor que uno, el controlador agrega a la decisión la característica predictiva. El controlador calculará las decisiones para el horizonte de control completo N , es decir $\{S(k), \dots, S(k+N-1)\}$, mediante predicciones basadas en datos históricos, y aplicará al sistema solamente la secuencia en el siguiente instante $S(k)$, de acuerdo al horizonte deslizante. El rendimiento del esquema de ruteo de los vehículos, dependerá entonces de la calidad con que el sistema predice el impacto de posibles re-ruteos debido a inserciones provocadas por requerimientos de servicio desconocidos.

Denotando J_j^U y J_j^O como el costo de usuario y operador respectivamente, asociados a la secuencia de paradas que debe seguir el vehículo j en cierto instante, la función objetivo para un horizonte de predicción N , puede ser escrita de la siguiente manera:

$$\underset{\{S(k), S(k+1), \dots, S(k+N-1)\}}{\text{Min}} \quad J = \lambda J_1 + (1 - \lambda) J_2 \quad (7)$$

$$J_1 = \sum_{\ell=1}^N \sum_{j=1}^F \sum_{h=1}^{h_{\max}(k+\ell)} p_h^{\Delta T(k+\ell)} \cdot \left(J_j^U(k+\ell) - J_j^U(k+\ell-1) \right)_{S_j(k+\ell-2), h} \quad J_2 = \sum_{\ell=1}^N \sum_{j=1}^F \sum_{h=1}^{h_{\max}(k+\ell)} p_h^{\Delta T(k+\ell)} \cdot \left(J_j^O(k+\ell) - J_j^O(k+\ell-1) \right)_{S_j(k+\ell-2), h}$$

$$J_j^U(k+\ell) \Big|_{S_j(k+\ell-2), h} = \sum_{i=1}^{w_j(k+\ell)} \left\{ \underbrace{\mathcal{Q}_v \hat{T}_j^{i-1}(k+\ell) (\hat{T}_j^i(k+\ell) - \hat{T}_j^{i-1}(k+\ell))}_{J \text{ TIEMPO DE VIAJE}} + \underbrace{\mathcal{Q}_e z_j^i(k+\ell) (\hat{T}_j^i(k+\ell) - T_j^0(k+\ell))}_{J \text{ TIEMPO DE ESPERA}} \right\} \Big|_{S_j(k+\ell-2), h} \quad (8)$$

$$J_j^O(k+\ell) \Big|_{S_j(k+\ell-2), h} = \sum_{i=1}^{w_j(k+\ell)} \left\{ c_T (\hat{T}_j^i(k+\ell) - \hat{T}_j^{i-1}(k+\ell)) + c_L D_j(k+\ell) \right\} \Big|_{S_j(k+\ell-2), h} \quad (9)$$

En las ecuaciones (7)-(9), $k+\ell$ es el instante en el que el ℓ -ésimo requerimiento entra en el sistema, medido desde el requerimiento del instante k . $h_{\max}(k+\ell)$ es el número de posibles requerimientos en el instante $k+\ell$, $p_h^{\Delta T(k+\ell)}$ es la probabilidad de ocurrencia del h -ésimo requerimiento tipo (asociado a un patrón de viajes asociado a un par específico de zonas) durante el intervalo de tiempo $\Delta T(k+\ell)$. Las probabilidades de ocurrencia $p_h^{\Delta T(k+\ell)}$ asociadas a cada escenario son parámetros en la función objetivo y deben ser calculadas en base a datos en tiempo real, históricos o una combinación de ambos. En Sáez et al. (2007) se ocupa una zonificación basada en Fuzzy Clustering, en la cual se sistematiza la estimación de patrones de viaje.

En expresiones (8) y (9), $J_j^U(k+\ell) \Big|_{S_j(k+\ell-2), h}$, $J_j^O(k+\ell) \Big|_{S_j(k+\ell-2), h}$ representan las funciones de costo de usuario y operador asociadas al vehículo j en el instante $k+\ell$, las cuales dependen de la secuencia previa $S_j(k+\ell-2)$ y un nuevo requerimiento potencial h el cual ocurre con probabilidad $p_h^{\Delta T(k+\ell)}$, $w_j(k+\ell)$ es el número de paradas estimadas para el vehículo j en el instante $k+\ell$, $S_j(k+\ell-2), h$ es la nueva secuencia dado que h ocurrió.

Para explicitar la flexibilidad de la formulación y la consistencia económica, el tiempo de viaje es ponderado por un factor \mathcal{Q}_v , y el de espera es ponderado por un peso \mathcal{Q}_e . Del mismo modo,

asumiremos una expresión genérica del costo de operación de los vehículos, con una componente que depende de la distancia total recorrida, ponderada por un factor c_L , y otra que depende del tiempo total de operación, en este caso a costo unitario c_T . Así, $D_j^i(k + \ell)$ representa la distancia entre las paradas $i-1$ e i en la secuencia del vehículo j . Dada la naturaleza mono-objetivo de esta formulación, se generaliza la expresión (7) asumiendo un factor arbitrario λ a definir por el tomador de decisiones.

3. CONTROL PREDICTIVO HIBRIDO BASADO EN OPTIMIZACION MULTI OBJETIVO EVOLUCIONARIO (HAPC-EMO) PARA EL PROBLEMA DE RUTEO

3.1. Control Predictivo Híbrido basado en Optimización Multiobjetivo Evolucionaria (HAPC-EMO)

La estrategia HAPC-EMO es una generalización de HAPC donde la acción de control óptima se selecciona basada en un criterio que toma soluciones de la región del Pareto Óptima considerando el siguiente problema multiobjetivo:

$$\underset{\{S(k), S(k+1), \dots, S(k+N-1)\}}{\text{Min}} \quad J = \{J_1, J_2\} \quad (10)$$

con J_1 y J_2 las funciones objetivos definidas en (7). Notar que este esquema no requiere definir un parámetro arbitrario λ de la forma como se plantea en 2.2. La solución a este problema corresponde a un conjunto de secuencias de control que forman el conjunto de Pareto Óptimo. Considerando que $S^i = \{S^i(k), \dots, S^i(k+N_u-1)\}$ es una secuencia factible de acciones de control, se tienen las siguientes definiciones asociadas al problema de optimización multiobjetivo:

- Una solución S^i se dice que Pareto-domina a otra solución S^j si y solo si:

$$(J_1(S^i) \leq J_1(S^j) \wedge J_2(S^i) < J_2(S^j)) \vee (J_2(S^i) \leq J_2(S^j) \wedge J_1(S^i) < J_1(S^j))$$
- Una solución S^i se dice Pareto Óptima si y solo si no existe otra solución S^j que la domine según el criterio anterior.
- El conjunto de Pareto Óptimo P_s contiene todas las soluciones Pareto Óptima.
- El conjunto de todos los valores que toman las funciones objetivos para cada solución en P_s es conocido como el Frente de Pareto Óptimo P_F y se define como

$$P_F = \left\{ (J_1(S^i), J_2(S^i)) : S^i \in P_s \right\}.$$

En este caso, como las secuencias de control son enteras y además definidas en un conjunto factible finito, el Frente de Pareto Óptimo resultante corresponde a un conjunto con un número finito de elementos. A partir de las soluciones del frente de Pareto Óptimo para este problema de HAPC dinámico es necesario elegir tan sólo una secuencia de control $S^i = \{S^i(k), \dots, S^i(k+N_u-1)\}$ y a partir de ésta, aplicar la acción de control $S^i(k)$ al sistema según el horizonte deslizante. Por lo tanto, para la selección de esta secuencia se requiere un criterio que estará relacionado con la importancia que tenga el costo usuario (J_1) y el costo del operador (J_2). Se debe destacar que las soluciones obtenidas del problema EMO forman un conjunto que incluye los óptimos obtenidos

del problema mono-objetivo definido en la sección 2. Inclusive, se puede encontrar una relación analítica entre ambas soluciones, que para el caso mono-objetivo se reflejaría en la selección adecuada del factor de peso λ .

Una aplicación relevante de este enfoque en la decisión de despacho del controlador, es la definición de criterios para seleccionar la mejor acción de control en el momento bajo el enfoque HAPC-EMO. Por ejemplo, una vez que el mejor frente de Pareto es encontrado, distintos criterios respecto de nivel de servicio mínimo podrían ser usados dinámicamente. En este trabajo evaluaremos tres criterios de nivel de servicio:

Criterio 1: costo usuario menor que \$1000 por pasajero; Criterio 2: costo usuario menor que \$1125 por pasajero; Criterio 3: costo usuario menor que \$1250 por pasajero. En casos en que la política se cumpla para varias soluciones, se seleccionará aquella que minimice el costo operador. Resultados y análisis de estas políticas de operación a partir de simulaciones de reporta en Sección 4. A continuación en Sección 3.2, se explicará el método de optimización multiobjetivo basado en Algoritmos Genéticos (GA) propuesto para este problema.

3.2. Algoritmos Genéticos para encontrar Óptimo de Pareto

Algoritmos Genéticos (GA) es usado para resolver el problema EMO planteado. En GA, una potencial solución se denomina individuo, y puede ser representada por un conjunto de parámetros y ser descrita en una forma entera. Para esta aplicación, un individuo representará una secuencia de control factible $S^i = \{S^i(k), \dots, S^i(k+N_u-1)\}$, en donde cada gen o elemento del conjunto corresponde a una acción de control, y el largo del individuo está dado por el horizonte de control N_u . Usando GA, los individuos mejor adaptados serán seleccionados con mayor probabilidad para asegurar una buena descendencia. Los mejores padres entonces son seleccionados y recombinados para producir una nueva generación. Para la recombinación se usan dos operadores fundamentales: *crossover* y mutación. Para el mecanismo de *crossover*, dos porciones de genes son intercambiadas con una cierta probabilidad. El operador mutación por otro lado, altera cada porción del individuo aleatoriamente con cierta probabilidad. Es importante mencionar que eventualmente se pueden generar individuos infactibles, y estos se podrían eliminar de la población (estrategia abortiva) o bien mantener (pro-vida) ya sea arreglándolos o bien penalizándolos elevadamente.

En cada etapa del algoritmo, para encontrar el conjunto de Pareto Óptimo los mejores individuos serán aquellos que pertenezcan al mejor conjunto de Pareto encontrado hasta la iteración actual. Esto debido al hecho de que hay soluciones que pertenecen a la región Pareto Óptima pero aun no son encontradas, y hay soluciones que parecieran pertenecen a la región Óptima de Pareto pero no pertenecen debido a que aun no se encuentra la solución que las Pareto-domina. La solución ocupando GA en HAPC-EMO entrega frentes de Pareto sub-óptimos, pero muy cercanos al óptimo global. La porción más importante del costo computacional de aplicar este algoritmo está en computar las predicciones, las cuales se calculan recursivamente ocupando el modelo y las acciones de control dadas por el individuo. Los parámetros de sintonización de GA son el número de individuos, número de generaciones, probabilidad de *crossover*, probabilidad de mutación y criterio de parada.

4. RESULTADOS POR SIMULACION

En esta sección se resume las pruebas de simulación realizadas para visualizar los resultados del enfoque HAPC-EMO. Se simula un tiempo de dos horas representativas de un día laboral (14:00-14:59, 15:00-15:59), sobre un área urbana de servicio de aproximadamente 81 km². Se considera una flota de cuatro vehículos, con capacidad para cuatro pasajeros cada uno. Se asume que los vehículos viajan en línea recta entre paradas y que la red de transporte se comporta de acuerdo a la siguiente distribución de velocidad:

$$v(t, p, \varphi) = 20 + \left(5 - \frac{t}{12}\right) \cdot e^{-\frac{(p_x - 4)^2 + (p_y - 4)^2}{2}} + \left(\frac{t}{12} - 5\right) \cdot e^{-\frac{(p_x - 7)^2 + (p_y - 6)^2}{2}} + \varphi(t) \quad (11)$$

donde $t[\text{min}]$ es el tiempo continuo (reloj), $t=0[\text{min}]$ corresponde a las 14:00, y $t=120[\text{min}]$ a las 16:00. $p=(p_x, p_y)$ [km] denota una posición en términos del plano de coordenadas dentro del área urbana y $\varphi(t)$ es el ruido blanco que captura la estocasticidad que proviene de la congestión. Se asume que las llamadas futuras son desconocidas para el controlador. Sin embargo, se dispone de datos históricos a partir de los cuales se extraen los patrones típicos de viaje. La distribución de velocidades y los datos históricos generados por simulación siguen los patrones de viaje mostrados en la Figura 2 a) y b) respectivamente. A partir de los datos históricos y el método de zonificación difusa propuesto en Sáez et al. (2007), se determinan las coordenadas de recogida y entrega y probabilidades de los patrones más relevantes.

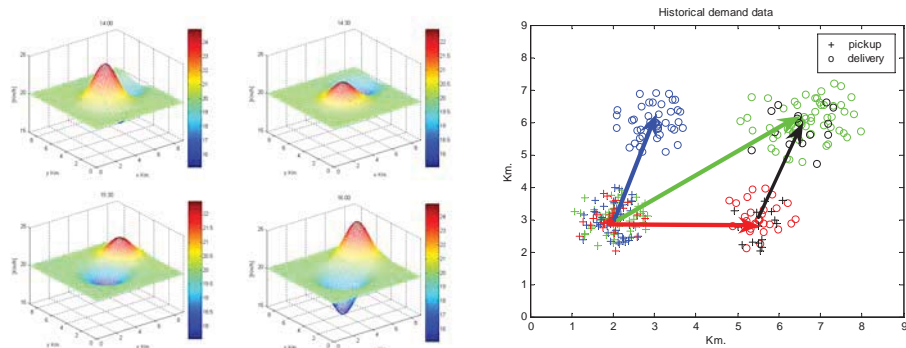


Figura 2: a) Distribución de velocidad detrás del modelo recurrente inicial. b) Demanda y patrones origen-destino.

En las pruebas de simulación, se generaron 60 llamadas sobre el periodo de simulación de dos horas siguiendo la distribución espacial y temporal que se observa de los datos históricos. Respecto de la dimensión temporal, se asumió una distribución exponencial negativa para intervalos de tiempo entre llamadas con tasa 2[llamada/minuto] para ambas horas de simulación. Respecto de la distribución espacial, las coordenadas de *pick-up* y *delivery* fueron generadas aleatoriamente dentro de cada zona. Las 10 llamadas del principio y del final de las pruebas fueron quitadas de las estadísticas para evitar distorsión de límites. 50 réplicas de cada experimento fueron realizadas para obtener las estadísticas globales. Cada replica tardó 20 minutos en promedio, en un procesador Pentium® D, 2.40Ghz. La función objetivo es a dos pasos, asumiendo parámetros $\mathcal{G}_v=16,7[\$/\text{min}]$, $\mathcal{G}_e=50 [\$/\text{min}]$, $c_t=25 [\$/\text{min}]$, $c_d=350 [\$/\text{Km}]$.

Lo primero que se reporta son resultados iniciales para HAPC con funciones mono-objetivo, asumiendo pesos $\lambda=1, 0.75, 0.5, 0.25$ y 0 , de manera de verificar que los objetivos que buscan usuarios y operadores se contraponen. Al evaluar las estadísticas globales, se obtiene la Tabla 1, con valores promedio por usuario o vehículo según sea el caso.

Tabla 1: HAPC con distintas funciones de costos

Factor de peso de: $J = \lambda J^U + (1 - \lambda) J^O$	Tiempo Viaje [min/pax]	Tiempo Espera [min/pax]	Tiempo recorrido [min/veh]	Distancia recorrida [km/veh]
$\lambda = 0$	14.0512	25.3705	82.4936	21.8086
$\lambda = 0.25$	16.2678	12.7871	106.2952	26.8951
$\lambda = 0.5$	16.4896	10.4631	111.3786	27.4946
$\lambda = 0.75$	15.8964	9.4583	113.7029	28.6032
$\lambda = 1$	16.2400	8.4579	121.7460	30.8408

Para analizar y evaluar el desempeño de las estrategias HAPC-EMO, se realizaron pruebas por simulación para dos pasos de predicción, bajo las mismas condiciones anteriores. Se presenta los resultados de 50 réplicas con GA usando 20 individuos y 20 generaciones. La Tabla 2 reporta los tiempos efectivos de espera y viaje de usuario, además de tiempo y distancia recorrida promedio para vehículos, usando HAPC-EMO para dos pasos, y los tres criterios de nivel de servicio planteados en Sección 3.1. En la Figura 3 se muestran los resultados globales obtenidos por HAPC y HAPC-EMO, mostrando las componentes de costo a usuarios y operador globales usando los distintos criterios.

Tabla 2: EMO HAPC con distintos criterios

CRITERIOS EMO	Tiempo Viaje [min/pax]	Tiempo Espera [min/pax]	Tiempo recorrido [min/veh]	Distancia recorrida [km/veh]
<i>Criterio 1</i>	15.8817	14.9941	94.4766	27.3942
<i>Criterio 2</i>	15.3825	16.6497	91.7576	26.8549
<i>Criterio 3</i>	14.8654	18.5962	88.5647	24.1264

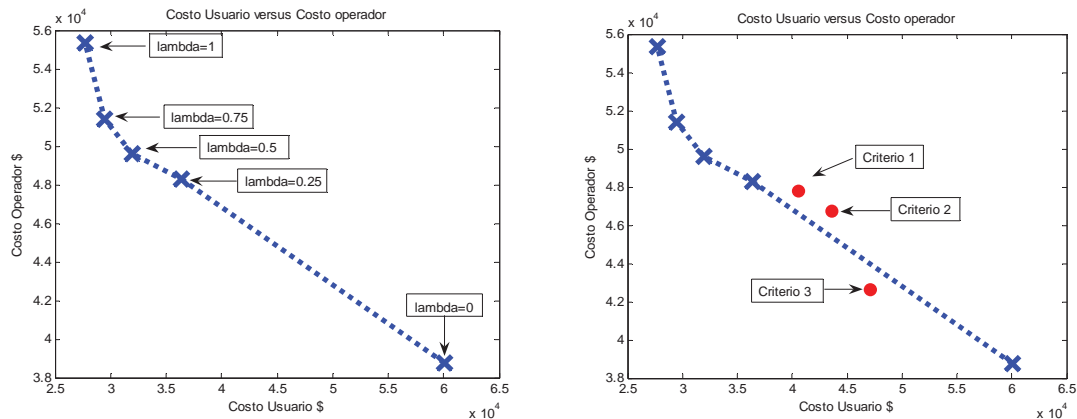


Figura 3: Frentes de Pareto. a) HAPC con distintos valores de lambda. b) Se agregan soluciones con criterios EMO .

Notar de la Figura 3 que efectivamente la premisa de que los objetivos (usuarios y operador) se contraponen se cumple al menos en estos ejemplos simulados. El enfoque HAPC-EMO genera una variedad de opciones no dominadas a ser analizadas por el tomador de decisiones y así decidir de mejor forma la política de operación en tiempo real, que no es posible descubrir bajo

un enfoque HAPC tradicional. Además, es posible agregar soluciones bajo ciertos criterios (que pueden ser tanto de nivel de servicio como de operación). En este trabajo se probaron tres criterios de nivel de servicio (Figura 3b). Con el criterio 1 se obtuvo un costo usuario igual a \$1014.4 similar a los \$1000 que se pedían en la política de servicio. Con el criterio 2 se obtuvo un costo usuario igual \$1088.86 inferior a los \$1125 que se pedían en la política de servicio. Finalmente, a partir del criterio 3 se obtuvo un costo usuario igual \$1177.7 lo cual es inferior a \$1250 por lo que se cumple también la política de servicio.

5. COMENTARIOS Y CONCLUSIONES

Este trabajo presenta un nuevo enfoque para resolver el DPDP bajo un esquema de Control Predictivo Híbrido usando Optimización Multiobjetivo evolucionaria. Se proponen tres distintos criterios para obtener acciones de control sobre el ruteo ocupando el frente de Pareto dinámico. Los criterios permitieron dar prioridad a una política de servicio para los usuarios y luego a la minimización de costos operacionales. Las políticas de servicio se verifican de manera aproximada en el promedio de las réplicas. Priorizar es distinto a penalizar, y en un sistema implementado *on-line* es mas claro para el operador seguir políticas de servicio en lugar de sintonizar parámetros de ponderación en forma dinámica. El enfoque multiobjetivo permitió obtener soluciones que se interpretan directamente del uso del frente de Pareto en lugar de resultados obtenidos con funciones mono-objetivo que carecen de interpretación física directa (los factores de peso se sintonizan pero no permiten aplicar políticas de operación o servicio del tipo de las propuestas aquí). De esta manera se indagó en soluciones más genéricas.

Como trabajo futuro, dado que los controladores mas usados no se basan en EMO, se pretende analizar con mayor detalle la relación entre EMO y HAPC, con lo cual se podrá determinar factores de peso que emulen el comportamiento de EMO. Además se investigará el sentido de aplicar otras políticas de servicio y se analizará distintas estrategias evolutivas de manera de encontrar aquella que mejor se ajuste a los requerimientos del DPDP.

AGRADECIMIENTOS

Esta investigación ha sido parcialmente financiada por los proyectos FONDECYT 1061156 y 1061261, por el Instituto Milenio “Sistemas Complejos de Ingeniería” y por el proyecto Anillo ACT-32.

REFERENCIAS

- Cortés, C.E., D. Sáez y A. Núñez (2007) Hybrid Adaptive Predictive Control for a Dynamic Pickup and Delivery Problem including Traffic Congestion. Aceptada, **revista ISI International Journal of Adaptive and Signal Processing**.
- Desrosiers, J., F. Soumis, y Y. Dumas (1986). A Dynamic Programming Solution of a Large-Scale Single-Vehicle Dial-a-Ride with Time Windows, **American Journal of Mathematical and Management Sciences** 6, 301-325.

Farina, M., K. Deb y P. Amato (2004). Dynamic Multiobjective Optimization Problems: Test Cases, Approximations, and Applications, **IEEE Transactions on Evolutionary Computation**, Vol 8, No 5, pp. 425.

Hajri-Gabouj, S.(2003). A fuzzy genetic multiobjective optimization algorithm for multilevel generalized assignment problema, **IEEE Transactions on Systems, Man and Cybernetics**, Vol 33, No 2, pp. 214-224.

Ichoua, S., M. Gendreau y J.Y. Potvin (2005). Exploiting Knowledge about Future Demands for Real-Time Vehicle Dispatching, aceptado para publicación en **Transportation Science**.

Jara, S. y A. Tudela (1991). Un modelo para la negociación en la Tarificación de servicios Metro-Bus, **Cuadernos de Economía**, año 28, n°84, pp 329-346.

Sáez, D., C.E. Cortés y A. Núñez (2007), Hybrid adaptive predictive control for the multi-vehicle dynamic pick-up and delivery problem based on genetic algorithms and fuzzy clustering, *Computers & Operations Research*, In Press. <http://dx.doi.org/10.1016/j.cor.2007.01.025>

Savelsbergh M. y M. Sol (1995). The general Pickup and Delivery problem, **Transportation Science**, Vol. 29, No. 1, pp. 17-29.

Topaloglu H. y W. Powell (2005). A Distributed Decision-Making Structure for Dynamic Resource Allocation Using Non Linear Functional Approximations, **Operations Research** **53**(2), 281-297.